

ISSN 1012-2354



ERCIYES ÜNİVERSİTESİ

FEN BİLİMLERİ
ENSTİTÜSÜ DERGİSİ

*Erciyes University
Journal of
the
Institute
of
Science and Technology*

Cilt (Vol.): 40

Sayı (No): 3



ERCİYES ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ DERGİSİ

Erciyes University Journal of Institute of Science and Technology

ISSN: 1012-2354



Genel Yayın Yönetmeni

Prof. Dr. Oktay ÖZKAN, Erciyes Üniversitesi

İmtiyaz Sahibi

Prof. Dr. Fatih ALTUN, Erciyes Üniversitesi

Baş Editör

Prof. Dr. Emel KIZILKAYA AYDOĞAN, Erciyes Üniversitesi

Editör

Prof. Dr. M. Duran TOKSARI, Erciyes Üniversitesi

Prof. Dr. M. Gökhan HALICI, Erciyes Üniversitesi

Düzenleme Editörleri

Arş. Gör. Mehmet Uğur TÜRKDAMAR

Arş. Gör. Hüseyin ÖZKAYA

Kadir YÖNAK

Editörler Kurulu

Prof. Dr. Abdulkadir BİLİŞİK, Erciyes Üniversitesi, kbilisik@erciyes.edu.tr

Prof. Dr. Mustafa Serdar ÖNSES, Erciyes Üniversitesi, onses@erciyes.edu.tr

Prof. Dr. Kamil KOÇ, Manisa Celal Bayar Üniversitesi, kamil.koc@cbu.edu.tr

Prof. Dr. Musa SARI, Gazi Üniversitesi, msari@gazi.edu.tr

Prof. Dr. Orhan BÜYÜKGÜNGÖR, Ondokuz Mayıs Üniversitesi, orhanb@omu.edu.tr

Prof. Dr. Hasan KÜÇÜKBAY, İnönü Üniversitesi, hasan.kucukbay@inonu.edu.tr

Prof. Dr. Mehmet AKKURT, Erciyes Üniversitesi, akkurt@erciyes.edu.tr

Prof. Dr. Tuncay CANDAN, The American University of the Middle East, tuncay.candan@aum.edu.kw

Prof. Dr. Derviş KARABOĞA, Erciyes Üniversitesi, karaboga@erciyes.edu.tr

Prof. Dr. M. Tamer ŞENEL, Erciyes Üniversitesi, senel@erciyes.edu.tr

Prof. Dr. Doğan IŞIK, Erciyes Üniversitesi, dogani@erciyes.edu.tr

Prof. Dr. Burak UZAL, Abdullah Gül Üniversitesi, burak.uzal@agu.edu.tr

Prof. Dr. Niğmet UZAL, Abdullah Gül Üniversitesi, nigmet.uzal@agu.edu.tr

Prof. Dr. Nuray ATEŐ, Erciyes Üniversitesi, nuraya@erciyes.edu.tr
Prof. Dr. Murat GÖKÇEK, Ömer Halisdemir Üniversitesi, mgorkeek@ohu.edu.tr
Prof. Dr. Ömer Galip SARAÇOĐLU, Erciyes Üniversitesi, saracog@erciyes.edu.tr
Prof. Dr. Semih YILMAZ, Erciyes Üniversitesi, semihyilmaz@erciyes.edu.tr
Doç. Dr. Ömer AYDIN, Erciyes Üniversitesi, omeraydin@erciyes.edu.tr
Doç. Dr. Emrah TIRAŐ, Erciyes Üniversitesi, emrahtiras@erciyes.edu.tr
Doç. Dr. Umut ÇALIŐKAN, Erciyes Üniversitesi, ucaliskan@erciyes.edu.tr
Dr. Öğr. Üyesi Erhan KARAKAYA, Yozgat Bozok Üniversitesi, erhan.karakaya@bozok.edu.tr



ERCİYES ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ DERGİSİ

Erciyes University Journal of Institute of Science and Technology

ISSN: 1012-2354



Yayın Danışma Kurulu

Prof. Dr. Fatih ALTUN, Erciyes Üniversitesi

Prof. Dr. Ülkü YETİŞ, Ortadoğu Teknik Üniversitesi

Prof. Dr. Filiz B. DİLEK, Ortadoğu Teknik Üniversitesi

Prof. Dr. Gülçin BÜYÜKÖZKAN, Galatasaray Üniversitesi

Prof. Dr. Ceyda OĞUZ, Koç Üniversitesi

Prof. Dr. Yaman BARLAS, Boğaziçi Üniversitesi

Prof. Dr. Levent KANDİLLER, Yaşar Üniversitesi

Prof. Dr. Cengiz KAHRAMAN, İstanbul Teknik Üniversitesi

Prof. Dr. Metin DAĞDEVİREN, Gazi Üniversitesi

Prof. Dr. Cevriye Temel GENCER, Gazi Üniversitesi

Prof. Dr. Mehmet TANYAŞ, Maltepe Üniversitesi

Prof. Dr. TUNCAY CANDAN, Ömer Halisdemir Üniversitesi

Prof. Dr. Li TONGXING, Linyi University

Prof. Dr. Panos M. PARDALOS, University of Florida

Prof. Dr. José Machado Minho, University

Prof. Dr. Petraq PAPAJORGJË, University of New York Tirana

Prof. Dr. Şahin YILDIRIM, Erciyes Üniversitesi

Prof. Dr. Derviş KARABOĞA, Erciyes Üniversitesi

Prof. Dr. Orhan BÜYÜKGÜNGÖR, Ondokuz Mayıs Üniversitesi



ERCİYES ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ DERGİSİ

Erciyes University Journal of Institute of Science and Technology

ISSN: 1012-2354



Cilt 40, Sayı 3, Hakem Kurulu

- Prof. Dr. Zeliha LEBLEBİCİ, Nevşehir Hacı Bektaş Üniversitesi
Prof. Dr. Mustafa Serdar GENÇ, Erciyes Üniversitesi
Prof. Dr. Ali AKDAĞLI, Mersin Üniversitesi
Prof. Dr. Ahmet ERDOĞAN, Necmettin Erbakan Üniversitesi
Prof. Dr. Şener KARABULUT, Hacettepe Üniversitesi
Prof. Dr. Ertuğrul ŞAHMETLİOĞLU, Kayseri Üniversitesi
Prof. Dr. Durmuş DAĞHAN, Niğde Ömer Halisdemir Üniversitesi
Prof. Dr. Recep KARA, Nevşehir Hacı Bektaş Üniversitesi
Prof. Dr. Çiğdem Alabaş USLU, Marmara Üniversitesi
Prof. Dr. Vecihi YİĞİT, Atatürk Üniversitesi
Prof. Dr. Murat UYSAL, Afyon Kocatepe Üniversitesi
Prof. Dr. Ercan KARAKÖSE, Kayseri Üniversitesi
Doç. Dr. Şenol KARTAL, Niğde Ömer Halisdemir Üniversitesi
Doç. Dr. Bahatdin DAŞBAŞI, Kayseri Üniversitesi
Doç. Dr. Seyhan ORAN, Bursa Uludağ Üniversitesi
Doç. Dr. Vedat YILMAZ, Erciyes Üniversitesi
Doç. Dr. Tamer DİRİKGİL, Kayseri Üniversitesi
Doç. Dr. Murat OLUTAŞ, Abant İzzet Baysal Üniversitesi
Doç. Dr. Dursun BALKAN, Türk Hava Kurumu Üniversitesi
Doç. Dr. Mustafa ZEYBEK, Selçuk Üniversitesi
Doç. Dr. Gökçe TANER, Bursa Teknik Üniversitesi
Doç. Dr. Mevlüt ŞAHİN, Niğde Ömer Halisdemir Üniversitesi
Doç. Dr. Onur ÇAVUŞOĞLU, Gazi Üniversitesi
Doç. Dr. Erkan YILMAZ, Erciyes Üniversitesi
Doç. Dr. Umut Çalışkan, Erciyes Üniversitesi
Dr. Öğr. Üyesi Lütfiye KARASAKA, Konya Teknik Üniversitesi
Dr. Öğr. Üyesi Ukbe Usame UÇAR, Fırat Üniversitesi
Dr. Öğr. Üyesi Kübra KESER, Kütahya Dumlupınar Üniversitesi

Dr. Öğr. Üyesi Habibe DURMAZ, Recep Tayyip Erdoğan Üniversitesi
Dr. Öğr. Üyesi Adem Gölcük, Selçuk Üniversitesi
Dr. Öğr. Üyesi Aydan YELTİK, TOBB Üniversitesi
Dr. Öğr. Üyesi Fatih KIRAZ, Nuh Naci Yazgan Üniversitesi
Dr. Öğr. Üyesi Murat Çağlar BAYDOĞAN, Erciyes Üniversitesi
Dr. Öğr. Üyesi İlknur Acar ATA, Niğde Ömer Halisdemir Üniversitesi
Dr. Öğr. Üyesi Mehmet CANDAN, Ankara Yıldırım Beyazıt Üniversitesi
Dr. Öğr. Üyesi Meltem KAÇIKOÇ, Süleyman Demirel Üniversitesi
Dr. Öğr. Üyesi Senem Teksoy BAŞARAN, İstanbul Medeniyet Üniversitesi
Dr. Öğr. Üyesi Kutalmış Recep AKÇA, Sakarya Üniversitesi
Dr. Öğr. Üyesi Nizar POLAT, Harran Üniversitesi
Dr. Öğr. Üyesi Hasan Bilgehan MAKİNECİ, Konya Teknik Üniversitesi
Dr. Öğr. Üyesi Abdullah VARLIK, Necmettin Erbakan Üniversitesi
Dr. Öğr. Üyesi Elif Burcu BALI, Gazi Üniversitesi
Dr. Öğr. Üyesi Nurullah ÖZTÜRK, Kayseri Üniversitesi
Dr. Öğr. Üyesi Özlem Karabiber CURA, İzmir Katip Çelebi Üniversitesi
Dr. Öğr. Üyesi Muhammet ÇELİK, Aksaray Üniversitesi
Dr. Öğr. Üyesi Sertaç Samed SEYİTOĞLU, Hitit Üniversitesi
Dr. Öğr. Üyesi Yüksel Tokur BOZKURT, Gaziantep Üniversitesi
Dr. Öğr. Üyesi Murat Emre ERKOÇ, Erciyes Üniversitesi
Dr. Öğr. Üyesi Mehmet YERLİKAYA, Selçuk Üniversitesi
Dr. Öğr. Üyesi Ümmü Gülsüm Söylemez, Muş Alparslan Üniversitesi
Dr. Öğr. Üyesi Yasin GÖRMEZ, Sivas Cumhuriyet Üniversitesi
Dr. Öğr. Üyesi Pelin AKIN, Çankırı Karatekin Üniversitesi
Öğr. Gör. Dr. Ferhat ÇEÇEN, Süleyman Demirel Üniversitesi
Arş. Gör. Sümeyra Büşra ŞENGÜL, Selçuk Üniversitesi

Cilt: 40 Sayı: 3

Aralık 2024

İçindekiler

| Sayfalar | Makaleler | Türü |
|----------|--|--------------------|
| 450-461 | Sentez Farklılıklarının ZnS Nanopartiküllerin Yağlayıcı Katkısı Olarak Kullanımında Tribolojik Özelliklere Etkisi | Araştırma Makalesi |
| 462-468 | Experimental Investigations of Pulse Oscillators | Araştırma Makalesi |
| 469-478 | Manual and Remote-Controlled Secondary Emission Calorimeter Modules for High-Radiation Environments | Araştırma Makalesi |
| 479-486 | Farklı Tanecik Boyutu ve Ağırlık Fraksiyonlarında Karbon Nanotüp Kullanılarak Üretilen Radar Soğurucu Kompozit Malzemelerin İncelenmesi | Araştırma Makalesi |
| 487-497 | Smart Classroom Attendance and Management System with Deep Learning | Araştırma Makalesi |
| 498-517 | Teknopark Firma Performanslarının Çok Kriterli Karar Verme Yöntemleriyle İncelenmesi | Araştırma Makalesi |
| 518-527 | A Hybrid Deep Learning Model for Traffic Flow Prediction | Araştırma Makalesi |
| 528-534 | CR3022 Antikoru ile Cihazdan Bağımsız Pratik Kağıt Tabanlı İmmünotest ile Direkt SARS CoV-2 Teşhisi | Araştırma Makalesi |
| 535-558 | Panoramik Radyograflarda Anatomik Yer İşaretlerinin Yapay Zeka Destekli Otomatik Tespiti | Araştırma Makalesi |
| 559-569 | Farklı Geometriye Sahip Savaklarda Nümerik Modeller ile Elde Edilen Debi Katsayılarının İncelenmesi | Araştırma Makalesi |
| 570-586 | Yüksek FFA İçerikli Yağlar: Doğrudan Transesterifikasyon ve Ardışık Esterifikasyon-Transesterifikasyon Prosesleri ile Biyodizel Üretiminin Karşılaştırmalı Analizi | Araştırma Makalesi |
| 587-608 | Güvenlik Duvarlarındaki Ağ Trafik Log Kayıtlarının Analizinde Açıklanabilir Yapay Zekâ ve Derin Sinir Ağlarının Kullanımı: Karşılaştırmalı Bir Analiz | Araştırma Makalesi |
| 609-626 | Avrupa Ülkelerinde ve Türkiye'de Trafik Kazalarının İstatistik Tekniğine Göre Kümelenmesi | Araştırma Makalesi |
| 627-634 | Endemik Lomelosia pseudograminifolia (Hub.-Mor.) Greuter & Burdet'nın Antioksidan ve Antibakteriyel Aktivite Yönünden İncelenmesi | Araştırma Makalesi |
| 635-642 | Application of the MABAC Method for the Selection of Denim Fabrics with Sustainability Framework | Araştırma Makalesi |
| 643-649 | A New Hybrid Clover from Türkiye with Evidence From Morphological Data and a New Combination | Araştırma Makalesi |
| 650-660 | Classification of System and Software Related FDA Medical Device Recalls with a Three-Level Taxonomy Approach: Defibrillator Case | Araştırma Makalesi |
| 661-669 | Investigation of Pilot Reaction Time on Automatic Ground Collision Avoidance System | Araştırma Makalesi |

Sentez Farklılıklarının ZnS Nanopartiküllerin Yağlayıcı Katkısı Olarak Kullanımında Tribolojik Özelliklere Etkisi

Alper Uğur*¹ , İlker Avan² 

*¹Eskişehir Teknik Üniversitesi, Ulaştırma Meslek Yüksekokulu

²Eskişehir Teknik Üniversitesi

(Alınış / Received: 29.06.2024, Kabul / Accepted: 13.11.2024, Online Yayınlanma / Published Online: 30.12.2024)

Anahtar Kelimeler

*Katkılar,
ZnS,
1-Oktanitiol,
Yağlayıcı,
Aşınma*

Öz: Aşınma ve sürtünme nedenli ekonomik kayıpların azaltılması için yağlayıcıların kullanılması etkili çözüm yöntemlerinden biridir. Yağlayıcılara eklenen katkı malzemeleri ile yağlayıcının tribolojik ve termofiziksel özelliklerinin gelişmesi amaçlanmaktadır. Bu çalışmada çinko sülfür (ZnS) nanopartiküllerin (NP) farklı sıcaklıkta (10 ve 70 °C) ve farklı çözücüde (1-Propanol ve etil alkol) sentez parametrelerinin değiştirilerek farklı tanecik yapılarında ZnS NP'ler elde edilmiştir. Bu nanopartiküllerin motor yağına eklenmesiyle elde edilen ZnS NP katkılı yağlayıcıların tribolojik özelliklerindeki değişimler incelenmiştir. Bulgularımız, ZnS NP lerin 10 °C de Etil alkol (EtOH) içerisinde sentezlenmesiyle daha küçük boyutlu taneciklerin oluştuğunu ve bunların 0–200 °C aralığında yüksek termal kararlılığa sahip olduğunu göstermiştir. Bu nanopartiküllerin 10W motor yağına eklenmesiyle yağın vizkozitesinde bir artışa ve bu ZnS NP katkılı yağlayıcının sürtünen metal yüzeyler arasındaki aşınmayı %39'a varan oranda azalttığı belirlenmiştir.

Effect of Synthesis Differences on Tribological Properties of ZnS Nanoparticles as Lubricant Additives

Keywords

*Additives,
ZnS,
1-Octanethiol,
Lubricant,
Wear*

Abstract: The use of lubricants to reduce economic losses caused by wear and friction is one of the effective solution methods. The additives added to the lubricant aim to improve the tribological and thermophysical properties. In this study, zinc sulfide (ZnS) nanoparticles (NPs) with various particle structures were synthesized by altering the synthesis parameters at different temperatures (10 and 70 °C) and using solvents (1-propanol and ethyl alcohol). The tribological properties of lubricants were investigated after ZnS nanoparticles were added to the base oil. Our findings indicated that smaller-sized particles were formed by the synthesis of ZnS NPs in ethyl alcohol (EtOH) at 10 °C. These particles exhibited high thermal stability in the range of 0–200 °C. It was determined that adding nanoparticles to the 10W engine oil increased the viscosity and reduced the wear between the rubbing metal surfaces by up to 39%.

1. Giriş

Uluslararası Enerji Ajansı verilerine göre ulaştırma sektörünün enerji tüketim payı %28'dir [1]. Bu oranın %11'i ise yolcu araçlarına aittir ve bu araçlarda yakıt enerjisinin %33'ünün sürtünme kayıplarına harcandığı belirtilmiştir [2]. Sürtünmenin etkisiyle hareketli parçaların temas yüzeylerinde deformasyon oluşması ve mekanik malzeme kaybı olarak tanımlanan aşınma sonucunda, yıpranmış ya da işlevini yitirmiş mekanik parçaların değişimi ekonomik kayıpları da beraberinde getirmektedir [3]. Yağlama ile sürtünme ve aşınma kayıplarına çözüm getirilebilmektedir [4]. Günümüzde her ne kadar elektrikli araçlara olan ilgi artsa da yataklama ve dişli bölgelerinde daha az miktarlarda olsa da gelişmiş yağlayıcılara ihtiyaç olacaktır. Küresel otomotiv yağları pazarı gelişme beklentileri 2024–2032 yılları arasında %4'lük bir bileşik yıllık büyüme oranını (CAGR) öngörmektedir [5]. Yağlama tekniğinde uygulanan yağlayıcı maddelerin büyük çoğunluğu hidrokarbon bileşikleridir ve %80 baz yağ ve %12–20 yağ katkı malzemelerinin karışımından oluşmaktadır [6–8]. Yağ katkı

malzemeleri yağın tribolojik ve termofiziksel özelliklerinin gelişmesini sağlamaktadırlar [9-11]. Nano partikül (NP) yağ katkıları; yapı özellikleri ve düşük partikül boyutları ile temas arayüzeyinde oluşturdukları yüksek yüzey alanı ve kimyasal etkileşimlerle tribolojik davranışların iyileştirilmesi için kullanılmaktadır [12-15]. Nanometal temelli yağ katkıları genellikle saf metaller (Cu, Ag, Fe, Pd, Ni) metal oksitler (CuO, ZnO, Al₂O₃, TiO₂, ZrO₂), metal sülfürler (WS₂, MoS₂, CuS, FeS, ZnS), metal hidroksitler ve metal tuzlarını içerirler [16-18]. Bunların arasında sülfürlü nanopartiküller ve özellikle yağ ile etkileşimi arttıran organik ligand kaplı NP'lerin yağ katkısı olarak kullanımı ön plana çıkmaktadır [19-21]. ZnS NP'ler yüksek yüzey/hacim oranı [22], termal kararlılık, ve sentezlerindeki düşük maliyet nedenleriyle tribolojik performansı geliştirmek üzere katkı olarak yaygın olarak kullanılmaktadır [23-26]. Örneğin, 2000 yılında Chen ve Liu di-n-heksadesilditiyofosfat (DDP) kaplı ZnS NP'leri sıvı parafin içerisine 0.1 (ağırlıkça %) oranında eklenmesiyle elde edilen katkılı yağın organik ligandsız ZnS NP'lere göre aşınmayı düşürdüğünü, ve NP'lerin termal kararlılığı arttırdığını belirlemişlerdir [27, 28]. 2015'de Wang ve ark., yüzeyi polietilen glikol monometil eter ditiyofosfat ile modifiye edilmiş ZnS NP'lerinin %0,6 oranında polietilen glikol içinde eklendiğinde oluşan yağlayıcının tribolojik özelliklerini önemli ölçüde geliştirdiğini göstermişlerdir [29]. Lu ve ark. 2019 yılında etilendiamin bağlı ZnS nanoparçacığını üretmiş ve lityum gresi içerisine katkılayarak yağlama değişimini incelemeleri sonucunda yağın tribolojik özelliklerinin iyileştiğini belirlemişlerdir [30]. 2023 yılında Kumara ve ark. Dodekanol ile modifiye edilmiş ZnS NP'lerin Polialfaolefin (PAO) yağlayıcısına eklendiğinde; ticari katkı maddesi çinkoditiyofosfat (ZDDP)'dan üstün aşınma engelleyici performans gösterdiğini belirtmişlerdir [31]. Yağ katkısı olarak çeşitli NP'lerin sentezi ve bunların yağlara eklenmesiyle değişen tribolojik özelliklerin belirlenmesi konusunda araştırmalar yapan grubumuz, önceki çalışmalarımızda yüzey fonksiyonlama ajanı olarak oktantiyol (OT) (C₈H₁₈S) ve çeşitli polimerleri içeren ZnS ve ZnO NP lerin sentezini ve bunların 10W ve 5W-30 motor yağlarına eklenmesiyle elde edilen nano katkılı yağlayıcıların tribolojik özelliklerini ortaya koymuştur [32, 33]. Adı geçen organik ligandları içeren NP ler ile elde edilen yağlayıcılar, bu ligandları içermeyen türlerine göre aşınmanın azaltılmasında daha yüksek performans göstermişlerdir. Yağ katkısı olarak NP'lerin sentezi ve kullanılmasına dönük çalışmalarımızın devamı olarak bu çalışmamızda, sıcaklık ve çözücü gibi sentez parametrelerinin değiştirilmesiyle farklı tanecik yapısında ZnS NP'lerin sentezlenmesi ve bunların yağ katkısı olarak kullanılmasıyla oluşturulan motor yağlarının tribolojik özelliklerindeki değişimler ortaya koyulmuştur.


2. Materyal ve Metot

2.1. OT-ZnS Nanopartiküllerin hazırlanışı

ZnS NP'ler daha önce prosedürü verildiği şekilde sentezlenmiştir [32]. İlk olarak çinko asetat (10 mmol) çözücü 100 mL etil alkol (EtOH) veya 1-propanol (1-PrOH) içerisinde 70 °C'ye ısıtılarak çözülmüştür. 1-oktantiyol (OT) (1,46 g, 10 mmol) içeren 50 mL (EtOH veya 1-PrOH) çözeltisi üzerine, 10 mL 1,0 M NaOH sulu çözeltisi ilave edilerek kapatma ajanı çözeltisi hazırlanmıştır. Kapatma ajanı çözeltisi, belirtilen sıcaklıkta çinko çözeltisine eklendi ve bu karışım 30 dk karıştırıldı. Başka bir kaptaki 2,40 g Na₂S.9H₂O (10 mmol S²⁻), 100 mL (EtOH veya 1-PrOH) içerisinde 60-70 °C'ye ısıtılarak çözüldü. Sıcak ekleme yönteminde hazırlanan karışımlar bu sıcaklıkta eklenirken, soğuk ekleme yönteminde ise karışımlar belirtilen sıcaklıklarda ve çözücülerde Na₂S çözeltisi, kuvvetli bir şekilde karıştırılan Zn²⁺ çözeltisine eklenerek OT kaplı ZnS nanopartiküllerin oluşumunu sağlanmıştır (**Şekil 1**). Elde edilen nanopartiküller EtOH ile birkaç defa yıkandı, çözünen kısımları santrifüj ile uzaklaştırıldı ve kalan nanopartiküller vakum altında kurutulmuştur. **Tablo 1**'de belirtilen şartlarda sentezlenen A, B ve C kısaltmalı ZnS NP numuneleri sentez parametreleri verilmiştir.

Tablo 1. ZnS NP sentez parametreleri.

| Numune | Çözücü | Sıcaklık (°C) |
|--------|--------|---------------|
| A | 1-PrOH | 70 |
| B | 1-PrOH | 10 |
| C | EtOH | 10 |



Şekil 1. Oktantiyol kaplı ZnS nanopartikül eldesinin şematik gösterimi

2.1. Karakterizasyon

2.1.1. FTIR analizleri

Kapatma ajanı ile işlem görmemiş ve işlem görmüş numune ZnS nanopartikülüne ait Fourier Dönüşümlü Kızılötesi (FTIR) Spektrumları Spectrum 100 (PerkinElmer , USA) cihazında 4000–600 cm^{-1} dalga sayısı aralığında KBr peletleri hazırlanarak elde edilmiştir.

2.1.2. DTA/TG/DTG analizleri

Diferansiyel Termal Analiz (Differential Thermal Analysis, DTA), Termogravimetri (Thermogravimetry, TG) ve DTG (Diferansiyel Termal Termogravimetrik) analizleri termal analizör STA 449 F3 Jupiter (NETZSCH-Gerätebau GmbH) cihazı kullanılarak, 10 $^{\circ}\text{C}/\text{dk}$ ısıtma hızında N_2 atmosferinde 550 $^{\circ}\text{C}$ sıcaklık şartlarında yapılmıştır.

2.1.3. DLS partikül boyutu analizleri

Partikül boyut dağılımı, Zetasizer Nano-ZS (ZEN 3600, Malvern Panalytical Ltd., UK) cihazı kullanılarak toz numunelerin 1-propanol çözücüsü içinde 1 dk. dağıtılması ardından yapılmıştır.

2.1.4. Mikroyapı analizleri

2.1.4.1 SEM-EDX analizleri

Numunelerin morfolojik karakterizasyonu yüksek çözünürlüklü SEM Ultra plus (Carl Zeiss Microscopy GmbH., Almanya), mikroyapıların element analizi ise Enerji Dağılımlı Spektroskopi (EDX) (Oxford Instruments, UK) kullanılarak yapılmıştır. Morfolojik karakterizasyondan önce numune, yüzey yüklemeye etkilerini azaltmak için ince Au/Pd katmanlarıyla püskürtmeyle kaplanmıştır (Agar Scientific Ltd, UK).

2.1.5. OT-ZnS katkılı yağlayıcıların hazırlanması

Tablo 1'de belirtilen şartlarda sentezlenen A, B ve C kısaltmalı ZnS NP numuneleri; 10W motor yağı içine % 0,0125 (ağırlıkça) katılarak 12 s manyetik karıştırıcıda karıştırılarak AY, BY ve CY kısaltmalı yağlayıcılar hazırlanmıştır. Tek dereceli 10W motor yağı; diğer motor yağlarına göre içeriğinde az katkı maddesi içermektedir. Yağ katkısı olarak sonradan eklenen NP'lerin etkinliğinin daha belirgin bir şekilde incelenebilmesi için 10W motor yağı seçilmiştir.

2.1.6. Vizkozite ölçümleri

Dinamik vizkozite ölçümleri Brookfield RV DV3T (Brookfield, USA) tip reometre ile 21 nolu spindle kullanılarak 200 d/d, 25 $^{\circ}\text{C}$ şartlarında yapılmıştır.

2.2. Aşınma testleri

Aşınma testlerinde Timken metodu prensibine göre ASTM D2509 [34] ve ASTM D2782 [35] standartları kapsamında tasarlanan aşınma test cihazı, aşınma malzeme çifti olarak sabit C40 pimleri ve dönen 1.2379 alaşımli çelik alaşım silindirler kullanılmıştır. Aşınma testlerinde yükler pnömatik piston vasıtasıyla elde edilmiş yük hücresi vasıtasıyla uygulanan yükün (80 kg) homojenliği anlık olarak kontrol edilmiştir. Piston koluna bağlı pim ($\text{Ø}20 \times 16$, sertlik ort. 25 HRC) numuneler, motordan tahrik alan 1000 d/d hızında dönen silindire ($\text{Ø}21 \times 15$, sertlik ort. 62 HRC) doğru bastırılarak, 10 dk süresince yağlı ortamda numunelerin aşınma davranışları incelenmiştir. Aşınma kaybı miktarları numunelerin test öncesi ağırlığından - test sonrası (g) ağırlığı çıkartılarak hesaplanmıştır.

2.2.1. Optik mikroskop analizleri


Aşınmış yüzeylerin görüntü incelemesinde optik mikroskop Discovery V12 SteREO model mikroskop (Carl Zeiss Microscopy GmbH., Almanya), ve PlanApoS 0.63x FWD 81 mm. objektif kullanılmıştır.

3. Bulgular ve Tartışma

3.1. OT-ZnS sentez sonuçları

3.1.1. FTIR


FTIR spektroskopisi sonuçları **Şekil 2**'de verilmiştir. 3500 – 3300 cm^{-1} aralığındaki pikler NP'lerin yüzeyine tutunan su moleküllerine ait O-H gruplarının sinylidir. OT alifatik gruplarındaki CH_3 ve CH_2 asimetrik ve simetrik gerilme pikleri sırasıyla 2955 cm^{-1} ve 2922 cm^{-1} ile 2852 cm^{-1} de belirgin bir biçimde tespit edilmiştir [36, 37]. 1646 – 1622 cm^{-1} ve 1456 – 1417 cm^{-1} aralığındaki sırasıyla C=O (karbonil) grubu ve $-\text{CH}_3$ asimetrik eğilme pikleri olup [37, 38] yıkama sonrası yüzeyde kalan asetat bileşiklerine aittir. C numunesi NP'lerinin IR sinyallerinden, asetat kalıntısından kaynaklanan 1620 ve 1130 sinyallerinin, A ve B numunelerine göre daha zayıf ortaya çıkması ve 2950 – 2820 cm^{-1} civarındaki alifatik sinyallerin gücünün artması C numunesi üzerinde daha fazla oktantiyol bağlandığının bir göstergesidir. Benzer şekilde, C numunesinin IR analizleri EDX analizlerinde de daha yüksek miktarda kükürt elementini içeriğiyle uyumludur. Zn-S bağına ait karakteristik pikler 1002 – 965 cm^{-1} ve 660 – 640 cm^{-1} 'deki ZnS bandına ait sülfütlere karşılık gelen pikler olarak tespit edilmiştir [39-41].




Şekil 2. FTIR spektrumları.

3.1.2. Termal analiz sonuçları (TG, DTG, DTA)


Termal analizler mekanik bir sistemin en genel anlamda maruz kaldığı 0–200 °C gibi normal çalışma sıcaklığı [42] ve 200–500 °C gibi aşırı çalışma sıcaklığı olmak üzere iki farklı sıcaklık aralığında incelenmiştir (Şekil 3 a, b, ve c). DTG ve DTA eğrilerinde A, B ve C numuneleri için 0–200 °C aralığında sırasıyla 68,2 °C, 116,2 °C, 93,9 °C, ve 68,2 °C ile 108,7 °C ve 200–500 °C aralığında ise 263,1 °C, 297,9 °C, ve 327,2 °C’de kütle kaybını gösteren endotermik pikler tespit edilmiştir. 0–200 °C aralığında A, B ve C örneklerinin ağırlık kaybı (%) değişimi sırasıyla 5,63, 8,29, ve 5,40 olarak ölçülmüştür (Şekil 4). 0–200 °C aralığında en düşük ağırlık kaybı (%) değeri 5,4 ile C numunesine aittir. Maksimum endotermik pik C numunesinde 327,2 °C olarak aşırı çalışma aralığında oktantiyol ligandlarının eliminasyonu ile en yüksek kütle kaybına uğramıştır (Şekil 5).



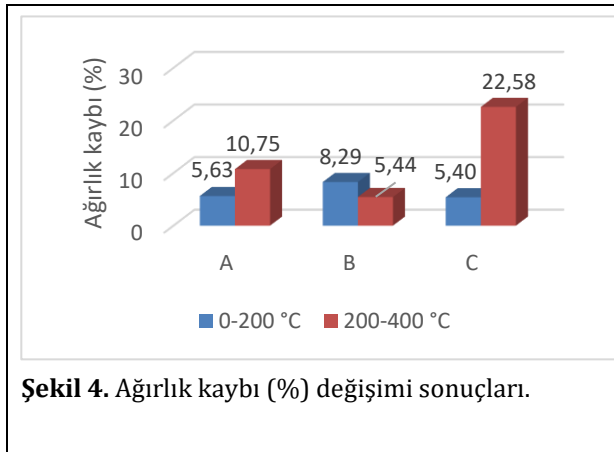
Şekil 3. a. Diferansiyel termal termogravimetrik (DTG) analiz sonucu.




Şekil 3. b. Diferansiyel termal analiz (DTA) sonucu.



Şekil 3. c. Termogravimetrik (TG) analiz sonucu.



Şekil 4. Ağırlık kaybı (%) değişimi sonuçları.



Şekil 5. En yüksek endotermik pik sıcaklık değerleri değişimi analiz sonucu.

3.1.3. DLS sonuçları

DLS ile partikül boyutları incelendiğinde, EtOH içerisinde soğukta sentezlenen C numunesinin 178 nm ile en düşük NP boyutlarında elde edildiğini görülmektedir. 1-PrOH çözücüsünde 70 °C de yapılan sentezde 318 nm boyutunda NP ler elde edilirken sentez sıcaklığının düşürülmesiyle B numunesinde 195 nm’de daha küçük parçacık boyutu oluşturulmasını sağlamıştır. Bu durum düşük sıcaklıklarda OT kapatma ajanları ZnS yüzeylerinin daha fazla etkileşime girerek NP topaklaşmanın engellenmesiyle daha küçük tanecikli yapıların oluşumunu


sağlamıştır. Yine düşük sıcaklıkta 1-PrOH yerine daha yüksek polariteli EtOH kullanılmasıyla, OT ile kaplı ZnS NP ler bu çözücüde 1-PrOH ye göre daha fazla askıda kalamayıp yaklaşık 178 nm boyutunda NP ler oluşturmuştur (**Tablo 2**). Bu bulgularımıza benzer şekilde, Bahena-Martinez ve ark. ZnS NP'lerin sentez sıcaklığının (120-180 °C) NP tanecik boyutlarına etkisini inceledikleri çalışmalarında artan sıcaklıkla partikül boyutlarının arttığını belirtmişlerdir [40].

Tablo 2. Partikül boyutu ölçüm sonuçları

| Numune ismi | Partikül boyutu (nm) |
|-------------|----------------------|
| A | 318 |
| B | 195 |
| C | 178 |

3.1.4. SEM

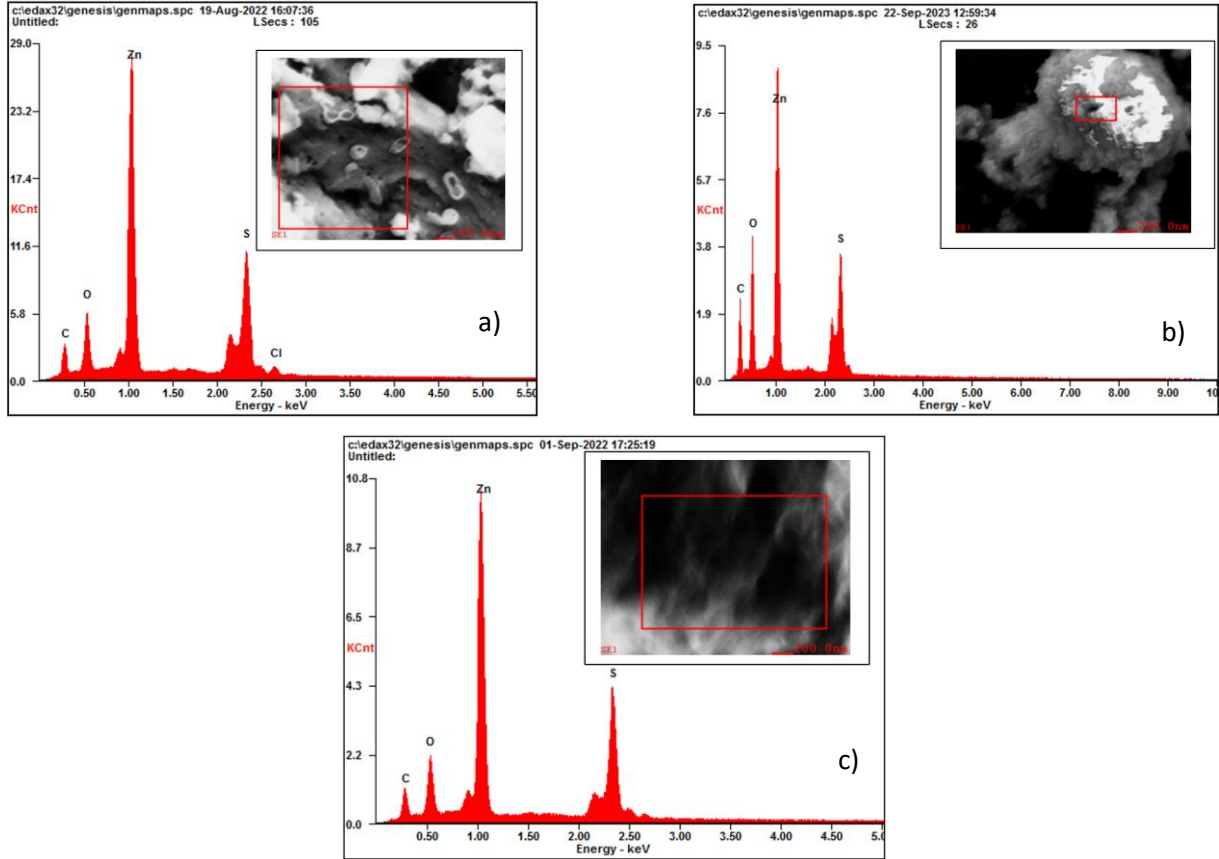
SEM analizi sonuçları **Şekil 6**'da verilmiştir. Görüntüler incelendiğinde sentezlenen ZnS NP'lerin birbirine kümelenmiş formlarda olduğu gözlemlenmiştir. ZnS NP'lerin sentezinde sıcaklık ve çözücünün değiştirilmesi tanecik morfolojisini büyük ölçüde değiştirmiştir. 1-PrOH çözücüsü içerisinde 70 °C de yapılan sentezde 318 nm boyutunda yığın halinde NP ler elde edilirken, sentez sıcaklığının 10 °C düşürülmesiyle **Şekil 6, B** numunesinde görüldüğü üzere daha küçük boyutta küresel yapılar oluşturulmasına neden olmuştur. Ancak, yine düşük sıcaklıkta C örneğindeki gibi çözücü polaritesinin artırılması kürecikli formdan ziyade C numunesi yapısındaki gibi rastgele yığıntılı yapılar formuna geçmiştir.



Şekil 6. SEM görüntüleri.

3.1.4.1. EDX

Elementsel analiz sonucunda elde edilen sonuçlar sırasıyla A, B ve C numuneleri için **Şekil 7** a, b ve c'de aşağıda verilmiştir. Elementlerin ağırlıkça ve atomik yüzde olarak miktarları **Tablo 3**'de görülmektedir. Elde edilen sonuçlara göre S (% ağırlıkça) miktarları sırasıyla A, B ve C numuneleri için 26,59, 22,63 ve 27,83 olarak ölçülmüştür. Düşük sıcaklıkta ve yüksek polariteli çözücü kullanılarak sentezlenen C numunesinin IR spektrumunda $-CH_2-$ ve $-CH_3$ sinyallerinin daha belirgin olması ve EDX analizlerinde bu numunede daha fazla oranda kükürt ihtivası (% 27,83) bu NP'ler üzerinde daha fazla OT ligandı bulunduğuna dair bulguları güçlendirmektedir. SEM-EDX numunelerinin yapışkan karbon bantlar üzerinde hazırlanması ve bu bantların karbon analizlerinde yer alması nedeniyle EDX analizlerinde karbon elementi yüzdesine bağlı değerlendirmelerin yapılmasını güçleştirmektedir.



Şekil 7. Numuneler a) A, b) B, ve c) C için EDX spektrumları sonuçları

Tablo 3. EDX analiz sonuçları


| Element | A | | B | | C | |
|---------|--------------|----------|--------------|----------|--------------|----------|
| | Ağırlık % | Atomik % | Ağırlık % | Atomik % | Ağırlık % | Atomik % |
| C | 13,24 | 33,92 | 22,62 | 46,23 | 12,75 | 33,42 |
| O | 7,81 | 15,02 | 13,71 | 21,04 | 7,17 | 14,11 |
| Zn | 50,09 | 23,58 | 41,04 | 15,41 | 52,25 | 25,16 |
| S | 26,59 | 25,51 | 22,63 | 17,32 | 27,83 | 27,32 |
| Cl | 2,27 | 1,97 | - | - | - | - |

3.1.5. Vizkozite ölçüm sonuçları

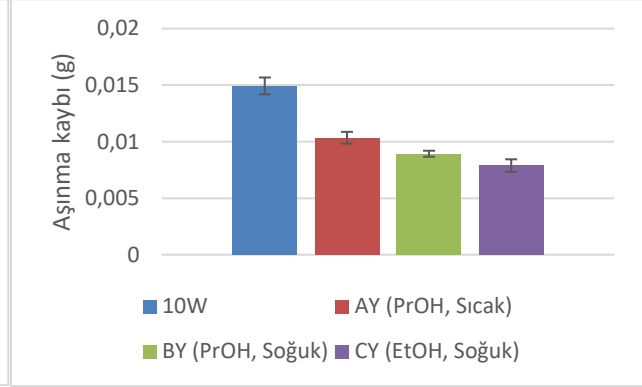
Yağın lipofilik unsurlarıyla etkileşime giren ve onların hareketini kısıtlayan oktantiyol kaplı ZnS NP'lerinin yağ içerisinde dağılımları nedeniyle ortaya çıkan ZnS katkılı yağlayıcıların viskozitesi temelde viskozitesi 84 cP olan yağın viskozitesini arttırmıştır. NP katkılı yağlayıcıların vizkozite ölçümleri Şekil 8'dedir. Sırasıyla yağlayıcı numuneler; AY, BY ve CY yağları için vizkozite değerleri sırasıyla 90, 89 ve 87,6 cP olarak ölçülmüştür.

3.2. Aşınma test sonuçları

Aşınma testi sonuçlarına (**Şekil 9**) göre en düşük aşınma oranı C numunesinde çıkmıştır. Sentez işleminde 10 °C proses şartlarında ve EtOH kullanıldığında elde edilen NP'lerin aşınma kaybını 10W yağ ile karşılaştırıldığında ortalama %39 oranında azalttığı hesaplanmıştır. IR ve EDX analizleri, C numunesinde OT ligandının diğer ZnS NP'lere göre daha fazla miktarda OT ligandını ihtiva ettiğini işaret etmektedir. OT ligandının gösterdiği lipofilik etki ile bu ligandı daha fazla içeren C gibi ZnS NP örneklerinin yağ içerisinde diğer NP lere göre daha fazla dağılmasını sağlamaktadır. Fazla OT ligandı ihtivasi nedeniyle yağ içerisine daha fazla dağılma gösteren C numunesinin yağ katkısı olarak kullanılmasıyla elde edilen yağlar (CY) ile yapılan aşınma testlerinde temas eden yüzeylerinde aşınmayı daha fazla azaltıcı yönde etki sağladığı görülmüştür (**Şekil 9**).



Şekil 8. Viskozite ölçüm sonuçları




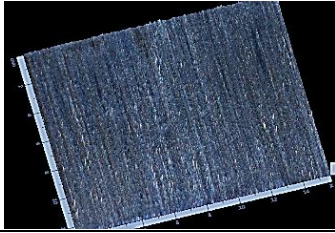

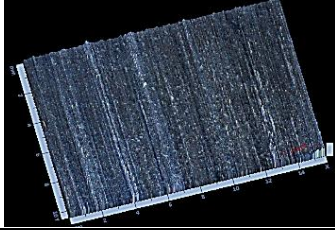
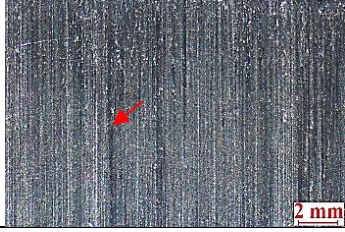
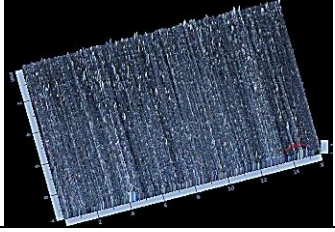
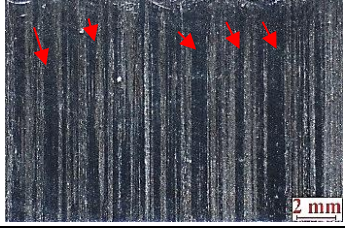
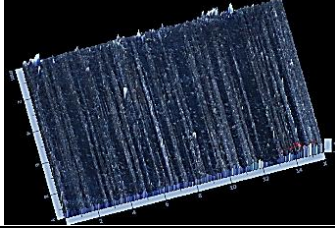
Şekil 9. Aşınma kaybı (g) sonuçları

3.2.1. Optik mikroskop analiz sonuçları

Aşınma testi sonrası aşınmış yüzeylerin genel görüntüleri **Şekil 10**'da görülmektedir. Aşınma izi boyutlarının ölçümünde; yatay eksen: x ve dikey eksen: y ile ifade edildiğinde yatay ölçülerin hemen hemen aynı olduğu ölçülmüştür bu oluşturulan yük etkileşiminde baskının kontak noktasında homojen olarak her ölçümde oluşturulduğunu göstermektedir. Dikey eksendeki y ölçülerinde ise sentez parametreleri değişen AY, BY ve CY yağlayıcılarıyla sırasıyla aşınma izinin boyutlarının düştüğü ve en iyi sonucun 1.86 mm ölçüsü ile CY yağlayıcısıyla elde edildiği belirlenmiştir. **Şekil 11**'de ise büyütülmüş optik mikroskop görüntülerinin yanında 2.5D profil görüntüleri de verilmiştir. Yüzey profilleri incelendiğinde 10W yağa göre diğer numunelerde OT kaplı ZnS NP'lerin malzeme çiftleri arasında kontak noktasındaki yük kaynaklı basınç, sürtünme kaynaklı oluşan ısı sonucunda tribokimyasal reaksiyonu sonucu yüzeylerde bir şerit şeklinde tribofilm oluşumu [25, 43-45]} gözlemlenmiş ve kırmızı oklarla gösterilmiştir. Özellikle en iyi sonuçlar CY yağlayıcısında, sınır yağlama koşullarında belirgin bir şekilde adeziv aşınma kaynaklı aşınma oluklarının azalması ve tribofilm bölgelerinin artması şeklinde gözlemlendiğinden, sentez parametrelerinin aşınmayı azaltıcı yönde etkisi görülmektedir.

| Yağlayıcı | Optik mikroskop görüntüleri | x (mm) | y (mm) |
|-----------|-----------------------------|--------|--------|
| 10W | | 14,99 | 2,62 |
| AY | | 14,92 | 2,29 |
| BY | | 14,89 | 2,06 |
| CY | | 14,85 | 1,86 |

Şekil 10. Aşınmış yüzey görüntüleri

| Yağlayıcı | Optik mikroskop görüntüsü | 2.5D Profil görüntüsü |
|-----------|--|---|
| 10W |  |  |
| AY |  |  |
| BY |  |  |
| CY |  |  |

Şekil 11. Aşınmış yüzey görüntüleri.

4. Sonuç

Bu çalışmada, farklı iki sıcaklıkta (10 ve 70 °C) ve farklı iki çözücü (PrOH, EtOH) gibi NP sentez parametrelerinin değiştirilmesiyle ZnS NP'lerin tanecik özelliklerinin değiştiği ve bu NP'ler ile hazırlanan yağlayıcıların tribolojik özelliklerindeki farklılaşma nedeniyle aşınma testlerindeki etkinliklerinin değiştiği bildirilmiştir. ZnS NP'lerin tanecik özelliklerinin incelendiği SEM, EDX, DLS ve IR analizlerinden elde edilen bulgulara göre 1-PrOH çözücüsü içerisinde 70 °C de yapılan sentezde 318 nm boyutunda rast gele yığıntılar ve büyük kürecikli yapılar halinde NP ler elde edilirken sentez sıcaklığının düşürülmesiyle B örneği gibi 195 nm de daha küçük parçacık boyutlu kürecikli oluşturulmasını sağlamıştır. Yine düşük sıcaklıkta 1-PrOH yerine daha yüksek polariteli EtOH kullanılmasıyla, OT ile kaplı ZnS NP ler bu çözücüde 1-PrOH ye göre daha fazla askıda kalamayıp yaklaşık 178 nm boyutunda rastgele kümelenmiş NP ler oluşturmuştur. Sentez sıcaklığının düşürülmesiyle OT ligandlarının ZnS yüzeylerinin daha fazla tutunarak NP topaklaşmasını engellediği ve çözücünün polaritesinin de artışının lipofilik karakterdeki NP lerin daha hızla çözücü ortamından uzaklaşarak daha küçük tanecikli yapıların oluşumunu sağlamıştır. Sentezlenen ZnS NP'ler, 0–200 °C aralığı gibi birçok mekanik sistemin çalıştığı sıcaklık bölgesinde oldukça kararlı olduğu termal analizlerde ortaya çıkmıştır. A ve C numuneleri en fazla %5,6 kütle kaybı ile B numunesinden daha kararlı yapıda olduğu görülmüştür. Sentezlenen OT-ZnS NP'lerin ağırlıkça % 0,0125 oranında 10W özellikli temel yağa katılmasıyla oluşan yağlayıcının akışkanlığı düşürülerek temel yağın vizkozitesinden (84 cP) daha yüksek yağlayıcılar elde edilmiştir. Vizkozitesi artmış ZnS NP katkılı yağlarla yapılan aşınma testlerinde temas eden metal yüzeylerde bu yağlayıcıların kullanılmasıyla aşınmanın azaldığı tespit edilmiştir. En düşük aşınmaya %39 ile en küçük boyutta ZnS içeren CY yağlayıcısının kullanılmasıyla ulaşılmıştır. Optik mikroskopla yapılan aşınma yüzeyi incelemelerinde, ZnS NP katkılı yağların kullanılmasıyla aşınma çizgilerinde azalma ve dağılma ile birlikte yüzeylerde aşınmayı azaltıcı şekilde tribofilm bölgelerinin oluştuğu izlenmiştir. Sonuç olarak, düşük sıcaklıkta yüksek polariteli çözücüler ile yapılan ZnS sentezlerinde daha küçük yapıda ve üzerinde daha fazla lipofilik OT grupları içeren OT-ZnS NP ler elde edilmiş ve bu NP nin temel yağlara eklenmesiyle oluşan yağlayıcıların yağlayıcılık özelliklerinde büyük gelişme olduğu belirlenmiştir.

Teşekkür

Bu çalışma, Eskişehir Teknik Üniversitesi Bilimsel Araştırma Projeleri (ESTÜ BAP) komisyonu tarafından desteklenmiştir (Proje No: 21GAP120). Termal analizler Seramik Araştırma Merkezi (SAM) A.Ş.'de yapılmıştır. Sağlanan desteğe teşekkür ederiz.

Kaynakça

- [1] Holmberg, K. and Erdemir, A. 2017. Influence of tribology on global energy consumption, costs and emissions. *Friction* 5, 3, 263-284.
- [2] Holmberg, K., Andersson, P. and Erdemir, A. 2012. Global energy consumption due to friction in passenger cars. *Tribol Int* 47, 221-234.
- [3] Holmberg, K. and Erdemir, A. 2019. The impact of tribology on energy use and CO2 emission globally and in combustion engine and electric cars. *Tribol Int* 135, 389-396.
- [4] Hutchings, I. and Shipway, P. 2017. *Tribology, Friction and Wear of Engineering Materials*. Editon Edition, Butterworth-Heinemann, United Kingdom.
- [5] Nagrale, P., *Automotive Lubricants Market Research Report Information By Material (Mineral Oil, Fully Synthetic Oil, Semi-Synthetic Oil and Bio-Based Oil), Product Type (Engine Oil, Brake Oil, Gear Oil, Grease, and Other Fluids), Application (Two Wheelers, Three Wheelers, Passenger Cars, Light-Weight Commercial Vehicles, and Heavy-Weight Commercial Vehicles), and By Region (Asia-Pacific, North America, Europe, And Rest Of The World) –Market Forecast Till 2032* <https://www.marketresearchfuture.com/reports/automotive-lubricants-market-1225>, (Erişim tarihi: 17.06.2024).
- [6] Betton, C. I. 2010. *Lubricants and Their Environmental Impact*. Editon Edition, Springer Netherlands, Dordrecht.
- [7] Speight, J. and Exall, D. I. 2014. *Refining Used Lubricating Oils*. Editon Edition, CRC Press., Boca Raton.
- [8] Lacroix-Andrivet, O., Hubert-Roux, M., Loutelier Bourhis, C., Moualdi, S., Mendes Siqueira, A. L. and Afonso, C. 2023. Characterization of Base Oil and Additive Oxidation Products from Formulated Lubricant by Ultra-High Resolution Mass Spectrometry. *Lubricants* 11, 8, 345.
- [9] Akbulut, M. 2012. Nanoparticle-based lubrication systems. *J. Powder Metall. Min* 1, 1, 1-3.
- [10] Mousavi, S. B., Heris, S. Z. and Estellé, P. 2020. Experimental comparison between ZnO and MoS₂ nanoparticles as additives on performance of diesel oil-based nano lubricant. *Sci Rep-Uk* 10, 1, 5813.
- [11] Duan, L., Li, J. and Duan, H. 2023. Nanomaterials for lubricating oil application: A review. *Friction* 11, 5, 647-684.
- [12] Zhao, J., Huang, Y. Y., He, Y. Y. and Shi, Y. J. 2021. Nanolubricant additives: A review. *Friction* 9, 5, 891-917.
- [13] Singh, A., Chauhan, P. and Mamatha, T. G. 2020. A review on tribological performance of lubricants with nanoparticles additives. *Materials Today: Proceedings* 25, 586-591.
- [14] Wang, B., Qiu, F., Barber, G. C., Zou, Q., Wang, J., Guo, S., Yuan, Y. and Jiang, Q. 2022. Role of nano-sized materials as lubricant additives in friction and wear reduction: A review. *Wear* 490-491, 204206.
- [15] Chen, Y., Renner, P. and Liang, H. 2023. A review of current understanding in tribochemical reactions involving lubricant additives. *Friction* 11, 4, 489-512.
- [16] Liu, Y.-D., Wang, C.-B., Yuan, J.-J. and Liu, J.-J. 2010. Investigation on anti-wear properties of sulfide layer on bearing steel lubricated by oil-containing FeS particles. *Surface and Coatings Technology* 205, 2, 470-474.

- [17] Hatami, M., Hasanpour, M. and Jing, D. 2020. Recent developments of nanoparticles additives to the consumables liquids in internal combustion engines: Part II: Nano-lubricants. *Journal of Molecular Liquids* 319, 114156.
- [18] Ogenesova, E. Y., Lyadov, A. S. and Parenago, O. P. 2018. Nanosized Additives to Lubricating Materials. *Russ J Appl Chem+* 91, 10, 1559-1573.
- [19] Dai, W., Kheireddin, B., Gao, H. and Liang, H. 2016. Roles of nanoparticles in oil lubrication. *Tribol Int* 102, 88-98.
- [20] Shafi, W. K. and Charoo, M. S. 2021. An overall review on the tribological, thermal and rheological properties of nanolubricants. *Tribol-Mater Surf In* 15, 1, 20-54.
- [21] Yu, H., Chen, H., Zheng, Z., Qiao, D., Feng, D., Gong, Z. and Dong, G. 2023. Effect of functional groups on tribological properties of lubricants and mechanism investigation. *Friction* 11, 6, 911-926.
- [22] Kaur, N., Kaur, S., Singh, J. and Rawat, M. 2016. A Review on Zinc Sulphide Nanoparticles : From Synthesis , Properties to Applications. *Journal of Bioelectronics and Nanotechnology* 1, 1, 1-5.
- [23] Wang, H., Xu, B. and Liu, J. 2012. *Micron-nano ZnS Solid Lubrication Film*. Editon Edition, Springer Berlin Heidelberg, Berlin, Heidelberg.
- [24] Zhang, S., Yang, J., Chen, B., Guo, S., Li, J. and Li, C. 2017. One-step hydrothermal synthesis of reduced graphene oxide/zinc sulfide hybrids for enhanced tribological properties of epoxy coatings. *Surface and Coatings Technology* 326, 87-95.
- [25] Zhao, F., Li, G., Zhang, G., Wang, T. and Wang, Q. 2017. Hybrid effect of ZnS sub-micrometer particles and reinforcing fibers on tribological performance of polyimide under oil lubrication conditions. *Wear* 380-381, 86-95.
- [26] Liu, H., Qi, Z., Wang, H., Huang, J., Zhao, Y., Yang, Y. and Zhao, Z. 2024. 'Ball-on-plane' ZnS@RG0 compound filler: effect on tribological properties of thermosetting polyimide film. *Composite Interfaces*, 1-18.
- [27] Liu, W. and Chen, S. 2000. An investigation of the tribological behaviour of surface-modified ZnS nanoparticles in liquid paraffin. *Wear* 238, 2, 120-124.
- [28] Chen, S. and Liu, W. 2001. Characterization and antiwear ability of non-coated ZnS nanoparticles and DDP-coated ZnS nanoparticles. *Mater Res Bull* 36, 1, 137-143.
- [29] Wang, L., Gao, Y., Li, Z., Zhou, A. and Li, P. 2015. Preparation and tribological properties of surface-modified ZnS nanoparticles. *Lubrication Science* 27, 4, 241-250.
- [30] Lu, A., Niu, W., Dai, Y., Xu, H. and Dong, J. 2019. Tribological Properties of ZnS(NH₂CH₂CH₂NH₂)_{0.5} and ZnS as Additives in Lithium Grease. *Lubricants* 7, 3, 26.
- [31] Kumara, C., Armstrong, B., Lyo, I., Lee, H. W. and Qu, J. 2023. Organic-modified ZnS nanoparticles as a high-performance lubricant additive. *Rsc Adv* 13, 10, 7009-7019.
- [32] Uğur, A. and Avan, İ. 2023. Investigation of 1-octanethiol capped ZnS nanoparticles as lubricant additives and tribological behavior of oil-based nanolubricant. *Wear* 530-531, 205029.
- [33] Uğur, A. and Avan, İ. 2024. Anti-wear behavior of 1-octanethiol and tween-80 capped ZnO nanoparticles as lubricating oil additives. *Surfaces and Interfaces* 46, 104018.
- [34] International, A. 2003. Standard Test Method for Measurement of Load-Carrying Capacity of Lubricating Grease (Timken Method), Test no. D-2509-03. International, A., West Conshohocken.
- [35] International, A. 2020. Standard Test Method for Measurement of Extreme-Pressure Properties of Lubricating Fluids (Timken Method), Test No: D2782-20. International, A., West Conshohocken.

- [36] Hu, P., Cao, Y., Lou, Y., Lu, B., Shao, M., Ni, J. and Cao, M. 2013. A New Simple Route to ZnS Quantized Particles with Tunable Size and Shape, and Size/Shape-Dependent Optical Properties. *Advances in Materials Physics and Chemistry* Vol.03No.01, 9.
- [37] Qu, H., Cao, L. X., Su, G., Liu, W., Gao, R. J., Xia, C. H. and Qin, J. J. 2014. Silica-coated ZnS quantum dots as fluorescent probes for the sensitive detection of Pb²⁺ ions. *J Nanopart Res* 16, 12.
- [38] Yan, L., Yue, W., Wang, C., Wei, D. and Xu, B. 2012. Comparing tribological behaviors of sulfur- and phosphorus-free organomolybdenum additive with ZDDP and MoDTC. *Tribol Int* 53, 150-158.
- [39] Viswanath, R., Naik, H. S. B., Somalanaik, Y. K. G., Neelanjeneallu, P. K. P., Harish, K. N. and Prabhakara, M. C. 2014. Studies on Characterization, Optical Absorption, and Photoluminescence of Yttrium Doped ZnS Nanoparticles. *Journal of Nanotechnology* 2014, 1-8.
- [40] Bahena-Martínez, C. J., Torres-Gómez, N. and Vilchis-Néstor, A. R. 2020. Study of the temperature effect on the morphology and structure of ZnS nanoparticles synthesized by hydrothermal method. *MRS Advances* 5, 63, 3379-3388.
- [41] Jrad, A., Naouai, M., Ammar, S. and Turki-Kamoun, N. 2022. Chemical composition, structural, morphological, optical and luminescence properties of chemical bath deposited Fe:ZnS thin films. *Optical Materials* 123, 111851.
- [42] Yu, H.-l., Xu, Y., Shi, P.-j., Xu, B.-s., Wang, X.-l. and Liu, Q. 2008. Tribological properties and lubricating mechanisms of Cu nanoparticles in lubricant. *Transactions of Nonferrous Metals Society of China* 18, 3, 636-641.
- [43] Chen, Y., Yang, K., Lin, H., Zhang, F., Xiong, B., Zhang, H. and Zhang, C. 2022. Important contributions of multidimensional nanoadditives on the tribofilms: From formation mechanism to tribological behaviors. *Composites Part B: Engineering* 234, 109732.
- [44] Li, H., Zhang, Y., Li, C., Zhou, Z., Nie, X., Chen, Y., Cao, H., Liu, B., Zhang, N., Said, Z., Debnath, S., Jamil, M., Ali, H. M. and Sharma, S. 2022. Extreme pressure and antiwear additives for lubricant: academic insights and perspectives. *The International Journal of Advanced Manufacturing Technology* 120, 1, 1-27.
- [45] Chen, H., Chow, C. L. and Lau, D. 2023. Recycling used engine oil in concrete: Fire performance evaluation. *Journal of Building Engineering* 64, 105637.

Experimental Investigations of Pulse Oscillators

Recep Emir^{*1}, Sezai Alper Tekin²

^{*1} Erciyes University, Electrical and Electronics Engineering, Kayseri, TURKEY

² Erciyes University, Industrial Design Engineering, Kayseri, TURKEY

(Alınış / Received: 22.06.2024, Kabul / Accepted: 22.10.2024, Online Yayınlanma / Published Online: 30.12.2024)

Keywords

Pulse Oscillators,
Opamp,
555,
Integrated

Abstract: Experimental investigations of pulse oscillators are presented. Various electronic circuits are operated with pulse signals. The main purpose of this work is to design portable oscillators with alkaline batteries without using electric source. The other purpose is to achieve oscillators with basic and easy to find components. For these purposes, two kind of pulse oscillators are implemented, which are based on opamp and 555 integrateds. Positive and negative alternances of generated pulse signals are adjusted to 5V and 0V, respectively, in accordance with logic 5V standart. Frequency is adjusted to 1Hz to be able to observe alternance transitions. Produced pulse signals are shown simulationally and experimentally. Additionally, both oscillators are evaluated in terms of some properties and advantages.

Kare Dalga Osilatörlerinin Deneysel Olarak Araştırılması

Anahtar Kelimeler

Kare Dalga Osilatörleri,
Opamp,
555,
Entegre

Öz: Kare dalga osilatörlerinin deneysel olarak araştırılması sunulmaktadır. Çeşitli elektronik devreler kare dalga sinyalleriyle çalıştırılır. Bu makalenin temel amacı elektrik kaynağı kullanmadan alkalın pillerle çalışan taşınabilir osilatörler tasarlamaktır. Diğer amaç ise basit ve bulunması kolay elemanlara sahip osilatörler elde etmektir. Bu nedenlerle opamp ve 555 entegrelerine dayanan iki tür kare dalga osilatörü uygulanmaktadır. Üretilen kare dalga sinyallerinin pozitif ve negatif genlikleri, lojik 5V standardına uygun olarak sırasıyla 5V ve 0V olarak ayarlanmıştır. Alternans geçişlerini gözlemleyebilmek için frekans 1Hz'e ayarlanmıştır. Üretilen kare dalga sinyalleri simülasyonlu ve deneysel olarak gösterilmektedir. Ek olarak, her iki osilatör de bazı özellikleri ve avantajları açısından değerlendirilmektedir.

1. Introduction

In recent years, due to big growth in portable electronic devices such as calculators, smart phones, tablets, laptops, the demand for energy efficient and high speed circuits have largely been investigated in very-large-scale-integration (VLSI) systems. Arithmetic and memory units are core parts for most electronic designs and the usage of pulse signals is mostly indispensable [1,2].

Most fundamental logic gates such as NOT-NOR-NAND-XOR-XNOR [3,4] and complex logic circuits such as adders, flip-flops, arithmetic units and some others [5-8] are operated with pulse signals. On the other hand, it is important to use pulse signals in analog designs [9-11]. So the usage of function generators is necessary to control or operate these structures. There are multiple function generator devices generating different AC signals such as sinusoidal, square, triangle and some others in large amplitude and frequency range. However, the function generators have some disadvantages as follows. They are big, need to electric source and cost expensive. For this reason, portable and cheap oscillators operating with alkaline batteries, even if they operate in stable values in terms of amplitude and frequency, provide advantage to control and operate electronic circuits without using electric source and big function generators. Additionally, it is easy to add adjustable property of amplitude and frequency for portable oscillators by using a variable resistor or capacitor.

In this work, experimental investigations of pulse oscillators for electronic circuits are presented. It is important to achieve oscillators with basic and easy to find components. For this purpose, two kind of pulse oscillators are implemented, which are based on opamp and 555 integrateds. Positive and negative alternances of generated pulse signals are adjusted to 5V and 0V, respectively, in accordance with logic 5V standart. Frequency is adjusted to 1Hz to be able to observe alternance transitions. Generated pulse signals are shown simulationally and experimentally. Additionally, these two oscillators are evaluated against each other in terms of some properties and advantages.

2. Material and Method

An AC signal has three components. One of them is the waveform. The other components are amplitude and frequency, which are defined as Voltage and Hertz, respectively. It is important to use basic and easy to find integrateds in designing circuits. For this purpose, two basic integrateds are utilized to design pulse oscillators, which are opamp and 555 integrateds. Both integrateds are core elements in oscillators, they also comprise environmental devices such as diodes, resistors and capacitors. Three components of pulse signals can be defined as in Table 1. The waveform is square. Positive and negative alternances of amplitude are 5V and 0V, respectively, in accordance with logic 5V standart. Frequency is adjusted to 1Hz to be able to observe alternance transitions.

Table 1. Parameters of pulse signal

| | |
|------------------------|--------|
| Waveform | Square |
| Amplitude ⁺ | 5V |
| Amplitude ⁻ | 0V |
| Frequency | 1Hz |

2.1. Pulse oscillator using opamp

Pulse oscillator circuit using opamp [12] is shown in Figure 1. The core element of this oscillator is a basic opamp. It also comprises one capacitor and three resistors.




Figure 1. Pulse oscillator using opamp

In pulse oscillator with opamp, amplitude voltage is determined by power supplies and offset voltages of opamp. If pozitiv or negative alternance of pulse signal is made equal to ground (0) voltage, reverse power supply is made equal to offset voltage and same power supply is made equal to desired amplitude voltage. Typical pozitiv and negative offset voltages of opamp are 2V and -2V, respectively. To acquire 5V pulse signal, which means pozitiv alternance is 5V and negative alternance is 0V, V_{CC} and V_{EE} power supplies are adjusted to 5V and -2V, respectively. Considering a standart alkaline battery is near to and less than 1.5V, it is convenient to use four serial connected alkaline battery for V_{CC} and two serial connected alkaline battery for V_{EE}.

In pulse oscillator with opamp, frequency is defined in equation (1.a),

$$f_{Pulse} = \frac{1}{2 \cdot R_{f-} \cdot C_i \cdot \ln\left(\frac{2 \cdot R_{f+} + R_i}{R_i}\right)} \quad (1.a)$$

To adjust $f_{Pulse} = 1\text{Hz}$, the component values can be typically chosen as follows, $C_1 = 1\mu\text{F}$, $R_i = 1\text{K}\Omega$, $R_f = 470\text{K}\Omega$ and $R_{f+} = 1\text{K}\Omega$. If these values are written as in the equation (1.b),

$$f_{Pulse} = \frac{1}{2.470 \cdot 10^3 \cdot 1 \cdot 10^{-6} \cdot \ln\left(\frac{2 \cdot 10^3 + 1 \cdot 10^3}{1 \cdot 10^3}\right)} \approx 1\text{Hz} \tag{1.b}$$

Before implementation opamp based pulse oscillator, device list is as in Table 2.

Table 2. Device list of opamp based pulse oscillator

| Device | Property | Count |
|-----------|-----------------|-------|
| Opamp | Standart | 1 |
| Capacitor | 1 μF | 1 |
| Resistor | 470K Ω | 1 |
| Resistor | 1K Ω | 2 |
| Battery | 1.5V | 6 |

Experimental design of pulse oscillator with opamp is seen in the Figure 2 in accordance with chosen component values.




Figure 2. Experimental pulse oscillator using opamp

2.2. Pulse oscillator using 555

Pulse oscillator circuit using 555 [12] is shown in Figure 3. The core element of this oscillator is a basic 555. It also comprises one diode, two capacitor and two resistors.




Figure 3. Pulse oscillator using 555

In pulse oscillator with 555, amplitude voltage is determined by power supply. To acquire 5V pulse signal, which means positive alternance is 5V and negative alternance is 0V, it is enough to adjust V_{cc} power supply is 5V.

Considering a standart alkaline battery is near to and less than 1.5V, it is convenient to use four serial connected alkaline battery for V_{cc} .

In pulse oscillator with 555, frequency is defined in equation (2.a),

$$f_{Pulse} = \frac{1.44}{(R_A + R_B) \cdot C_1} \tag{2.a}$$

To adjust $f_{Pulse} = 1\text{Hz}$, the component values can be typically chosen as follows, $C_1 = 10\mu\text{F}$, $C_2 = 10\text{nF}$ and $R_a = R_b = 68\text{K}\Omega$. If these values are written as in the equation (2.b),

$$f_{Pulse} = \frac{1.44}{(68 \cdot 10^3 + 68 \cdot 10^3) \cdot 10 \cdot 10^{-6}} \approx 1\text{Hz} \tag{2.b}$$

Before implementation 555 based pulse oscillator, device list is as in Table 2.

Table 3. Device list of 555 based pulse oscillator

| Device | Property | Count |
|-----------|------------------|-------|
| 555 | Standart | 1 |
| Diode | 1N4007 | 1 |
| Capacitor | 10 μF | 1 |
| Capacitor | 10nF | 1 |
| Resistor | 68K Ω | 2 |
| Battery | 1.5V | 4 |

Experimental design of pulse oscillator with 555 is seen in the Figure 4 in accordance with chosen component values.




Figure 4. Experimental pulse oscillator using 555

3. Results

3.1. Simulational results

Simulational pulse signals of opamp based and 555 based oscillators are indicated in Figure 5 and Figure 6, respectively. Volt/div and time/div values are adjusted to 5V and 0.5s in oscilloscopes, which means pulse signal should take place one division vertically and two divisions horizontally. Both oscillators produce desired and acceptable pulse signals. Considering more details, vertically, while signal of opamp based is a very little weak, signal of 555 based is more near to desired values. On the other hand, horizontally, while signal of opamp based exceeds somewhat, signal of 555 based is more near to desired values.




Figure 5. Simulational pulse signal of opamp based oscillator




Figure 6. Simulational pulse signal of 555 based oscillator

3.2. Experimental results

Experimental pulse signals of opamp based and 555 based oscillators are indicated in Figure 7 and Figure 8, respectively. Volt/div and time/div values are adjusted to 5V and 0.5s in oscilloscopes, which means pulse signal should take place one division vertically and two divisions horizontally, same as in simulational results. Both oscillators produce desired and acceptable pulse signals. Considering more details, vertically, while signal of opamp based is a very little weak, signal of 555 based is more near to desired values. On the other hand, horizontally, while signal of opamp based exceeds somewhat, signal of 555 based is more near to desired values.




Figure 7. Experimental pulse signal of opamp based oscillator




Figure 8. Experimental pulse signal of 555 based oscillator

3.3. Evaluation of oscillators

Both opamp based and 555 based oscillators produce desired and acceptable pulse signals. However, considering more details, produced pulse signals take places a little ahead or behind of necessary values due to real values of alkaline batteries and environmental electronic elements. It is not possible to exactly adjust amplitude and frequency to necessary standart values. On the other hand, it is more possible to exactly adjusting with special produced electronic elements in series production.

Two alternative method is presented to achieve pulse oscillators in this work. Even so, to consider which oscillator should be chosen, both oscillators are compared against each other. In terms of count of alkaline battery, if endurance time is neglected, 555 based oscillator with one power supply and four alkaline batteries is more advantageous than opamp based oscillator with two power supplies and six alkaline batteries. On the other hand, in terms of environmental electronic elements, opamp based with four extra elements is more advantageous than 555 based with five extra elements. Besides, the comparison in terms of cost is possible.

4. Discussion and Conclusion

Two alternative pulse oscillators for electronic circuits are presented, based on opamp and 555 integrateds. Pulse signals are necessary for operating of most analog and logic circuits. Main purpose of this work is to achieve portable oscillators with cheap and easy to find electronic elements. In accordance with logic 5V standart, three components of pulse signals are adjusted. The other important purpose is to eliminate needing electric source by using alkaline batteries. Both oscillators are implemented simulationally and experimentally and both of them produces desired and acceptable pulse signals. Additionally, both oscillators are evaluated in terms of some properties and advantages.

References

- [1] Sedra, A. S., Smith, K. C., Carusone, T. C., Gaudet, V., 2020. *Microelectronic Circuits*. 8th Edition, New York Oxford, Oxford University Press
- [2] Amini-Valashani, M., Ayat, M., Mirzakuchaki, S., 2018. Design and Analysis of a Novel Low Power and Energy-Efficient 18T Hybrid Full Adder. *Microelectronics Journal*, 74(2018), 49-59.
- [3] Mirmotahari, O., Berg, Y., 2014. Ultra Low-Voltage Static Precharge NAND/NOR Gates. *IEEE International Nanoelectronics Conference (INEC)*, 28-31 July, Sapporo, Japan.
- [4] Naseri, H., Timarchi, S., 2018. Low-Power and Fast Full Adder by Exploring New XOR and XNOR Gates. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 26(2018), 1481-1493.
- [5] Rafiee, M., Shiri, N., Sadeghi, A., 2022. High-Performance 1-Bit Full Adder with Excellent Driving Capability for Multistage Structures, *IEEE Embedded Systems Letters*, 14(2022), 47-50.
- [6] Karimi, A., Rezai, A., Hajhashemkhani, M. M., 2019. Ultra-Low Power Pulse-Triggered CNTFET-Based Flip-Flop, *IEEE Transactions on Nanotechnology*, 18(2019), 756-761.
- [7] Ji, H., Geng, D., Chuai, X., Duan, X., Chen, Q., Wu, W., Chen, C., Jiang, W., Jiang, J., Ling, Li L., (2022). An Advanced Full Adder Based Arithmetic Logic Unit (ALU) Using Low-Temperature Poly-Si Oxide TFTs, 69(2022), 6160-6165.
- [8] Gupta, R., Gupta, R., Sharma, S., 2017. Design of high speed and low power 4-bit comparator using FGMOS. *International Journal of Electronics and Communications (AEU)*, 2017(76), 125-131.
- [9] Fowler, B., Gamal, A. E., 1994. Pulse-Modulated Analog Neuron Circuits. *Analog Integrated Circuits and Signal Processing*, 1994(6), 45-51.
- [10] Papathanasiou, K., Brandtner, T., Hamilton, A., 2002. Palmo: Pulse-Based Signal Processing for Programmable Analog VLSI. *IEEE Transactions on Circuits and Systems II-Express Briefs*, 2002(49), 379-389.
- [11] Bizzarri, F., Brambilla, A., Gajani, G. S., 2011. Phase Noise Simulation in Analog Mixed Signal Circuits: An Application to Pulse Energy Oscillators. *IEEE Transactions on Circuits and Systems II-Express Briefs*, 2011(58), 154-158.
- [12] Alçı, M., Kara, S., 2000. *Elektronik Devre Tasarımında OPAMP ve Lineer Tümdetreler*. Erciyes Üniversitesi, Mühendislik Fakültesi, Elektronik Mühendisliği Bölümü, Kayseri.

Manual and Remote-Controlled Secondary Emission Calorimeter Modules for High-Radiation Environments

Nejdet Paran^{1,*} , Saleh Abubakar¹ , Burak Tekgün² , Emrah Tıraş^{1,3,*} 

¹ Department of Physics, Faculty of Science, Erciyes University, Kayseri 38030, Türkiye

² Department of Electrical Electronics Engineering, School of Engineering, Abdullah Gul University, Kayseri, 38080, Türkiye

³ Department of Physics and Astronomy, University of Iowa, IA 52242, USA

(Alınış / Received: 10.10.2024, Kabul / Accepted: 19.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Keywords

Secondary Emission
Ionization Calorimetry,
Cosmic Radiation,
Radiation Detectors,
Particle Detectors, PMTs.

Abstract: There is a growing demand for durable and radiation-resistant particle detectors and ionization calorimeters. This demand arises from the increased luminosity and extreme radiation conditions at particle colliders and accelerators. Secondary Emission (SE) Ionization Calorimetry is an innovative technology developed to quantify the energy of electromagnetic and hadronic particles, especially under high-radiation conditions. This study examines the development and radiation testing of the innovative SE modules. The modules were produced by altering the standard Hamamatsu single anode R7761 Photomultiplier Tubes (PMTs). A SPICE model was constructed based on the parameters of the PMT system. The model's objective is to evaluate various divider circuits. Three distinct voltage conditions for the identical modules were established, and the new modules were evaluated utilizing cosmic background and gamma radiation sources. Results indicate that all three modes exhibit significant cosmic and gamma radiation sensitivity. Mode 1 and Mode 2 exhibit substantial signal sizes compared to Mode 3, which results from cosmic particle interactions. The obtained signal sizes are ~70 mV for Mode 1, ~65 mV for Mode 2, and ~8 mV for Mode 3. This study indicates that the SE module is a promising technology for future radiation-resistant nuclear and high-energy detectors. Since such detector systems are either in a high-radiation area or a closed room/box, remote mode changes allow us to continue the experimental process without interruption. We can instantaneously observe the modes' effects by adding these signals to the interface where the modes are controlled.

Yüksek Radyasyonlu Ortamlar için Manuel ve Uzaktan Kumandalı İkincil Emisyon Kalorimetre Modülleri

Anahtar Kelimeler

İkincil Emisyon
İyonizasyon Kalorimetrisi,
Kozmik Radyasyon,
Radyasyon Dedektörleri,
Parçacık Dedektörleri,
PMT'ler

Öz: Parçacık çarpıştırıcıları ve hızlandırıcılarındaki artan parlaklık ve aşırı radyasyon koşulları nedeniyle, hassas, dayanıklı ve güvenilir, radyasyona dayanıklı parçacık dedektörleri ve iyonizasyon kalorimetrelerine olan talep artmaktadır. İkincil Emisyon (SE) İyonizasyon Kalorimetrisi, özellikle yüksek radyasyon koşulları altında elektromanyetik ve hadronik parçacıkların enerjisini ölçmek için geliştirilmiş yenilikçi bir teknolojidir. Bu çalışma, yeni SE modüllerinin geliştirilmesini ve radyasyon testlerini incelemektedir. Modüller, standart Hamamatsu tek anotlu R7761 Fotoçoğaltıcı Tüpler (PMT'ler) değiştirilerek üretilmiştir. PMT sisteminin parametrelerine dayalı bir SPICE modeli oluşturulmuştur. Modelin amacı çeşitli bölücü devrelerle incelemektir. Aynı modül için üç farklı voltaj koşulu oluşturulmuş ve yeni modüller kozmik arka plan ve gama radyasyon kaynakları kullanılarak ölçümler alınmıştır. Sonuçlar, her üç modun da

önemli ölçüde kozmik ve gama radyasyon hassasiyeti sergilediğini göstermektedir. Mod 1 ve Mod 2, kozmik parçacık etkileşimlerinden kaynaklanan sinyal boyutları açısından Mod 3'e kıyasla önemli bir fark sergilemektedir. Elde edilen sinyal boyutları Mod 1 için ~70 mV, Mod 2 için ~65 mV ve Mod 3 için ~8 mV'dir. Bu çalışma, SE modülünün gelecekteki radyasyona dayanıklı nükleer ve yüksek enerjili dedektörler için potansiyel bir teknoloji olduğunu göstermektedir. Bu tür dedektör sistemleri ya yüksek radyasyonlu bir alanda ya da kapalı bir odada/kutuda olduğundan, uzaktan mod değişiklikleri deneysel süreci kesintiye uğratmadan devam ettirmemizi sağlar. Bu sinyalleri modların kontrol edildiği arayüze ekleyerek modların etkilerini anlık olarak gözlemleyebiliriz.

1. Introduction

Energy measurement using calorimetry is one of the widely used techniques in high-energy and nuclear physics to determine the momentum and energies of particles. The principle behind calorimeters is to use crystal, quartz, or plastic scintillators to convert particle showers created by primary particles into light and then use a photodetector to turn that light into electric signals. Calibration and long-term signal efficiency are critical issues for plastic scintillators and crystalline material calorimeters operating in strong radiation conditions. Quartz-based calorimeters are more radiation-resistant and produce fast, narrow-band signals. However, they have a lower signal output and primarily detect the electromagnetic core of hadronic showers. In contrast, calorimeters made of crystalline materials or plastic scintillators struggle with long-term signal efficiency and calibration in high-radiation environments [1–7].

To overcome these obstacles, active research programs in the field are concentrating on enhancing light yield, radiation resistance, and active materials. In situations with high-radiation levels, a unique method for measuring electromagnetic shower particles is the Secondary Emission Ionization (SE) calorimetry [8–16]. Developing SE calorimeters is one of the main focuses of the research and development groups in the field of High Energy and Accelerator Physics. Apart from the commonly employed techniques for calorimeter performance development and enhancement, we devised a unique method that alters the voltage applied just to the photocathode and first dynode while maintaining the basic structure of photomultiplier tubes (PMTs). This research aims to design and fabricate a remotely controllable baseboard for SE calorimetry and related calorimetric uses and evaluate the newly developed module using gamma and cosmic sources. This study alters and redesigns the conventional PMT bias circuit to deal with numerous anode signal outputs to characterize various operation modes. The design of various operational modes and the characterization measurements of both secondary emission modes and the conventional PMT mode are examined comprehensively. The required sensor front-end and back-end circuits are designed to enable the different operating modes, which allow fault-tolerant operation of SE calorimetry in radiation-harsh environments.

This paper presents a novel design for remote-controllable SE calorimetry. This design permits dynamic voltage adjustments solely for the photocathode and initial dynode while maintaining the fundamental architecture of the PMTs. This pioneering method is unprecedented in the literature, overcoming the constraints of manual voltage regulation and improving operational adaptability. Additionally, we develop a remote-control circuit integrated with computer interface software to facilitate a smooth transition between various working modes, thereby streamlining the operation of intricate detecting systems. The modules underwent testing with cosmic and gamma radiation in Mode 1, the usual operational mode of photomultiplier tubes (PMTs). The signal dimensions of the PMT were measured at voltages marginally below (1800V) and above (2200V) the typical working voltage of 2000V. This flexibility to various working modes guarantees the system's versatility and robustness, instilling confidence in readers regarding its prospective uses.

2. Material and Methods

Manual Control

Photomultipliers are very susceptible vacuum tubes that transform light into a quantitative electric current. PMTs transform the inferior light output of the scintillation signal into an observable electrical pulse; scintillators could widely be used in radiation detection and spectroscopy [17]. In this study, we used the Hamamatsu single anode R7761 PMT, previously used to collect data in the CDF experiment at Fermi National Accelerator Laboratory (Fermilab) [18]. R7761 PMT has 19 dynode stages serving as secondary emissive electrodes in a fine mesh structure, and it has a length of 50 mm and a diameter of 39 mm with an operational window diameter of 27 mm [19].

Operation of the R7761 photomultiplier tube requires a voltage source of at least -1700 V and a voltage divider circuit to appropriately allocate this voltage to the PMT's dynodes. In order to get high efficiency from the PMT, providing the appropriate voltage to the dynodes is mandatory. Since supplying each dynode with a separate voltage source is not economical or feasible, a voltage divider circuit is necessary. Therefore, a voltage divider circuit is usually used to supply the appropriate voltage to each dynode of the PMT and a high-voltage power supply is used to feed this circuit. A stable voltage from the high-voltage source is crucial for the proper operation of the PMT. Due to the high number of PMT dynodes, such as R7761, capacitors are added to these dynodes to prevent the voltage drop between the dynodes near the anode. We added a 22nF decoupling capacitor to the last five dynodes of the voltage divider board we designed. Figure 1 shows the schematic diagram of the SE voltage divider for R7761. The circuit schematic shows the baseboards that power and read data from a single PMT in the SE module.

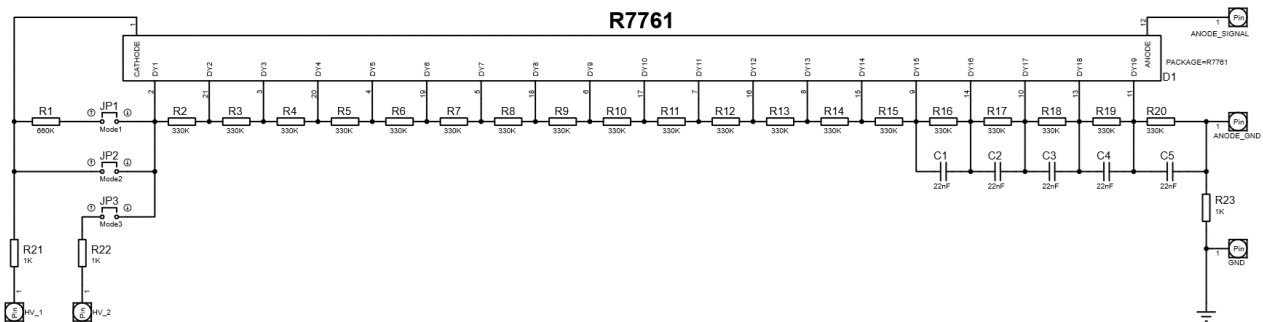


Figure 1. Schematic diagram of the secondary emission voltage divider for R7761 PMTs.

There are three different modes of operation for the baseboards of R7761 single-anode PMTs. High voltage was applied to Mode 1 and Mode 2 via HV1 and to Mode 3 via HV2. An oscilloscope was used for data collection.

Mode 1: JP1 switch is closed. As shown in Figure 2a, the voltage divider chain is unchanged, and the potential difference across the dynodes is equal, except for the two times potential across the Cathode-Dy1 gap. This mode is also the normal operating mode of the Hamamatsu R7761 PMT.

Mode 2: In this mode, the JP2 switch is closed. As shown in Figure 2b, the bridging of the R1 resistor is enabled, and the potential across the Cathode-Dy1 gap is 0 volt.

Mode 3: By closing the JP3 switch, the cathode is isolated from the rest of the divider chain. As shown in Figure 2c, a second voltage input to the baseboard allows for the voltage on Dy1. In this mode, the photocathode may still charge if there is no second high-voltage source.

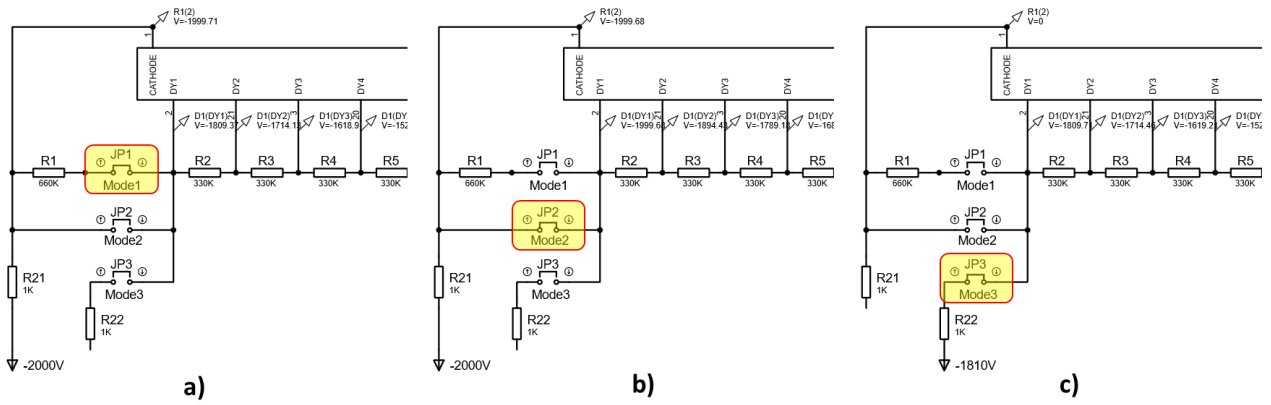


Figure 2. a) Schematic diagram of the secondary emission voltage divider for R7761 PMTs for Mode 1. b) Schematic diagram of the secondary emission voltage divider for R7761 PMTs for Mode 2. c) Schematic diagram of the secondary emission voltage divider for R7761 PMTs for Mode 3

A PCB layout of the manually controlled R7761 PMT is shown in Figures 3a and 3b. Figure 3c shows the printed circuit board with all the soldering and assembly processes done. Two high-voltage inputs were provided with SHV connectors, while BNC connectors were used for the signal. As can be seen in Figure 3c, the photomultiplier detector was wrapped with a light-impermeable foil and then taped with insulating tape to protect it from light.

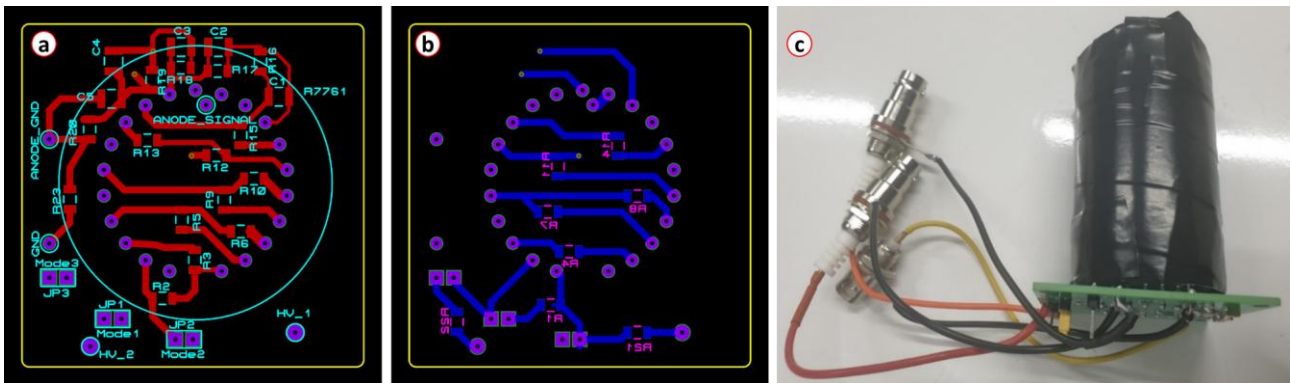


Figure 3. a) PCB layout view of the top side and b) bottom side c) Image of the electronic board with all soldering and assembly processes completed for the manually controlled R7761 type PMT.

Since photomultiplier tubes have a very high sensitivity, they must be protected from light sources other than the radiation to be measured. Otherwise, high noise is generated, and signal acquisition becomes impossible. Using a sheath to protect it from magnetic fields prevents noise in the PMT.

Remote Control

Complex calorimetric systems need to be automatically controlled and managed remotely to be able to run well in high-radiation environments. In addition to increasing operational flexibility, remotely adjustable solutions lessen the need for manual intervention in difficult situations. To meet these demands, we created a remote-control module that enables smooth changes to the PMT operating modes via a computer interface.

Figure 4 shows the schematic diagram of the SE voltage divider circuit for the remote-controlled R7761 photomultiplier tube. This circuit schematic shows the baseboards that power and read data from a single photomultiplier tube. Understanding the high-voltage application points in the voltage divider circuit that drives the PMT is crucial. The only change for the different modes is the points at which the high voltage is applied to the circuit. So, three different high-voltage application points exist for the three modes. In the first mode, the high voltage is applied to the photocathode through a 1kohm resistor and to the first dynode through a 660kohm resistor. In the second mode, the high voltage is applied directly to the photocathode and the first dynode through a 1kohm resistor. Finally, in the third mode, the photocathode was utterly disabled, and the high voltage was applied directly to the first dynode through a 1kohm resistor. In all three modes, the applied voltage value gradually decreases after the first dynode point in the voltage divider circuit since the resistances are equal until it is divided equally and reaches 0V at the anode.




Figure 4. Schematic diagram of the SE voltage divider circuit for the remote-controlled R7761 photomultiplier tube.

The selection of relays for the high-voltage control circuit was not arbitrary. We meticulously chose them to ensure the circuit's performance. Relays were chosen for their affordability, accessibility, ease of control, and reliability as electronic circuit elements. Since the DC coil that switches these relays on and off operates with a nominal voltage of 24V, these relays cannot be directly controlled with the Arduino, which can output 5V. One solution to this problem is to use suitable transistors between the Arduino and the relays. The schematic connections of the relays and transistors are given in Figure 4. The suitable transistor was chosen based on our relay's nominal voltage and coil resistance. This means we must supply the external electronic circuit board with 24VDC to operate the relays. The 24V entering the DC coil of the relay will be connected to the collector of the transistor at the other end of the coil and reach the ground via the emitter. Therefore, the Collector-Emitter Voltage of the transistor must be more than 24V, and the Collector Current (continuous) must be more than 22.5 mA. For the 2N3904 npn transistor we use, the Collector-Emitter Voltage value is 40V, and the Collector Current (continuous) value is 200mA, so it easily meets the desired values.

As mentioned above, since it is impossible to drive a relay with a 24V operating voltage directly with Arduino, it is necessary to put a suitable transistor in between. Depending on the value of the current in the Base leg of the transistor, the amount of current in the Collector leg changes. One factor that determines the value of the current in the Base leg is the value of the resistor connected to the Base leg. In our thorough simulation studies, we can obtain the desired values when we connect a 1k ohm resistor to the Base leg. This emphasis on thorough simulation studies reassures the reader about the circuit's functionality.

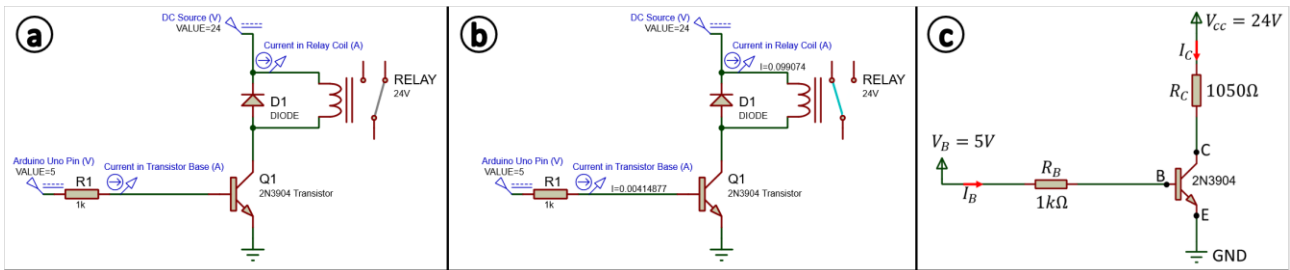


Figure 5. Relay and transistor simulation results are a) when switching OFF, b) when switching ON, and c) equivalent circuits are drawn to solve the current values I_C and I_B in the relay and transistor circuit diagram using an analytical method.

To compare the simulation result with the analytical solution, let us analyze the circuit using the schematic in Figure 5c. From V_{CC} through C and E to GND, the equation becomes:

$$V_{CC} - I_C \times R_C = 0.$$

If we substitute their values:

$$24V - I_C \times 1k\Omega = 0$$

is found. If we subtract I_C from here, $I_C = 24mA$ is found. This value is close to the 22.8 mA value obtained as a result of simulation.

For the current starting at 5V and ending at GND via B and E, the equation becomes:

$$5V - I_B \times R_B - V_{BE} = 0.$$

If the values are substituted,

$$5V - I_B \times 1k\Omega - 0.7V = 0$$

is found. If we subtract I_B from this equation, then $I_B = 4.3mA$ is found. It is seen that this value is close to the $4.2mA$ value obtained as a result of simulation.

A potential problem in this design was also addressed: When the voltage applied to the relay is switched off, the field induced on the DC winding may cause reverse currents and cause the transistors to fail after a while. This problem was solved by connecting a diode in parallel to the two legs of the DC winding. The diode allows the current to flow in only one direction, preventing the reverse currents that could damage the transistors.

The on/off combinations of transistors by mode, as presented in Table 1, were not randomly chosen. This strategic design, which was based on the operational requirements of each mode, can be created in different ways. Our electronic board design was created according to the combination in Table 1. According to this design, all transistors must be in the LOW (deactivated—not energized) position for the first mode to be active. This choice was a preferential choice. Because the first mode is the basic mode, it eliminates the need to control the electronic board to operate in this mode actively. The second and third modes require active control of the circuit. For the second mode to be active, the first and third transistors must be LOW, and the second transistor must be HIGH (activated-energized). Finally, the first and third transistors must be high for the third mode to be active. In this mode, whether the second transistor is LOW or HIGH does not change the circuit.

Table 1. Transistors combination for modes.

| | MODE 1 | MODE 2 | MODE 3 |
|---------------------|--------|--------|----------|
| TRANSISTOR 1 | LOW | LOW | HIGH |
| TRANSISTOR 2 | LOW | HIGH | LOW/HIGH |
| TRANSISTOR 3 | LOW | LOW | HIGH |

A PCB layout of the remote-controlled R7761 photomultiplier tube is shown in Figures 6a and 6b. Figure 6c shows the printed circuit board with all the soldering and assembly processes done. A high-voltage input is provided with SHV connectors, while a BNC connector is used for the signal. As can be seen in Figure 6c, the photomultiplier detector was wrapped with a light-impermeable foil and then taped with insulating tape to protect it from light.




Figure 6. a) PCB layout view of the top side and b) bottom side c) Image of the electronic board with all soldering and assembly processes completed for the remote-controlled R7761 type PMT

The Arduino Uno board, a microcontroller that can be programmed to turn on and off the relays used to operate different modes on the remote-controlled card, was a key component of our system. The Arduino Uno board acts as the control

unit, executing the programmed instructions to switch the relays on and off. Arduino, coded in C++, was connected to the computer via serial communication. The graphical user interface (GUI) program for controlling the modes was written in C#. The screenshot of the main page and the modes are given in Figure 7.

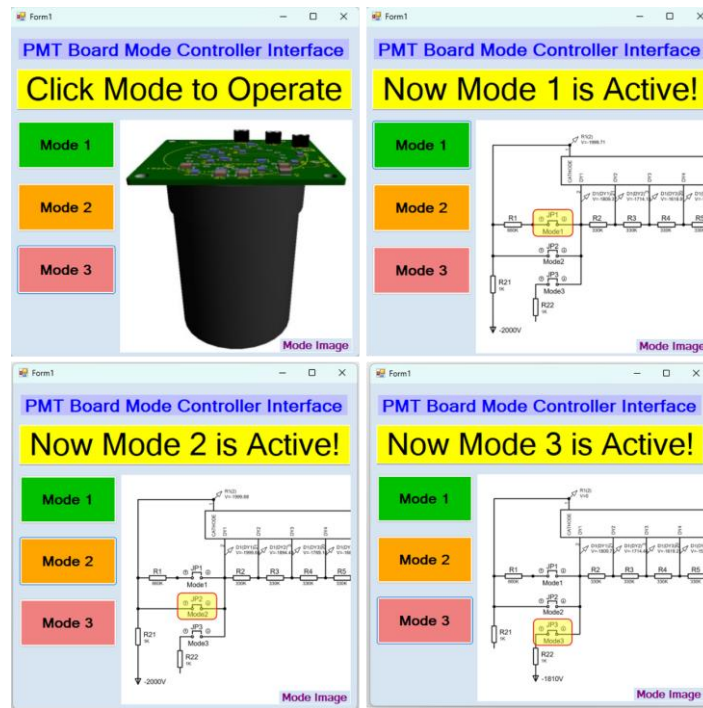


Figure 7. The screenshots of main (left top) and modes windows of the remote-controlled board's GUI.

3. Result and Discussion

Cosmic background radiation and a Co-60 (3.7 MBq) gamma radiation source were used in the same experiment to test all three SE module modes. We conducted the experiments at room temperature in a dark box in the lab and collected the experimental data using the same apparatus. Figure 8 displays the normalized waveform results for the gamma and cosmic radiation testing.

Modes 1 and 2 showed substantially larger signal sizes than Mode 3 for cosmic radiation. The signal amplitudes were about 70 mV for Mode 1, 65 mV for Mode 2, and 8 mV for Mode 3. Since there is no photocathode in the voltage-divider chain, there is a lot less space for cosmic radiation to interact. This makes the signal size 88% smaller in Mode 3 than it was in Mode 1. This proves that even at high voltages, Mode 3 is ineffective for detecting cosmic radiation.

As expected, Mode 2 exhibited a wider signal breadth than Mode 1 due to after-pulse contributions. Cosmological interactions with the photocathode material lead to the shorting of both the photocathode and the first dynode. Mode 3 showed a significantly smaller signal than Modes 1 and 2, which yielded similar signal sizes for gamma radiation. This suggests a clear variation in performance between the modes, highlighting the necessity of additional research to completely comprehend their applicability for various radiation detection circumstances.

We tested Mode 1 at three different voltage levels: 1800V, 2000V, and 2200V, to investigate performance variances. As anticipated, the signal size grew with higher applied voltages, as seen in Figure 9a (cosmic background) and Figure 9b (gamma radiation). Table 2 compiles these findings, demonstrating the SE module's versatility across a range of operating voltages and its capacity to detect gamma and cosmic radiation.

All things considered, the mode-specific traits and performance patterns highlight the SE module's potential as a technology for upcoming high-energy and radiation-resistant nuclear detectors.




Figure 8. The normalized waveform results of all three modes for the cosmic and gamma radiation results.

The signal size received from the PMT varies according to the value of the applied voltage. The signal size increases within a specific operating voltage range as the applied voltage increases. Figure 9a shows the signal size of the cosmic background for 1800V, 2000V, and 2200V, while Figure 9b shows the signal size of Co-60 gamma radiation. These signal size variations are given in Table 2. The signal size of the PMT mode is increasing with the increasing voltage for both cosmic and gamma radiation, as expected. This study indicates that the SE module is a promising technology for future radiation-resistant nuclear and high-energy detectors.

Table 2. Approximate signal sizes (mV) of cosmic background and Co-60 gamma radiation for 1800V, 2000V, and 2200V voltages applied to the PMT.

| | 1800V | 2000V | 2200V |
|--------------------------|--------------|--------------|--------------|
| Cosmic Background | 44.0 | 46.0 | 61.7 |
| Co-60 Gamma | 35.9 | 49.4 | 78.8 |

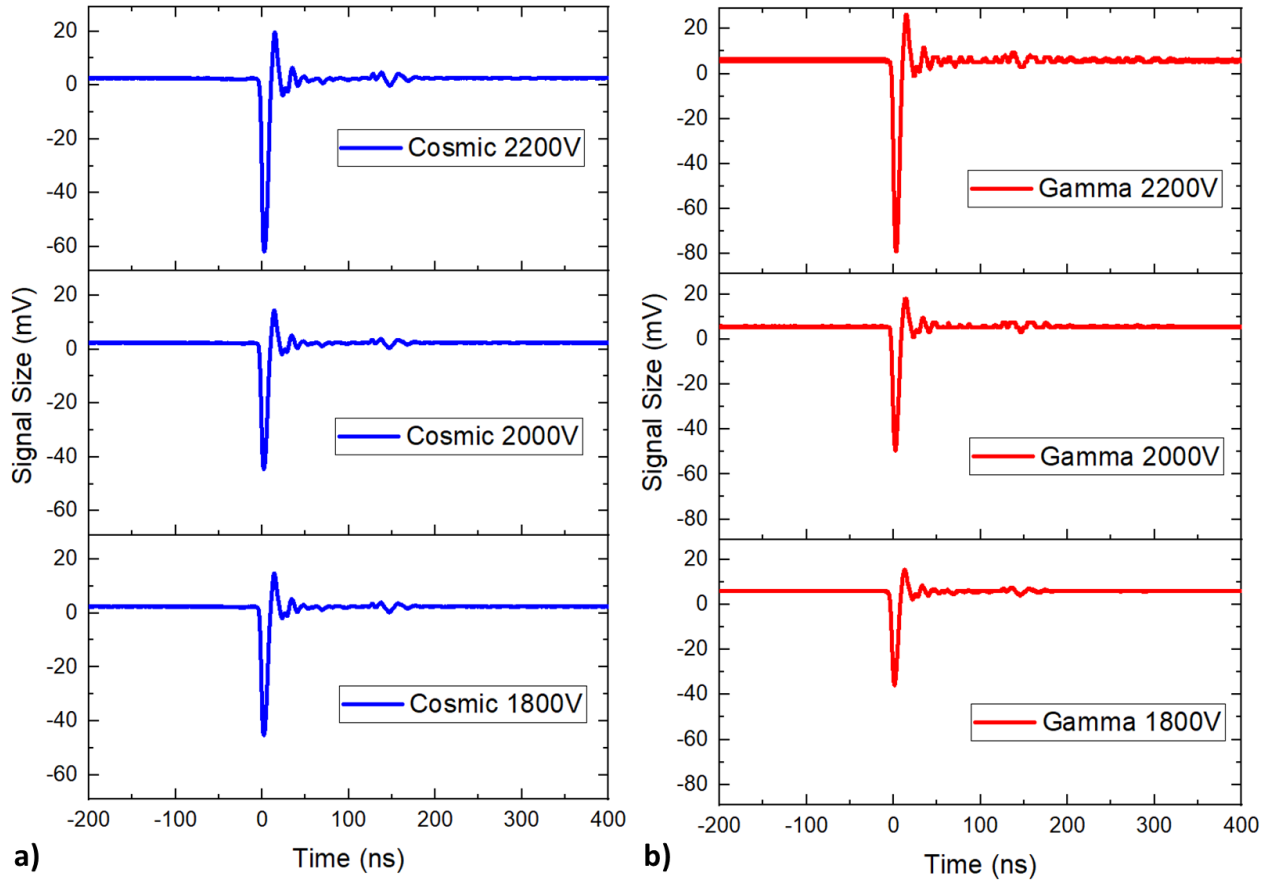


Figure 9. a) Pulse shapes of cosmic background radiation for 1800V, 2000V, and 2200V voltages applied to the PMT; **b)** Pulse shapes of Co-60 gamma radiation for 1800V, 2000V, and 2200V voltages applied to the PMT.

4. Conclusion

This study discusses the Hamamatsu R7761 PMT particle detector operating in three modes. We first provide information about the studies to solve the problems of particle detectors operating in high-radiation environments. Then, we explain one of these solutions, the SE Ionization Calorimeter. After explaining the SE calorimetry technique, we detail the design and fabrication of the electronic board for the operation of the R7761 photomultiplier detector. The results obtained by simulation highlight the differences between the design of manual and remote-controlled electronic boards. The electronic modules designed and produced for the study were then tested, and the results of the R7761 photomultiplier tube tests were obtained. We then describe the thorough preparation for the radiation testing process, which was essential to ensure the accuracy and reliability of our results. Finally, we present and explain the data obtained from our characterization tests with cosmic background and gamma radiation. All three SE module modes were tested with cosmic background radiation and a Co-60 gamma radiation source. Modes 1 and 2 exhibited substantially higher signal responses compared to Mode 3 in the detection of cosmic particles and gamma radiation. Mode 1 was further tested under three different voltages, revealing an increase in the signal size of the PMT mode with the increasing voltage for both cosmic and gamma radiation, as expected. This adaptability to different operating modes ensures the system's versatility and robustness, reassuring readers about its potential applications.

Acknowledgment

This work was supported by Scientific Research Projects (BAP) of Erciyes University, Türkiye, under the grant contracts of FBA-2022-12207, FBG-2022-11499, and FDS-2021-11525. Dr. Emrah Tiras is thankful for the support by the Turkish Academy of Sciences (TUBA) under the grant of the Outstanding Young Scientists Awards Program (GEBIP). We would like to thank the Office of the Dean for Research for providing the Lab's infrastructure at the ARGEPARK building at Erciyes University.

References

- [1] V. Khachatryan, et. al., Dose rate effects in the radiation damage of the plastic scintillators of the CMS hadron endcap calorimeter, *Journal of Instrumentation* 11 (2016) T10004. <https://doi.org/10.1088/1748-0221/11/10/T10004>.
- [2] U. Akgun, G. Funk, J. Corso, Z. Jia, D. Southwick, L. Adams, J. Kingyon, E. Tiras, T. Munhollon, E. Troendle, P. Bruecken, V. Khristenko, Y. Onel, Characterization of 1800 Hamamatsu R7600-M4 PMTs for CMS HF Calorimeter upgrade, *Journal of Instrumentation* 9 (2014) T06005.
- [3] S. Liao, R. Erasmus, H. Jivan, C. Pelwan, G. Peters, E. Sideras-Haddad, A comparative study of the radiation hardness of plastic scintillators for the upgrade of the Tile Calorimeter of the ATLAS detector, *J Phys Conf Ser* 645 (2015) 012021. <https://doi.org/10.1088/1742-6596/645/1/012021>.
- [4] A.M. Sirunyan, et. al, Measurements with silicon photomultipliers of dose-rate effects in the radiation damage of plastic scintillator tiles in the CMS hadron endcap calorimeter, *JINST* 15 (2020). <https://doi.org/10.1088/1748-0221/15/06/p06009>.
- [5] J. Wetzel, E. Tiras, B. Bilki, Y. Onel, D. Winn, Using LEDs to stimulate the recovery of radiation damage to plastic scintillators, *Nucl Instrum Methods Phys Res B* 395 (2017) 13–16.
- [6] J. Oliveira, V. Correia, E. Sowade, I. Etxebarria, R.D. Rodriguez, K.Y. Mitra, R.R. Baumann, S. Lanceros-Mendez, Indirect X-ray Detectors Based on Inkjet-Printed Photodetectors with a Screen-Printed Scintillator Layer, *ACS Appl Mater Interfaces* 10 (2018) 12904–12912. https://doi.org/10.1021/ACSAMI.8B00828/ASSET/IMAGES/LARGE/AM-2018-00828Q_0007.JPEG.
- [7] W. Frass, R. Walczak, C4: Particle Physics Major Option Particle Detectors, (n.d.).
- [8] P.W. Nicholson, *Nuclear electronics*, (1974).
- [9] D.R. Winn, Y. Onel, Secondary Emission Calorimeter Sensor Development, *J Phys Conf Ser* 404 (2012) 012021.
- [10] B. Bilki, K. Dilsiz, H. Ogul, Y. Onel, D. Southwick, E. Tiras, J. Wetzel, D.R. Winn, Secondary Emission Calorimetry, *Instruments* 6 (2022) 48. <https://doi.org/10.3390/INSTRUMENTS6040048>.
- [11] R.G. Lye, A.J. Dekker, Theory of Secondary Emission, *Physical Review* 107 (1957) 977.
- [12] B. Bilki, Secondary emission calorimetry R and D, 2014 IEEE Nuclear Science Symposium and Medical Imaging Conference, NSS/MIC 2014 (2016). <https://doi.org/10.1109/NSSMIC.2014.7431155>.
- [13] A. Albayrak-Yetkin, B. Bilki, J. Corso, P. Debbins, G. Jennings, V. Khristenko, A. Mestvirisvilli, Y. Onel, I. Schmidt, C. Sanzeni, D. Southwick, D.R. Winn, T. Yetkin, Secondary Emission Calorimetry: Fast and Radiation-Hard, (2013).
- [14] F. Ozok, T. Yetkin, E.A. Yetkin, E. Iren, M.N. Erduran, Geant4 simulation of a conceptual calorimeter based on secondary electron emission, *Journal of Instrumentation* 12 (2017) P07014. <https://doi.org/10.1088/1748-0221/12/07/P07014>.
- [15] E. Tiras, Beam test results of Secondary Emission Ionization Calorimetry modules at Fermilab, *Nucl Instrum Methods Phys Res A* 1049 (2023) 168083. <https://doi.org/10.1016/J.NIMA.2023.168083>.
- [16] E. Tiras, K. Dilsiz, H. Ogul, D. Southwick, B. Bilki, J. Wetzel, J. Nachtman, Y. Onel, D. Winn, Characterization of photomultiplier tubes in a novel operation mode for Secondary Emission Ionization Calorimetry, *Journal of Instrumentation* 11 (2016).
- [17] G.A. Morton, *Nuclear Radiation Detectors*, Proceedings of the IRE 50 (1962).
- [18] A. Artikov, J. Boudagov, D. Chokheli, G. Drake, M. Gallinaro, M. Giunta, J. Grudzinski, J. Huston, M. Iori, D. Kim, M. Kim, N. Kimura, S. Kuhlmann, S. Lami, R. Miller, K. Nakamura, L. Nodulman, A. Penzo, K. Sato, J. Suh, N. Turini, F. Ukegawa, Y. Yamada, CDF Central Preshower and Crack Detector Upgrade, (2007). <https://arxiv.org/abs/0706.3922v1> (accessed April 4, 2024).
- [19] H. Photonics, *Photomultiplier Tubes: Basics and Application*, 2006.

Farklı Tanecik Boyutu ve Ağırlık Fraksiyonlarında Karbon Nanotüp Kullanılarak Üretilen Radar Soğurucu Kompozit Malzemelerin İncelenmesi

Berkant Şentürk*¹, Gül Yılmaz Atay¹

*¹ İzmir Katip Çelebi Üniversitesi, Metalurji ve Malzeme Mühendisliği Bölümü Çiğli, İzmir, TÜRKİYE

(Alınış / Received: 06.12.2023, Kabul / Accepted: 13.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Anahtar Kelimeler

Karbon Nanotüpler,
Radar Soğurma,
Savunma Teknolojileri

Öz: Karbon nanotüplerin, görünmezlik teknolojisinde radar soğurucu malzemeler (RAM) alanında kullanımı bilinmekle birlikte, az sayıda çalışmada hem parçacık boyutunun hem de ağırlık fraksiyonunun etkileri incelenmiştir. Bu çalışmada, karbon nanotüplerle güçlendirilmiş polimerik bir kompozit yapı kullanarak elektromanyetik dalgaların yansımalarını en aza indiren, düşük ağırlık/kalınlık ve uygun maliyetli gibi benzersiz özelliklere sahip radar soğurucu malzeme üretimi incelenmiştir. Bu amaçla takviye malzemesi olarak <8 nm, 8-18 nm ve 48-78 nm gibi farklı tanecik boyutlarına sahip karbon nanotüpler %1, %2 ve %3'lük farklı ağırlıklarda polyster ile karıştırılmıştır. Üretilen kompozitler 8 ile 12 GHz frekans aralığında Network Analizer kullanılarak karakterize edilmiştir. Elde edilen sonuçlara göre tanecik boyutunun artmasıyla radar soğuruculuk özelliğinin arttığı görülmüştür. Kompozitlerde karbon nanotüplerin parçacık boyutlarının ve yükleme miktarının değiştirilmesiyle, soğurma performansının farklı frekans bantlarındaki uygulamalara uyacak şekilde ayarlanabileceği tespit edilmiştir.

Investigation of Radar Absorbing Composite Materials Using Carbon Nanotubes in Different Particle Sizes and Weight Fractions

Keywords

Carbon Nanotubes,
Radar Absorption,
Defense Technologies

Abstract: Although the use of carbon nanotubes in the field of radar absorbing materials (RAM) in stealth technology is known, few studies have examined the effects of both particle size and weight fraction. In this study, the production of radar absorber material with unique properties such as low weight/thickness and cost-effectiveness, which minimizes the reflection of electromagnetic waves using a polymeric composite structure reinforced with carbon nanotubes, was examined. For this purpose, carbon nanotubes with different particle sizes of <8 nm, 8-18 nm and 48-78 nm were mixed with polyester at different weight fractions of 1%, 2% and 3% as reinforcement material. The produced composites were characterized using a Network analyzer in the frequency range of 8 to 12 GHz. According to the results obtained, it was observed that radar absorption increased with increasing particle size. It has been determined that by changing the particle sizes and loading amounts of carbon nanotubes in composites, the absorption bands can be adjusted to suit different applications in different frequency bands.

1. Giriş

1930'larda, radar teknolojisinin ortaya çıkmasından kısa bir süre sonra Radar soğurucu malzemelerin (RAM) kullanılmaya başlandığı görülmektedir. Bu tür malzemelere yönelik ilk patent ise 1936'da Hollanda'da alınmıştır. Radar soğurucu malzemelerin geliştirilmesinde yaygın bir yaklaşım, farklı soğurma mekanizmalarına sahip maddelerin birleştirilmesiyle kompozit malzemeler oluşturmak olmuştur. Bu strateji, farklı bant genişliklerinde emilim özelliklerini optimize etmeyi amaçlamaktadır. Dalga sinyallerini zayıflatmak için kullanılan malzemeler arasında karbon yüklü grafit, demir oksit, çelik yünü, toz demir, toz alüminyum, bakır gibi çeşitli maddeler bulunur.

İlk RAM malzemelere bakıldığında düşük elektrik direnci özellikleri nedeniyle karbon siyahı kullanıldığı görülmektedir [1-3].

Radarın çalışma mekanizmasına bakıldığında oldukça basit olduğu görülebilir. Mekanizmanın temel işlevi elektromanyetik dalgaların iletimi ve alımıdır. Tüm dalgalar gibi elektromanyetik dalgalar (radyo dalgaları ve mikrodalgalar) enerji taşır. Ses dalgaları ve okyanus dalgaları enerjiyi taşımak için maddeye ihtiyaç duyarken elektromanyetik dalgalar bunu madde olmadan da yapabilir. Bu nedenle uydular, Dünya atmosferinin dışındaki ve diğer gezegenlerdeki projelerde çalışmak için elektromanyetik dalgaları kullanabilirler. Elektromanyetik dalgalar hakkında bir diğer yararlı şey de, "c" harfiyle kısaltılan ışık hızı (saniyede 292.792.458 metre) adı verilen sabit bir hızda hareket etmeleridir. Mesafe hesaplamaları yaparken bu değer kullanılır. Radyo dalgalarının dalga boyları 10 cm üzerindeyken, mikrodalgaların dalga boyları 10 cm ile 1/10 mm arasındadır [4-5].

Radyo dalgaları bir nesneye çarptığında, bir kısmı yansır ve bir kısmı radar setine geri döner. Bu nesnelere hakkındaki konum ve diğer bilgiler, yansıyan enerjiden elde edilen verilerle hesaplanır. Bunlar yansıyan enerjinin alınması için geçen süre, geri dönen sinyalin gücü veya sinyalin frekansındaki değişim gibi verilerdir. Yansıma ve kırılma miktarı, yüzeyin özelliklerine ve dalganın başlangıçta içinden geçtiği maddenin özelliklerine bağlıdır. Bir radar sinyali tamamen düz bir yüzeye çarparsa, sinyal tek bir yönde yansır. Sinyal tamamen düz olmayan bir yüzeye çarparsa, tüm yönlerde yansır, orijinal sinyalin yalnızca çok küçük bir kısmı alıcı yönünde geri iletilir. Sinyal onu soğuran bir yüzeye çarptığında ise aynı şekilde ya hiç yansımaz, yada belli bir kısmı iletilir. Bu mekanizmaya sahip radar soğurucu malzemeler, uçak, gemi ve tank gibi büyük yapılardan gelen elektromanyetik yansımaları önlemek veya en aza indirmek için yaygın olarak kullanılmaktadır. Bu malzemeler, ayrı veya geniş bant frekanslarında radar enerjisinin emilmesine izin vermek için elektriksel ve/veya manyetik özellikleri değiştirilmiş kaplamadan geliştirilmiştir. Belirli bir radar frekansındaki soğurma seviyesi kaplamanın bileşimine bağlı olarak değişir [4-5].

İkinci Dünya Savaşı sırasında Almanya, denizaltıları radarlardan gizlemek için yaklaşık 0,3 inç kalınlığında karbonil demir tozu içeren, 3 GHz rezonans frekansına sahip "Wesch" malzemesini geliştirdi. Aynı dönemde ABD, MIT Radyasyon Laboratuvarı'nda Halpern'in öncülüğünde "HARP" olarak bilinen malzemeleri geliştirdi. X bandı rezonansı için söz konusu radar soğurucu malzemenin kalınlığı 0,025 inç idi. Malzeme, düşük direnç özelliklerinin sağlanması amacıyla yönlendirilmiş alüminyum pulların karbon siyahı ile birlikte dağıtıldığı bir kauçuk matristen formüle edilmişti [1-4].

Her ne kadar savaş sonrası dönemde radar soğurucu malzemelerde farklı malzemelerin kullanılmaya başlandığı görülse de asıl gelişim Nanoteknolojinin ve dolayısıyla Nanomalzemelerin devreye girmesiyle gerçekleşti. Bunlardan en çok dikkat çeken buluşlarından birisi 1991'de bulunan karbon nanotüplerdir (KNT). Bu tarihten itibaren karbon nanotüpler, üzerinde en çok çalışma yapılan materyallerden biri haline gelmiştir. Karbon nanotüp, grafen olarak adlandırılan iki boyutlu (2D) örülü karbon yapının silindirik şeklinde sarılmış halidir. Grafenin tek katlı olarak sarılmasıyla elde edilen karbon nanotüp yapısı tek duvarlı karbon nanotüp olarak adlandırılmaktadır. Bunun yanında, birden fazla sarım yapılarak elde edilen çift katlı ve çok duvarlı karbon nanotüpler de yaygın olarak görülmekte ve kullanılmaktadır [4,5].

Bu çalışmada, karbon nanotüpler kullanılarak elektromanyetik sinyalleri etkin bir şekilde soğuran kompozit malzemelerin geliştirilmesi hedeflenmiştir. Buna bağlı olarak takviye malzemesi olarak <8 nm, 8-18 nm ve 48-78 nm farklı tanecik boyutlarına sahip karbon nanotüpler %1, %2 ve %3'lük farklı ağırlıkta polyester ile karıştırıldı. Elde edilen kompozitler 8 ile 12 GHz frekans aralığında Network analizler kullanılarak karakterize edildi.

2. Materyal ve Metot

2.1. Malzemeler

Karbon nanotüpler (KNT'ler), Türkiye'de yer alan Nanografi firmasından temin edilmiştir. Bilindiği üzere KNT'ler saf haliyle metalik yapı sergiler ve hidrofobik özellik gösterirler. Ancak hücre ve hayvan deneylerinde kullanılabilirlik, sıvıda çözünürlük ve biyo-uyumluluk gibi özellikler kazandırmak amacıyla karbon nanotüpler işlevlendirme işlemlerine tabi tutulmaktadır. Bu işlemler KNT'lerin -COOH, -OH ve -NH₂ gibi fonksiyonel gruplarla işlenmesini içerir. Ayrıca, karbon nanotüplerin üretim yöntemlerinden kaynaklı olarak içlerinde amorf karbon ve metal bulunabilir, bu da saflıklarının değişken olmasına neden olur. Bu çalışmada kullanılan KNT'ler, yeni özellikler eklenmeden, %96 saflıkta ve üç farklı tanecik boyutuna sahip olarak temin edilmiştir; <8 nm, 8-18 nm ve 48-78 nm. Matris malzemesi olarak Verpoi marka döküm tipi polyester reçine tercih edilmiştir. Bu reçine,

sertleştirici malzeme ile %3 oranında karıştırıldığında 1-2 gün içerisinde oda sıcaklığında sertleşme göstermektedir.

2.2. Çok Duvarlı Karbon Nanotüp Takviyeli Kompozit Malzemelerin Üretimi

Çalışma kapsamında kullanılan KNT'ler, yukarıda belirtilen boyutlarda saflıklarını koruyarak temin edilmiştir. Takviye malzemesi olarak kullanılan KNT'ler, her boyutta farklı yükleme seviyelerinde (%1, %2 ve %3) matris malzemesi olan polyester reçine ile önce manuel olarak, ardından 15 dakika boyunca mekanik olarak karıştırılmıştır. Karıştırma işlemi sonrasında homojen bir yapı elde edilmiştir. Akabinde karışıma matris malzemesi olarak reçine sertleştirici ile %3 oranında karıştırılmıştır. Elde edilen karışım Network Analiz cihazına uygun olarak üretilmiş olan 1,5 mm kalınlığa sahip Alüminyum holder içerisine dökülmüştür. Bu şekilde malzemenin 2 gün oda sıcaklığında sertleşmeye bırakılması suretiyle 1,5 mm kalınlığına sahip tek katmanlı kompozit numuneler üretilmiştir.

2.3. Kompozit Numunelerin Karakterizasyonu


Tozların faz analizi, 20–90° aralığında ($\lambda = 1:540 \text{ \AA}$) Panalytical Empryean X-ışını difraktometresi kullanılarak gerçekleştirilmiştir. Kompozitlerin morfolojik görüntülerini elde etmek için Carl Zeiss Sigma 300 VP taramalı elektron mikroskobu (SEM) kullanılmıştır. Radar soğurma özelliklerinin belirlenmesi 8-12 GHz frekans aralığında iletim/yansıma yöntemi kullanılarak yapılmıştır. Bu amaçla koaksiyel hat kurulumuna sahip HP8720D Network Analizörü kullanılmıştır.

3. Bulgular

Karbon nanotüplerin faz analizi için yapılan XRD analizi sonuçları Şekil 1'de gösterilmektedir. Elde edilen XRD verileri Williams-Hall yöntemi (Eq.1) kullanılarak tanecik boyutu hesaplanmıştır.


$$\Delta 2\theta \cos \theta / \lambda = 0,9/D + 2\varepsilon \sin \theta / \lambda \dots\dots\dots (\text{Eq.1})$$

Denklemden, λ X-ışını dalga boyunu ifade eder (1.54056 Å), D numunenin kristal boyutunu (nm), ε kafes gerinimini, θ kırınım açısını ve $\Delta 2\theta$ pik yarı yüksekliğinde tam genişliği (FWHM) olarak ifade eder. Bu denklem kullanılarak yapılan hesaplamalar sonucunda, XRD analizi ile elde edilen verilere dayanarak numunenin yaklaşık 14.2 nm olarak kristal boyutu hesaplanmıştır.



Şekil 1. %96 Saflıkta, 8-18nm tanecik boyutuna sahip ÇDKNT'ün XRD deseni

Malzemenin morfolojik olarak incelenebilmesi için yapılan SEM analizlerinde, %96 saflıkta ve sırasıyla <8nm, 8-18nm ve 48-78 nm tanecik boyutlarına sahip olan, herhangi bir işlevlendirme yapılmamış Çok Duvarlı Karbon Nanotüplerin (ÇDKNT) görüntüleri elde edilmiştir. Şekil 2.a, 2.b ve 2.c'de görülen SEM görüntüleri, her bir tanecik için elde edilen sonuçları yansıtmaktadır. Görüntülerden elde edilen sonuçlar, satın alınan ÇDKNT'lerin boyutsal tutarlılığının istenen düzeyde olduğunu doğrulamaktadır. Bu durum, çalışmanın temel materyalini oluşturan ÇDKNT'lerin homojen ve istikrarlı bir yapıda olduğunu göstermektedir.




Şekil 2. %96 Safılıkta, a) <8nm, b)8-18 nm ve c) 48-78 nm tane boyutuna sahip ÇDKNT'ün SEM görüntüleri

Tablo 1'de yer alan VSM analiz sonuçları, çalışmanın temel materyali olan üç farklı boyutta çok duvarlı karbon nanotüplerin (ÇDKNT'ler) manyetik özelliklerini göstermektedir. Buna göre 300 K sıcaklık değerinde elde edilen histeresis eğrilerinden çıkarılan koersivite ve doyum manyetizasyon değerleri verilmiştir. Tanecik boyutları arttıkça doyum manyetizasyon ve koersivite değerlerinde azalma gözlemlenmiştir. Bu durum, tanecik boyutlarının artmasıyla birlikte yüzey hacim oranının azalması ve aglomerasyonun artması gibi faktörlerin dielektrik kaybını azaltarak bu sonuca neden olabileceğini düşündürmektedir.


Tablo 1. 3 farklı boyutta ÇDKNT'ün VSM sonuçları

| Numune | Ms (emu/g) | Koersivite (Oe) | Mr/Ms |
|----------|------------|-----------------|-------|
| <8 nm | 2,63 | 112,63 | 0,106 |
| 8-18 nm | 2,19 | 111,71 | 0,122 |
| 48-78 nm | 2,12 | 97,75 | 0,153 |


Üretilen kompozitlerin, koaksiyel hat kurulumu yapılmış olan Network Analizörü kullanılarak 8 ila 12 GHz frekans aralığında alınan ölçümleri alınmıştır (Şekil 3). Şekil 3.a, farklı tanecik boyutuna sahip karbon nanotüplerin %1 yükleme oranında eklenmiş olduğu kompozit malzemenin Network Analiz ölçüm sonuçlarını göstermektedir. Bu sonuçlara göre, en iyi değer 48-78 nm aralığında boyuta sahip kompozitlerde gözlemlenmiş olup, minimum yansıma kaybı değeri -8.91 dB ve etkin bant genişliği 10,17 GHz olarak belirlenmiştir. Nanotüplerin %2 oranında eklendiği kompozitlerin sonuçları Şekil 3.b'de görülmektedir. Buna göre, en iyi sonuç yine 48-78 nm aralığında boyuta sahip nanotüp içeren kompozitlerde elde edilmiştir. Değer olarak ise minimum yansıma kaybı değeri -7.28 dB ve etkin bant genişliği 10,08 GHz olarak belirlenmiştir. Şekil 3.c ise, %3 yükleme oranında nanotüp eklenmiş kompozitlerin network analiz sonuçlarını göstermektedir. Görüldüğü üzere en iyi sonuç aynı şekilde, minimum yansıma kaybı değerininin -5.61 dB olarak ve etkin bant genişliğininin de 10.06 GHz olarak bulunduğu 48-78 nm aralığında boyutta nanotüp içeren kompozitlerden elde edilmiştir.



(a)



(b)



(c)

Şekil 3. Farklı boyutlarda ÇDKNT nanotüplerin %1, %2 ve %3 yükleme seviyelerinde ölçümlerin değerleri

4. Tartışma ve Sonuç

Fan ve arkadaşlarının [6] yaptığı çalışmada, elektromanyetik ve mikrodalga soğurma özellikleri bakımından Karbon Nanotüp (KNT)/polimer (PET, PP, Vernik) kompozitleri incelemiştir. Çalışmada artan KNT konsantrasyonuyla yansıtma frekansı düşmüş ve kompozitlerin kayıp faktörleri artmıştır. %4'ten yüksek KNT konsantrasyonunda kayıp faktöründe belirgin bir artış gözlenmiş, özellikle %4 KNT/PET ve %8 KNT/Vernik kompozitler önemli mikrodalga soğurma göstermiştir. KNT/polimer kompozitleri, 13 GHz, 10 GHz ve 6 GHz frekanslarında etkili mikrodalga soğurma göstermiştir. Bu bakımdan Fan'ın araştırmasında elde ettiği sonuçlar bizim çalışmamız ile farklılık göstermektedir. Zira bu çalışmada katkı miktarının artırılmasıyla yansıma kaybının azaltıldığı görülmüştür. Bunun ise fazla katkı maddesi yüklenmesiyle meydana gelen aglomerasyondan kaynaklandığı düşünülmektedir. Aglomerasyon dielektrik kaybını düşürerek soğuruculuk yeteneğini olumsuz etkileyebilmektedir. Ayrıca mikrodalga emilimi, manyetik kaybın ötesinde özellikle dielektrik kaybına bağlanabilir bir nitelik taşımaktadır. Zhang ve arkadaşlarının [7] yaptığı çalışmada 2 ila 6 GHz frekans aralığında Karbon Nanotüp (KNT)/epoksi kompozitlerin elektromanyetik özelliklerini ve mikrodalga soğuruculuk performansını incelemiştir. %15 yükleme oranına sahip tek katmanlı KNT/epoksi kaplama, S ve C1 bantlarında etkili mikrodalga soğuruculuk sergilemiştir. Özellikle, 2 mm kalınlığı ve %15 yükleme oranıyla 3,85 GHz'de maksimum -10,5 dB güçlü bir yansıtma sahiptir. İleri adımlarda, yansıtma zirvesini genişletmek amacıyla iki katmanlı bir kaplama tasarlanmıştır. Bu tasarım, 5,52 GHz'de -20,79 dB'ye ulaşan yüksek soğurma değeri sunmaktadır. Çalışma, KNT'lerin mikrodalga soğurucu malzemelerin tasarımında ve üretiminde potansiyelini vurgulayarak, özgün kaplama tasarımlarının S ve C1 bantlarında etkili elektromanyetik dalga soğuruculuk sağlayabileceğini göstermektedir. Bu çalışma bizim çalışmamızla oldukça paralel sonuçlar ortaya konmuştur.

Zhao ve arkadaşlarının yaptığı çalışmada, bilyeli öğütme ve ıslak öğütme yöntemlerinin Çok Duvarlı Karbon Nanotüp (ÇDKNT) dağılımı üzerinde belirgin bir etkisi olduğu belirlenmiştir. Elektromanyetik dalga soğurma özelliği, öğütme koşullarının önemli bir belirleyeni olarak ortaya çıkmış, kuru öğütme yöntemi kullanılan numunelerin en üst düzey performans sergilediği vurgulanmıştır. En düşük yansıma kaybı, 3 mm kalınlığındaki örneklerde ve 6,1 GHz bant genişliğinde, kalınlığın 2-5 mm arasında değiştiği örneklerde ise 6,8 GHz bant aralığında -37,3 dB olarak ölçülmüştür. Bu sonuçlar, ÇDKNT kompozitlerin elektromanyetik dalga soğuruculuk özelliklerini optimize etmede öğütme koşullarının kritik bir faktör olduğunu göstermektedir [8]. Diğer yandan, Kong ve arkadaşlarının çalışması, hafif, güçlü ve geniş bir soğurma bant genişliğine sahip potansiyel bir elektromanyetik soğurucu malzeme üretme amacını taşımaktadır. Karbon Nanotüp (KNT) ve grafenin kovalent C-C bağı ile büyüyen düzlemleri, daha iyi dağılım ve düşük arayüzey teması elektrik direnci sağlayarak elektromanyetik parametrelerin etkili bir şekilde optimize edilmesine olanak tanımaktadır. Elde edilen KNT/Grafen hibritleri, düşük Radyasyon Kaybı Katsayısı (RKA) ve etkili bir soğurma bant genişliği ile dikkat çekmektedir. Özellikle, %5 dolgu yükü ağırlığı ve 2,75 mm soğurucu kalınlığı durumunda, RKA minimum -55dB'ye ulaşmış ve geniş bir soğurma bant genişliğiyle etkin elektromanyetik soğurma kapasitesine sahip potansiyel bir malzeme elde edilmiştir [9].

Melvin ve arkadaşları yaptıkları çalışmada, sol-jel yöntemiyle üretilen Baryum titanat/karbon nanotüp (BTO/KNT) hibrit nanokompozitlerin elektromanyetik dalga soğuruculuk özelliklerini detaylı bir şekilde incelemiştir. Farklı ağırlık yüzdeleriyle parafin mumuna yüklenmiş olan bu nanokompozitler, vektör ağ analizörü kullanılarak 1mm kalınlığında toroidal şekilde üretilerek geçirgenlikleri değerlendirilmiştir. Çalışma sonuçlarına göre, BTO/KNT ağırlıkça %60 hibrit nanokompozit numunesi 1mm kalınlığında, 13,6 GHz'de minimum yansıma kaybının 29,6 dB'ye ulaştığı ve geniş bir bant genişliği sergilediği belirlenmiştir. Ayrıca, aynı malzemeden üretilen 1,1 mm kalınlığındaki BTO/KNT ağırlıkça %60 hibrit nanokompozit numunesi, 13,2 GHz'de -56,5 dB'lik minimum yansıma kaybı ile en iyi soğurucu olarak tespit edilmiştir. Yansıma kaybı tepe noktasının düşük frekansta kaydırılabilmesi ve numunelerin kalınlığının arttıkça daha geniş yanıt bant genişliği elde edilebilmesi, hibrit nanokompozitlerin soğurma bandını farklı frekans bantlarına modüle etme yeteneğini göstermektedir [10]. Öte yandan Wang ve arkadaşlarının çalışmasında, çok duvarlı karbon nanotüp (ÇDKNT)/çimento kompozitlerin elektromanyetik dalga soğurma özelliklerini detaylı bir şekilde incelemiştir. Farklı ÇDKNT içeriğine sahip çimento harcı numuneleri üretilmiş ve elektromanyetik dalga soğurma özellikleri analiz edilmiştir. Çalışma, ağırlıkça %0,6 ÇDKNT içeren 25 mm kalınlığındaki çimento harcı numunesinin, 2-8 GHz bant aralığında -28 dB yansıtıcılığa sahip en güçlü tepe noktasını 2,9 GHz'de elde ettiğini göstermektedir. Ayrıca, 35 mm kalınlığındaki çimento harcı numunesi, 8-18 GHz bant aralığında ağırlıkça %0,9 ÇDKNT ilavesi ile çimento harcının dalga soğurma performansını önemli ölçüde artırmış ve -10 dB'nin altındaki bant genişliğini 8-18 GHz frekans aralığında 7,1 GHz'e çıkarmıştır [11].

Başka bir çalışmada Qi ve arkadaşları, H-HCNT'ler, L-HCNT'ler ve solucan benzeri KNT'ler, asetilenin katalitik ayrışması yoluyla Fe nano parçacıkların katalizörü olarak kullanılmasıyla üretilmiştir. Bu süreç, kombine bir birlikte çökeltme/hidrojen indirgeme yöntemi ile gerçekleştirilmiştir. Çalışmada, kompozitteki KNT'lerin kütle fraksiyonunun düşük olmasına rağmen (ağırlıkça %30), malzemelerin iyi bir mikrodalga soğurma yeteneği

sergilediği belirlenmiştir. Solucan benzeri KNT kompozitleri, maksimum yansıma kaybı ve -20 dB'nin altındaki yansıma kaybına karşılık gelen bant genişliği sırasıyla -26,39 dB ve 3,2 GHz değerlerine sahiptir [12]. Liu ve arkadaşlarının çalışmasında ise, metal-organik çerçevelerden türetilen gözenekli ve içi boş CoNi@C (CNC) mikrokürelerin solvothermal yöntem ve tavlama işlemiyle üretildiği bir araştırmadır. Çalışmada, morfoloji, yapı, mikrodalga soğuruculuk özellikleri ve iç ilişkiler sistematik olarak araştırılmıştır. Gözenekli ve içi boş CNC mikroküreler, minimum yansıma kaybının 10,7 GHz'de -44,8 dB'ye ulaşabildiği ve ultra geniş etkili soğuruculuk bant genişliğinin 1,6-4,0 mm kalınlıkta 13,3 GHz'e (4,7-18,0 GHz) kadar ulaşabildiği belirtilmiştir. CNC mikrokürelerin, gelişmiş empedans uyumu ve zayıflama yeteneğine bağlı olarak üstün mikrodalga soğuruculuk performansı sergilediği vurgulanmıştır. İçi boş yapının, arayüzey polarizasyonu, CoNi alaşımı ve grafitleştirilmiş karbon arasındaki sinerjik etkinin, mikrodalga soğuruculuk mekanizmalarını aynı anda hesaba kattığı ifade edilmiştir. Bu çalışma, ayarlanabilir bileşen ve özel morfolojiye sahip, hafif ve yüksek verimli mikrodalga soğurucuların tasarımı ve hazırlanması konusunda umut verici seçenekler sunmaktadır [13].

Tiwari ve arkadaşlarının yaptığı çalışmada, pirolün 'kimyasal oksidatif polimerizasyonu' ile sentezlenen PPy/TiO₂(np)/CNT nanokompozitler X-bandında (8-12 GHz bant aralığında) mikrodalga ölçümleri ile detaylı bir şekilde incelenmiştir. Çalışmada, TiO₂(np) partikül boyutunun 60 ila 150 nm arasında olduğu belirlenmiş ve ortalama kristalit boyutu Scherrer formülü ile hesaplanarak 26 nm olarak tespit edilmiştir. Mikrodalğanın minimum yansıma kaybının, nanokompozitlerdeki dielektrik kayıptan kaynaklandığı ifade edilmiş ve 3 mm kalınlığındaki numune (PPy/TiO₂(np)/CNT) için 8,64 GHz'de -51,11 dB (%99,99) olarak ölçülmüştür. Bu sonuçlar, PPy/TiO₂(np)/CNT nanokompozit malzemenin, mikrodalgaları soğurabilmesi için etkili bir seçenek olabileceğini göstermektedir [14]. Hussein ve arkadaşlarının yaptığı çalışması ise, poliüretan polimerlerde işlevselleştirilmiş KNT kullanılarak mikrodalga soğurucu malzeme tasarımı ve geliştirme sürecine odaklanmaktadır. KNT, farklı konsantrasyonlarda (%5, %10 ve %20) karıştırılarak kompozitler elde edilmiştir. Yapılan ölçümlerde, KNT'deki işlevselleştirici eleman içeriği arttıkça geliştirilen kompozitlerin önemli dielektrik kayıplarına sahip olduğunu göstermektedir. Üç farklı metal alaşımı, %10 ve %20 konsantrasyonla geliştirilen kompozitlerde belirgin yansıma kaybı sergilemektedir. -10 dB'lik bir soğuruculuk seviyesine ulaşmak için, daha düşük konsantrasyonda 3 mm ve daha yüksek konsantrasyonlarda ise 0,8 mm kalınlığındaki bir kompozit tabaka kullanılmıştır. Bu bulgular, doğru kompozit kalınlığına sahip bir malzemenin soğuruculuk verimliliğini artırabileceğini ve geliştirebileceğini göstermektedir. Bununla birlikte, işlevselleştirilmiş KNT kullanımının havacılık uygulamalarında önemli bir gelişme oluşturduğu, ancak ekstra ağırlık artışına neden olabileceği belirtilmiştir [15].

Tüm bu araştırmaların ışığında yapılan bu çalışmada, çok duvarlı karbon nanotüplerin (ÇDKNT) mikrodalga soğurma özelliklerini araştırılmış ve bu özelliklerin optimize edilmesi sağlanmıştır. Kompozit malzemelerin elektromanyetik dalga soğurma yeteneklerinin, yüklenme miktarı ve tanecik boyutu gibi faktörlere bağlı olarak değişebileceğini göstermektedir. İlk olarak tanecik boyutunun artmasıyla yansıma kaybı değerlerinin arttığını gözlemlenmiştir. Bu durum, genellikle dielektrik kaybı ile ilişkilendirilir. Bu durum kompozit malzemelerin elektromanyetik dalgalarla etkileşime girerek bu dalgaların zayıflamasına neden olur. Bu da mikrodalga soğurma kabiliyetini artırır. Öte yandan, artan katkı malzemesinin aglomerasiyona yol açmasına bağlı olarak soğuruculuk yeteneği olumsuz etkilenmiştir. Bu nedenle, optimal mikrodalga soğurma performansı için katman sayısı, tanecik boyutu ve yüklenme seviyeleri dikkatle seçilmelidir. Çalışma ilerleyen teknoloji ile ÇDKNT'lerin, gizlilik teknolojisi, sağlık, telekomünikasyon gibi birçok uygulama alanında etkin bir şekilde kullanılabilmesini göstermiştir. Özellikle katkı maddelerinin boyutsal olarak değerlendirildiği bir çalışma olması sebebiyle, gelecekteki araştırmacılara mikrodalga soğurma özelliklerini optimize etmek ve çeşitli uygulamalarda kullanmak için bir yön gösterici olacağı düşünülmektedir.

Kaynakça

- [1] Ren, M., Li, F. 2020. Preparation And Electromagnetic Wave Absorption Properties Of Carbon Nanotubes Loaded Fe₃O₄ Composites. *Journal of Magnetism and Magnetic Materials*. (2020) 2, 513
- [2] Shoukat, R., Khan, M.I. 2021. Carbon Nanotubes: A Review on Properties, Synthesis Methods and Applications in Micro and Nanotechnology. *Microsystem Technologies*. (2021) 2, 1-10
- [3] Hussein, M.I., Jehangir, S.S. 2020. Microwave Soğurucu Properties Of Metal Functionalized-CNT-Polymer Composite For Stealth Applications. *Scientific Reports*. (2020) 2, 10.
- [4] Yılmaz Atay H., Çelik E. (2014). Barium Hexaferrite Reinforced Polymeric Dye Composite Coatings for Radar Soğurucu Applications, *Polymer Composites*. Volume 35, Issue 3, pages 602–610, March 2014
- [5] Karbon Nanotüpler ve Nanoteknoloji İle Gelecek, 2023. <https://shop.nanografi.com.tr/blografi/karbon-nanotupler-ve-nanoteknoloji-ile-gelecek/> pdf (Erişim Tarihi: 21.01.2007).
- [6] Fan, Z., Luo, G., Zhang, Z., Zhou, L., Wei, F. 2006. 3- Electromagnetic and Microwave Soğurucu Properties of Multi-Walled Carbon Nanotubes/Polymer Composites. *Materials Science and Engineering: B*. 132 (1-2) (2006) p. 85-89.
- [7] Zhang, H., Zeng, G. 2009. Electromagnetic Characteristic And Microwave Absorption Properties Of Carbon Nanotubes/Epoxy Composites In The Frequency Range From 2 To 6 Ghz. *Journal of Applied Physics*. 105 (2009) 5.
- [8] Zhao, T., Wang, X. 2019. Electromagnetic Wave Absorption Properties Of Multi-Walled Carbon Nanotubes-Anatase Composites in 1–18 Ghz Frequency *Ceramics International*. 45 (2019) 17.
- [9] Kong, L., Yin, X., Yuan, X., Zhang, Y., Liu, X., Cheng, L. 2014. 2- Electromagnetic Wave Absorption Properties of Graphene Modified with Carbon Nanotube/Poly(Dimethyl Siloxane) Composites. *Carbon*. 73 (2014) p. 185-193.
- [10] Melvin, J.H., Ni, Q.Q., Natsuki, T. 2014. Electromagnetic Wave Absorption Properties of Barium Titanate/Carbon Nanotube Hybrid Nanocomposites. *Journal of Alloys and Compounds*. 615 (2014) 84-90.
- [11] Wang, B., Guo, Z., Han, Y. 2013. Electromagnetic Wave Soğurucu Properties of Multi- Walled Carbon Nanotube/Soğurucu Composites. *Construction and Building Materials*. 46 (2013) 98-103.
- [12] Qi, X., Yang, Y. 2009. Large-Scale Synthesis, Characterization And Microwave Absorption Properties Of Carbon Nanotubes Of Different Helicities. *Journal of Solid State Chemistry*. 182(10) (2009) 2691-2697.
- [13] Liu, Y., Chen, Z. 2019. Enhanced Microwave Absorption Performance Of Porous And Hollow Coni@C Microspheres With Controlled Component And Morphology. *Journal of Alloys and Compounds*. (2019) 809.
- [14] Tiwari, D.C., Dipak, P. 2018. Ppy/Tio₂(Np)/CNT Polymer Nanocomposite Material For Microwave Absorption. *Journal of Materials Science: Materials in Electronics*. 29 (2018) 1643-1650.
- [15] Hussein, M.I., Jehangir, S.S. 2020. Microwave Soğurucu Properties Of Metal Functionalized-CNT-Polymer Composite For Stealth Applications. *Scientific Reports*. (2020) 10.

Smart Classroom Attendance and Management System with Deep Learning

İbrahim Ardıç¹, Batuhan Yıldızhan¹, Kübra Uyar^{1*}

¹ Alanya Alaaddin Keykubat University, Department of Computer Engineering, ANTALYA

(Alınış / Received: 23.06.2024, Kabul / Accepted: 01.10.2024, Online Yayınlanma / Published Online: 30.12.2024)

Keywords

Automation,
Biometric Identification,
Deep Learning
Facial Recognition,
Mobile Application,
Paper-based attendance

Abstract: The evolution of traditional educational methods highlights the necessity to adapt to new technologies. This study aims to facilitate the attendance-taking processes in the education sector through automation. Addressing challenges such as time loss, accuracy issues, and the fragmentation of class periods associated with paper-based attendance methods, we introduce the Smart Classroom Attendance and Management System. Our study utilizes facial recognition technology to scan the facial features of each student, providing a unique biometric identification and automatically enrolling students in the class. This approach allows students to be automatically recorded upon entering the classroom, eliminating the need for paper-based attendance. Additionally, it is supported by a mobile application, we provide two different panels for teachers and students, minimizing human errors. Students can view and verify attendance information through the application at the end of the class, while teachers can approve the recorded attendance, thereby enhancing the reliability of the system. In conclusion, the Smart Classroom Attendance and Management System offers an innovative approach to overcome the challenges posed by traditional methods and make educational processes more efficient. Representing the transformation of automation in the education sector, this study aims to contribute to a more effective learning experience for both students and teachers.

Derin Öğrenme ile Akıllı Sınıf Yoklama ve Yönetim Sistemi

Anahtar Kelimeler

Otomasyon,
Biyometrik Tarama,
Derin Öğrenme,
Yüz Tanıma,
Mobil Uygulama,
Kağıt Tabanlı Yoklama

Öz: Geleneksel eğitim yöntemlerinin evrimi, teknolojik gelişmelere uyum sağlama ihtiyacını doğurmuştur. Bu çalışma, eğitim sektöründe yoklama süreçlerini otomasyon ile kolaylaştırmayı amaçlamaktadır. Kağıt tabanlı yoklama sistemlerinin zaman kaybı, yoklamadaki doğruluk sorunları ve ders sürelerinin bölünmesi gibi zorluklarını ele almaktadır. Bu doğrultuda, Akıllı Sınıf Yoklama ve Yönetim Sistemi tasarlanmıştır. Yüz tanıma teknolojisi kullanılarak her öğrencinin yüz hatları taranmaktadır. Daha sonrasında, bu benzersiz biyometrik tanımlama ile öğrenciler otomatik olarak sınıfa kaydedilmektedir. Böylece, öğrencilerin sınıfa girişleri otomatik olarak sağlanmakta, kağıt tabanlı yoklama ihtiyacı ortadan kalkmaktadır. Ayrıca, mobil bir uygulama ile entegre edilen bu sistem, öğretmenler ve öğrenciler için iki ayrı panel sunarak insan ve sistem hatalarını en aza indirmeyi hedeflemektedir. Öğrenciler, dersin sonunda uygulama aracılığıyla yoklama bilgilerini görüntüleyebilir ve doğrulayabilirken, öğretmenler de alınan yoklamaları onaylayarak olası hataları önleyebilmektedirler. Sonuç olarak, Akıllı Sınıf Yoklama ve Yönetim Sistemi, geleneksel yöntemlerin zorluklarını aşmak ve eğitim süreçlerini daha verimli hale getirmek için yenilikçi bir yaklaşım sunmaktadır. Bu çalışma, eğitim sektöründeki yoklama sürecinde otomasyon dönüşümünü temsil ederek, öğrenciler ve öğretmenlerin daha etkili bir ders deneyimi yaşamasına katkı sağlamayı amaçlamaktadır.

1. Introduction

Education is a fundamental factor for the progress of societies and the personal development of individuals. Good education plays a critical role in the development of each individual and the preparation of new generations. Efficient and effective management of education processes is one of the key elements that reinforce this success. Traditional educational methods, with their time-consuming and paper-based processes, susceptibility to manipulation of information, and tendency to disrupt class periods, have brought about challenges. In light of these challenges, our study aims to overcome them in the education sector. It has emerged with the goal of automating and improving student attendance processes.

The “Smart Classroom Attendance and Management System” is developed to address challenges such as time loss, accuracy issues, and class period disruptions associated with paper-based attendance methods, presents an integrated approach with new-generation technologies. The main objective of the proposed study is to automatically enroll each student in the class by creating a unique biometric identity through facial recognition technology. Additionally, through a designed mobile application with two separate panels for teachers and students, minimizing human errors and enhancing the efficiency of the education process. This study is considered to represent an automation transformation in the way attendance is taken in the education sector.

In the Smart Classroom Attendance and Management System, the attendance process begins with teachers manually adding students to the appropriate course through the mobile app. Before the lesson, teachers activate the classroom camera and attendance system by connecting to the system. Upon entering the classroom, students present their faces to the camera. The system then utilizes facial recognition technology to match each student's face against the teacher's record. If a match is successful, the student is marked as present in the attendance log. Before confirming the attendance, the teacher can count the students in class and compare with the number of students in the system. At the end of class, the teacher confirms the attendance via the mobile application. By confirming the attendance list, system inactivates the camera and triggers a notification to all students informing them of their class attendance record. By implementing notification feature, we aim to achieve two goals: Students who are physically present in class but marked absent due to a system error can notify their teacher through the notification received, and the attendance system can provide feedback to students regarding their attendance status.

There are several projects aimed at addressing challenges in attendance systems have been identified. Previous works focused on developing smart attendance systems utilizing card reading, RFID systems, fingerprint scanning, IoT systems, and facial recognition technologies, emerging as notable examples in our research. Among these exemplary projects in the field: smart classroom roll caller system with IoT architecture [1], college smart classroom attendance management system based on IoT [2], A smart classroom application, monitoring and reporting attendance automatically using smart devices [3], automated attendance system [4], automated Attendance Marking and Management System by Facial Recognition Using Histogram [5], Classroom Attendance systems based on bluetooth low energy indoor positioning technology for smart campus [6], free and generic facial attendance system using Android [7], Android-based smart student attendance system [8], fingerprint attendance System for Classroom Needs[9], IoT Based Cloud Integrated Smart Classroom for Smart and a Sustainable campus [10], face recognition based attendance management system [11], automation attendance systems approaches: a practical review [12], Android-based attendance management system [13], location-based smart attendance system using GPS [14], mobile-based attendance system: face recognition and location detection using machine learning [15], automatic attendance management system using face detection [16].

Under the category of RFID, which is indicated as an older version of the currently used NFC technology, Souza et al. [5] have examined institutions that facilitate participation from various environments and suggest the need for a different participation project for these institutions. The android-based RFID project includes a mobile application and RFID components. The RFID component documents student participation in the database, but when it cannot be used due to resource constraints, the mobile application is used as an alternative. Chang [1], using a different RFID technology, also implements a system where RFID tags can be attached to student ID cards or clothing. The tags have a lifespan of 5 to 10 years and the read range is 10 to 100 centimeters. The server can be cloud-based or local. Another project by Zhao [2] uses 2 different RFID readers (one at the entrance and one at the exit of the classroom) to also detect whether students are present in the classroom during the entire class period and generate an automatic attendance report. This makes it easier to track absenteeism and take appropriate measures. Figure 1 illustrates the conceptual model of RFID roll call system.

In terms of android-based identity authentication, a system developed by the Android operating system is designed to expedite and simplify routine registration or login processes for users. However, this widely used system today can pose a security threat for users using weak login credentials. Hameed [8] offers three separate

management profiles using Android-based identity authentication in his developed application. These profiles include an administrator account that can modify the database, a teacher account that can mark students, and a reporter account that can verify attendance records. Teachers can easily take attendance with their Android or iOS devices and comfortably record it for presentations.

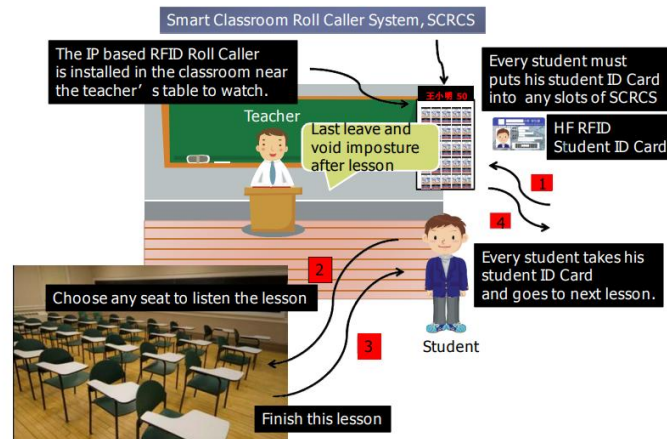


Figure 1. Conceptual model of RFID roll call system [1].

Some studies above, show the usability of fingerprint-based attendance systems. Mohamed and Raghu [9] allow students to verify their attendance by scanning their fingerprints on the device's sensor in the defined fingerprint attendance system as demonstrated in Figure 2. However, since fingerprint readers are generally sensitive devices, this process may require multiple repetitions and extend the attendance process.

The face recognition-based relies on comparing faces detected from photo or video sources with recognized/unrecognized face data in the database. The system developed by Smitha [12] consists of two main sections: face recognition and detection. It applies face recognition to data obtained with the help of a camera, and if the recognized face is detected in the recognized face database, it records the student's attendance in the attendance system. Another aspect addressed by Varadharajan et al. [18] is the capturing of the classroom photo through a camera placed in the classroom, checking for recognized faces in the photo against the database, and entering attendance information. Families of students not present in the class are informed. Hava and her coworkers research [7] identities by detecting their faces using a facial recognition algorithm from the cameras of their Android phones.




Figure 2. Fingerprint attendance system for classroom needs[9] portable fingerprint attendance system.

QR codes and Barcodes are graphical representations of data that can be read by machines. Barcodes are typically used to store information associated with a product. QR codes, on the other hand, are similar to barcodes but can store more information because they are two-dimensional. QR code technology and is based on research by Sutar et al. [4], is a smart attendance system that would speed the attendance process by creating and scanning QR codes. The system runs as an application on mobile devices and is built on QR technology.

Another system called GPS-based attendance systems uses location of students in order to define their attendance. GPS technology allows us to determine the current location of a user on the Earth. This technology is now being utilized in attendance systems in classrooms. For instance, Kumar and his colleagues [16] presented a location-based attendance monitoring system in their work using Android mobile applications. The GPS in the mobile application used by students monitors their current location. In this scenario, if the student is present at the

specified location during class hours, the attendance information is recorded in the database. However, there is a possibility of misleading the teacher during attendance with less accurate GPS devices. Figure 3 shows block diagram of location-based smart attendance system that use GPS.



Figure 3. Block diagram of location-based smart attendance system using GPS [16].

In Bluetooth Technology, researchers developed a system that utilizes Bluetooth Low Energy (BLE) technology for attendance management. Şengül [3] utilizes a BLE beacon placed within the classroom. When students enter the classroom, their smartphones automatically detect the beacon's signal, triggering their presence to be logged in the system. This data is then transmitted to a central server where attendance reports are generated and accessible to instructors. Puckdeevongs [6], also uses BLE technology for automated attendance, but it also utilizes dedicated beacons for enhanced accuracy and scalability.

Our study stands out in terms of originality compared to previous applications in the field. Unlike past implementations that solely relied on mobile applications or facial recognition systems, our study combines both technologies for a more robust solution. Specifically, while facial recognition technology ensures accurate attendance records, the integration of a dedicated mobile application adds an extra layer of sophistication. Unlike the existing projects, our mobile application boasts two distinct panels tailored for students and teachers, a feature designed to minimize potential errors in the attendance tracking process. This dual-system integration not only enhances accuracy but also plays a pivotal role in the overall automation system, setting our project apart with its innovative approach.

2. Material and Method

In this section, the focus will be on the technologies used in the Smart Classroom Attendance and Management System and the integration of these technologies.

2.1. Dataset

In the experimental studies, Fddb face recognition dataset [17] that contains selected a total of 3527 images is utilized. The dataset contains images and associated captions extracted from news articles. There is a lot of variance in the poses, lighting, backgrounds, and appearances of the photos in this collection. Motion, occlusions, and facial expressions are some of the elements that contribute to these variations in face appearance and are typical of the unconstrained picture capture setting.

2.2. Model Design

The proposed model works with Histogram Oriented Gradients (HOG) [18] for finding faces. The steps of the algorithm can be listed as follows:

- Step 1: Finding all the faces
 1. Make image black and white to find the faces in picture.
 2. Look at every single pixel in the image one at a time. For every single pixel, we want to look at the pixels that directly surrounding it.
- Step 2: Posing and projecting faces using the algorithm called face landmark estimation.
 1. Instead of training the CNN model to recognize pictures objects, we train it to generate 128 measurements (features) for each face.
- Step 3: Encoding Faces
- Step 4: Finding the name of the person from the encoding.

2.3. Database and Integration

In the Smart Classroom Attendance and Management System, we need a database because we need to store and access this data as needed. The project should store a variety of data, such as student information, teacher information, course information, and more. This data will make it possible to track and manage student attendance. In order for students and teachers to interact with the system, we need to provide access to this data in the database. The database supports secure and structured access to this data. In addition, the data in the system, such as attendance status, may need to be updated in real-time. The database makes real-time data synchronization possible. Student attendance and absenteeism statistics can also be analyzed using this dataset.

We use Google Firebase to meet our database needs for the project. Firebase is a cloud-based platform that provides the service that meets our project requirements. One of the reasons we are using Firebase is to provide real-time synchronization of student attendance records. Firebase makes it easy to synchronize data in real-time. It also provides tools to track and analyze application performance through its website. This will help us better track project data in a more convenient way. Also, Firebase can be seamlessly and easily integrated into Android and iOS mobile applications. This makes it easier for students and teachers to access the right data.

Our project must be integrated with libraries such as OpenCV, dlib, face_recognition, and TensorFlow to be able to recognize students by their facial features. The face recognition part of the project will be done using Python.

The system will be integrated with Google Firebase for user authentication, real-time data management and synchronization, and secure data storage. Firebase Realtime Database and Firestore will store student and course data.

The UI designs on the mobile side will be carried out separately for teachers and students. The teacher UI will provide the ability to view and change the data from the database. The student UI will only provide the ability to read.

The mobile application will serve as an interface for students and teachers to interact with the system. Developed using the Flutter framework for both iOS and Android platforms, the mobile application integrated with Firebase will provide the following features:

- Students' ability to view and verify attendance information.
- Teachers' ability to approve and edit taken attendance through the mobile interface.
- Real-time data synchronization with firebase.

These technologies will be seamlessly integrated to ensure that the Smart Classroom Attendance and Management System delivers a reliable, effective, and user-friendly experience.

2.4. Scenario

The teacher manually adds students under the class title through the mobile application. Before the lesson, the teacher connects to the system and activates the camera and attendance system in the classroom. When the camera is activated, students enter the classroom and present their faces. When the facial recognition system matches the student's face with the student recorded by the teacher, the attendance record is written as "Student present". The approval icon appears on the screen and the system goes into standby mode for other students to present their faces. At the end of the lesson, the teacher approves the camera shutdown process through the mobile application. After approval, a notification of the class attendance information is sent to the students through the mobile application.

As long as the camera is active, another teacher cannot access the same camera. Another teacher can activate the system using a different camera for a different lesson. For troubleshooting, if there is a problem with a student's attendance information, the student can notice it thanks to the notification that comes to their phone and contact the teacher. The teacher manually resolves the issue through the application and updates the information.

The camera will only be active with student interaction, in accordance with the Law on Unauthorised Surveillance of Persons. If there is no interaction for a long time or after the students' entry is approved, the camera will be automatically deactivated. Student consent will be obtained in accordance with the KVKK law for the processing of student facial data. This approval will be provided during course selection by adding the relevant course to the courses to be taken during the semester.

Google Firebase is used for data security, the database is created with Flutter. The mobile application is developed on Flutter. Python software is used for the facial recognition system. OpenCV and Face Recognition libraries is used in the project.

3. Functional and Non-Functional Requirements

The system is designed to provide a seamless and user-friendly experience for both students and lecturers in managing attendance. For students, the mobile application serves as a platform to view and verify their current attendance information, ensuring transparency and ease of access. Lecturers, on the other hand, are equipped with the tools to initiate attendance before class, as well as approve and edit attendance records at the end of the session. These functionalities are accessible through both the mobile application and a web interface, offering flexibility and convenience.

At the core of the system is an integrated classroom setup that utilizes facial recognition technology to create a unique biometric identity for each student. This technology allows the system to automatically record the presence of students as they enter the classroom, adding them to the attendance list upon recognition. To ensure the integrity of the data, all facial recognition information is securely stored in the database, protected by end-to-end encryption on Firebase. Different access levels are defined for students and lecturers, ensuring that only authorized users can access and manage the data.

Additionally, real-time data synchronization through Firebase ensures that attendance records are updated promptly, allowing lecturers to make manual adjustments if necessary. The mobile application, designed to operate smoothly on both iOS and Android platforms, is continuously monitored and analyzed using tools like Firebase Analytics to maintain optimal performance. This combination of automated attendance tracking, secure data handling, and robust mobile application performance provides a reliable and efficient solution for managing classroom attendance.

4. System Functionalities and Substances

The computer application part of the project includes four different modes that are activated based on the system's status. These modes indicate that the system is active and can scan the student's face, display student information, confirm that attendance has been taken, and notify if a student attempts to take attendance for the same class twice, showing that attendance has already been recorded. These conditions are activated when specific criteria are met. Figure 4 illustrates the interface of the smart classroom attendance system.

In addition to displaying information on the screen, a library has been imported that provides voice feedback to students. This library announces whose attendance has been recorded if it has been taken, or provides feedback if attendance has already been recorded with audio. Furthermore, if the student is recognized by the system but not enrolled in the course by the teacher, feedback of 'You are not enrolled in this course' is also provided audibly.

The face recognition system uses the 'face_recognition' library [19], which processes a single photo to identify 68 landmarks on the face. It offers high accuracy in face detection and recognition tasks by using a deep learning model based on a Convolutional Neural Network (CNN). As mentioned above, the library can detect 68 facial landmarks, including points around the eyes, nose, mouth, and jawline from a single image (Figure 5), simplifying the face recognition process and enhancing system efficiency. It also can be easily integrated with other Python libraries such as OpenCV, cvzone which we use. So that, this library is integrated into the system due to its high accuracy and efficiency. The use of a single photo for recognition, instead of multiple photos from different angles, enhances the system's usability.

We have a pre-existing JSON format that includes various information (name, major, student number, etc.) about students. The array of facial data obtained from the face recognition library is matched with student information in the JSON format, allowing us to decode facial data with student objects.



Figure 4. The interface of the smart classroom attendance system.



Figure 5. The 68 landmarks locete on every face [20].

When the system recognizes a student’s face, it retrieves the student’s information from the database by matching the facial data, displays this information on the screen, and provides feedback audibly, thereby updating the attendance records in the database. The mobile application communicates with the database in real-time, providing a seamless attendance experience.

Each individual performs the attendance process by having their face read by the camera. The proposed approach works flawlessly in cases where lighting is sufficient and without the need for an external camera, unless there are extremely adverse conditions (too dark an environment or a strong backlight that prevents the face from being read). Figure 6 explains the working principle of the proposed attendance system.

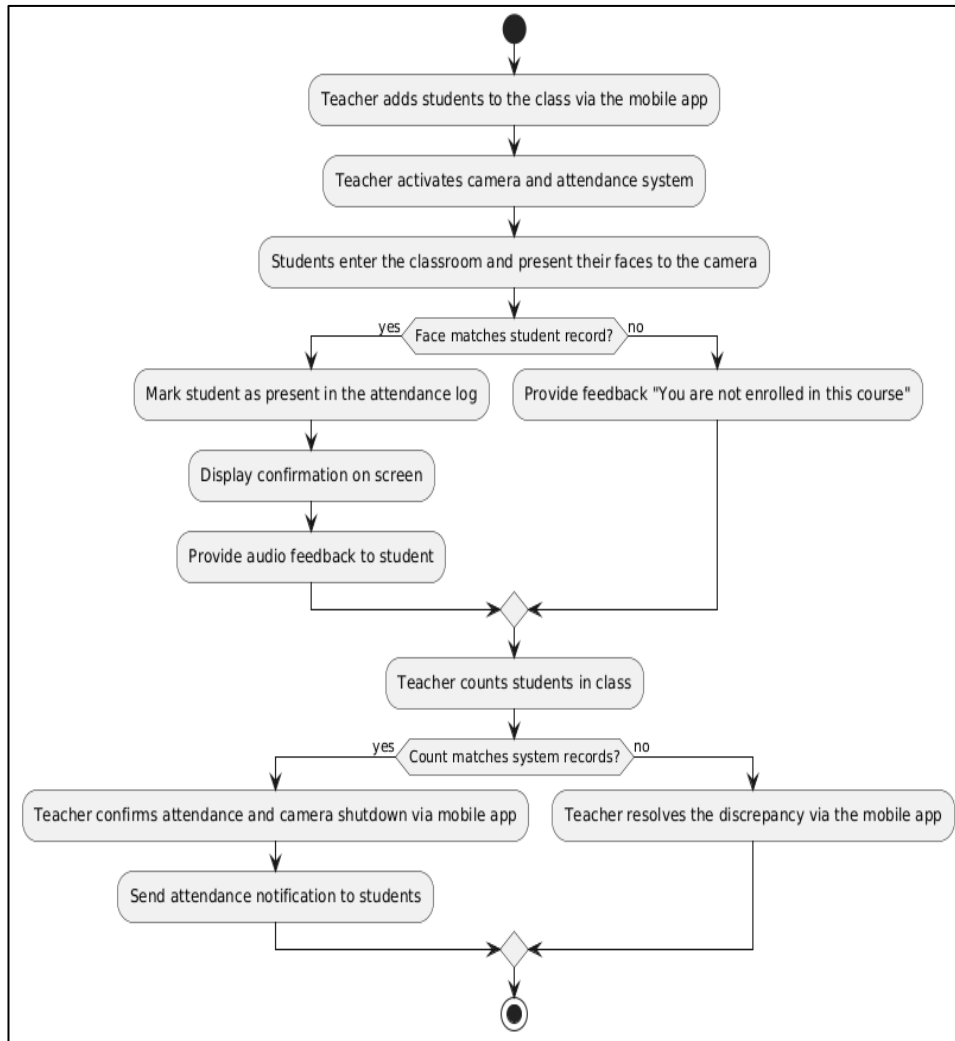


Figure 6. The working principle of the proposed attendance system.

5. Mobile Application

Our innovative attendance project for universities consists of two main components: facial recognition technology and a mobile control application. The mobile application allows teachers and students to log in through a user-friendly interface. Teachers can view active or inactive cameras and activate cameras assigned to their courses to start the attendance process. With the facial recognition system, students are automatically marked as "present," and teachers can make manual corrections if necessary. Attendance data is recorded in the database at the end of the class and reflected in students' profiles. Students can easily access all attendance records and dates for their courses through the mobile application. This system accelerates the attendance process, offering significant convenience and efficiency for both teachers and students. Figure 7 and Figure 8 gives some screens of the mobile application.

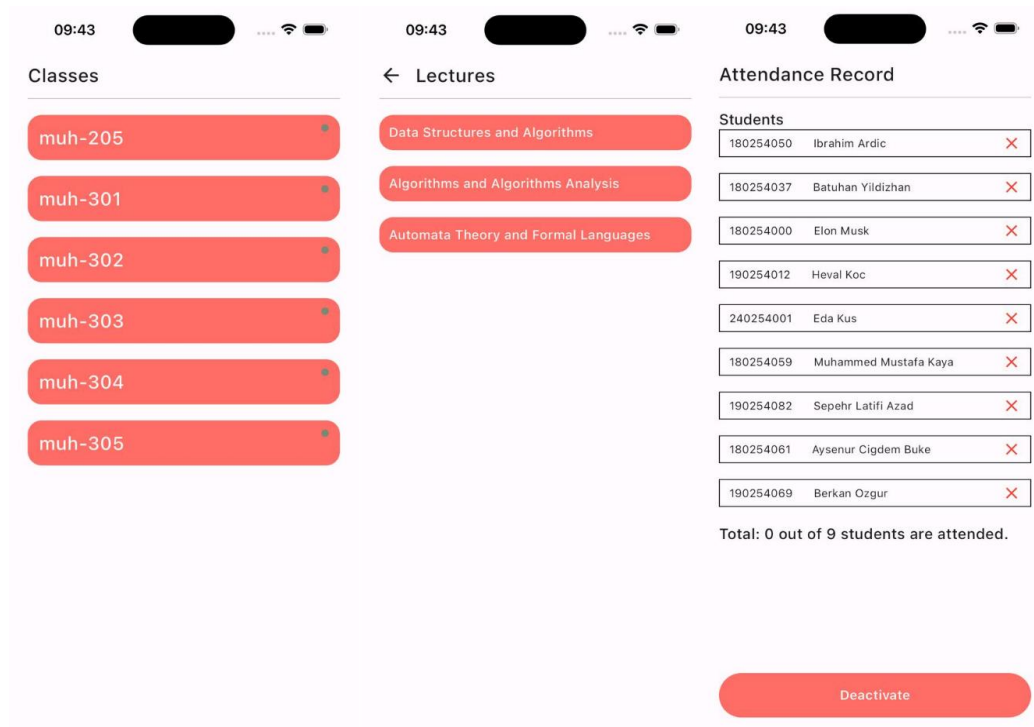


Figure 7. Lecturer's UI.

Figure 7 demonstrates the user interface designed for lecturers. The interface is organized into two main sections: classes and lectures. On the left, lecturers can see a list of the classes, each labeled with its respective university's class code. Upon selecting a class, one the middle one, it displays the list of lectures associated with the lecturer. Lecturers can easily access attendance records by clicking on a specific lecture. Lastly, on the right, the interface allows lecturers to view a detailed attendance record for each lecture, including a list of students enrolled in the course, identified by their student numbers and names. This view also includes the total number of students who have attended the lecture, providing lecturers with an overview of student participation at a glance. Additionally, lecturers have the option to deactivate the system once the attendance has been finalized.

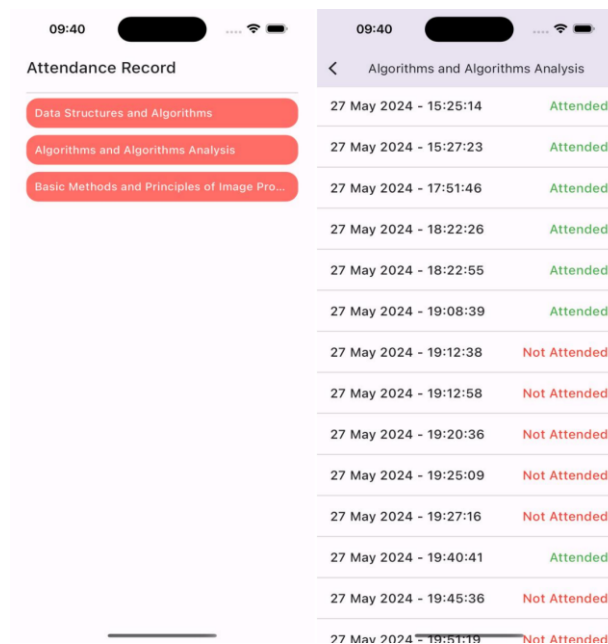


Figure 8. Student's UI.

Figure 8 presents the user interface designed for students. Similar to the lecturer's interface, students have access to a list of their enrolled lectures, displayed on the left side of the figure. Upon selecting a lecture, the right side of

the figure reveals the attendance record for that particular lecture. Students can see a timestamp of each attendance entry, along with an indication of whether they attended or missed the session. This interface allowing students to keep track of their participation in each course.

6. Discussion and Conclusion

The Smart Classroom Attendance and Management System project represents an advancement in the automation of attendance tracking. By integrating facial recognition technology with a dedicated mobile application, this system addresses the common challenges associated with traditional paper-based attendance methods. These challenges include time inefficiencies, accuracy issues, and disruptions during class periods.

Thanks to the 'face_recognition' library, the system's ability to create unique biometric identities for students ensures accurate and automatic attendance recording with a 99.38% accuracy, eliminating the need for manual input and reducing human errors. Also, two different panel designs of the mobile application for teachers and students enhance user experience and provides a reliable means for both parties to interact with attendance data. Teachers can efficiently manage and verify attendance records, while students can access and confirm their attendance status in real-time.

In conclusion, the Smart Classroom Attendance and Management System provides a practical and user-friendly solution to the challenges of traditional attendance methods. It highlights how modern technology can improve educational practices, contributing to a more efficient and effective learning environment for both students and teachers.

References

- [1] Ching Hisang Chang, "Smart Classroom Roll Caller System with IOT Architecture" 2011 Second International Conference on Innovations in Bio-inspired Computing and Applications 16-18-2011, Shenzhen, China. IEEE 02 January 2012. <https://ieeexplore.ieee.org/abstract/document/6118772>
- [2] Mingtao Zhao, Gang Zhao, Meihong Qu, "College Smart Classroom Attendance Management System Based on Internet of Things". Volume 2022 | Article ID 4953721 , <https://doi.org/10.1155/2022/4953721>
- [3] Gökhan Şengül, Murat Karakaya, Atilla Bostan, "A Smart Classroom Application, Monitoring and Reporting Attendance Automatically Using Smart Devices" International Journal of Scientific Research in Information Systems and Engineering Volume 3, issue 1, April – 2017. ISSN 2380-8128.
- [4] Harshad Sutar, Suyash Chaudhari, Pritam Bhopi, and Dipashri Sonavale, "Automated Attendance System," Int. Res. J. Mod. Eng. Technol. Sci., vol. 04, 2022.
- [5] Jenif W. S. D'Souza, S. Jothi, A. Chandrasekar, "Automated Attendance Marking and Management System by Facial Recognition Using Histogram" in 2019 5th International Conference on Advanced Computing and Communication Systems, ICACCS 2019, doi: 10.1109/ICACCS.2019.8728399.
- [6] Aipruk Puckdeevongs, N. K. Tripathi, Apichon Witayangkurn, Poompat Saengudomlert, "Classroom Attendance Systems Based on Bluetooth Low Energy Indoor Positioning Technology for Smart Campus", Remote Sensing and Geographic Information Systems Field of Study, School of Engineering and Technology, Asian Institute of Technology. Telecommunications Field of Study, School of Engineering and Technology, Asian Institute of Technology vol.11 No.329, 2020.
- [7] Vaishnavi Hava, Seema Kale, Arun Bairagi, Chandan Prasad, Sagar Chatterjee, Anish Varghese, "Free & Generic Facial Attendance System using Android" Int. Res. J. Eng. Technol., vol. 06, no. 09, p. 6, 2019.
- [8] M. A. J. Hameed, "Android-based Smart Student Attendance System" Int. Res. J. Eng. Technol., vol. 12, pp. 2356–2395, 2017. Detection," in 2016 Online international conference on green engineering and technologies, 2016.
- [9] Basheer K. P. Mohamed, C.V. Raghu, "Fingerprint Attendance System for Classroom Needs," 2012 Annual IEEE India Conference, INDICON 2012, 2012, doi: 10.1109/INDCON.2012.6420657. <https://ieeexplore.ieee.org/abstract/document/6420657>
- [10] Chien-wen Shen, Yen-Chun Jim Wu, Tsung-Che Lee, "Developing a NFC-Equipped Smart Classroom: Effects on Attitudes Toward Computer Science" Computers in Human Behavior Volume 30 January 2014, Pages 731–738.
- [11] P. S. H. Smitha, "Face Recognition based Attendance Management System" Int. J. Eng. Res. & Technol., vol. 9, no. 05, 2020.
- [12] Atanu Shuvam Roy, Hong Lan, Mehdi Gheisari, Aqif AfzaalAbbasi, Ata Jahangir Moshayedi, Liefaliao, Seyed Mojtaba Hosseini Bamakan, "Automation Attendance Systems Approaches: A Practical Review," BOHR Int. J. Internet Things Res., vol. 1, no. 1, pp. 7–15, 2022.

- [13] Siti Aisah Mohd Noor, Norliza Zaini, Mohd Fuad Abdul Latip, Nabilah Hamzah, "Android-Based Attendance Management System," in 2015 IEEE Conference on Systems, Process and Control (ICSPC), 2015, pp. 118–122.
- [14] Yoganathan N. S., Raviteja S., Sathyanarayanan R., Anup Kumar, Nithish Kumar R. , "Location Based Smart Attendance System Using GPS" Ann. Rom. Soc. Cell Biol., vol. 25, no. 2, pp. 4510–4516, 2021, [Online]. Available: <http://annalsofrscb.ro>
- [15] Mubarak Salem Mubarak Alburaiki, Gapar Md Johar, Rabap Alayam Abbas Helmi, Mohammed Hazim Alkawaz, "Mobile Based Attendance System: Face Recognition and Location Detection using Machine Learning" in 2021 IEEE 12th Control and System Graduate Research Colloquium, , 07 July 2021, doi: 10.1109/ICSGRC53186.2021.9515221.
- [16] E. Varadharajan, R. Dharani, S. Jeevitha, B. Kavinmathi, and S. Hemalatha, "Automatic Attendance Management System using Face Detection" in 2016 Online international conference on green engineering and technologies, 2016.
- [17] Vidit Jain and Erik Learned-Miller, FDDB: A Benchmark for Face Detection in Unconstrained Settings. Technical Report UM-CS-2010-009, Dept. of Computer Science, University of Massachusetts, Amherst. 2010.
- [18] Kazemi Vahid and Josephine Sullivan. "One millisecond face alignment with an ensemble of regression trees." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2014.
- [19] Adam Geitgey "Modern Face Recognition with Deep Learning", <https://medium.com/@ageitgey/machine-learning-is-fun-part-4-modern-face-recognition-with-deep-learning-c3cffc121d78>
- [20] The 68 landmarks locate on every face. This figure was created by Brandon Amos of CMU who works on OpenFace. <https://bamos.github.io/>

Teknopark Firma Performanslarının Çok Kriterli Karar Verme Yöntemleriyle İncelenmesi

Yunus Özmodanlı^{*1}, Prof. Dr. Cevriye Temel Gencer^z

^{*1} Gazi Üniversitesi Yönetim Bilişim Sistemleri, ANKARA

^z Gazi Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü, ANKARA

(Alınış / Received: 02.09.2024, Kabul / Accepted: 19.11.2024, Online Yayınlanma / Published Online: 30.12.2024)

Anahtar Kelimeler

Teknoparklar,
AHP,
DEMATEL,
TOPSIS,
ENTROPİ

Öz: Teknoparklar, farklı ölçekteki firmaların inovasyon çalışmalarını sürdürdüğü yenilik ekosistemleri olarak, teknoloji gelişimi sağlayana hibrit mekanizmalardır. Teşvik ve destekler teknoparkta yer almayı firmalar için oldukça cazip hale getirirken, teknopark alanlarındaki fiziksel kapasite ise sınırlıdır. Teknoparklarda yer alan firmaların performanslarının değerlendirilmesi amacıyla literatür incelenmiş ve uzman görüşlerine başvurularak teknoparklarda yer alan firmalar için performans kriterleri belirlenmiştir. Belirlenen kriterlere göre oluşturulan komposit değişkenler ile çok kriterli karar verme (ÇKKV) yöntemlerinden, karar vericinin sürece dahil olmasını sağlayan AHP ve DEMATEL yöntemleri ve veriyi esas alan TOPSIS ve Entropi yöntemleri ile firmaların performansları ölçülmüştür. Genel ortalamalar üzerinden belirlenen bağıl ölçekte 0-15 puan alan firmalar başarısız, 16-30 puan alan firmalar zayıf; 30 ve üzerinde alan firmalar daha başarılı performans gösteren firmalar olarak kabul edilmiştir. Puanlar incelendiğinde firmaların belirlenen kriterleri karşılama güçlerinin zayıf olduğu değerlendirilmektedir.

Ayrıca sperman ikili korelasyon yöntemiyle veri setleri olarak her bir yöntemdeki firma sıralamaları alınmış ve yöntemler ikili olarak karşılaştırılmıştır. Sonuç olarak, karar vericiye bağlı yöntemler (AHP ve DEMATEL) ve veriye bağlı yöntemler (TOPSIS ve Entropi) genel olarak birbirleriyle yüksek korelasyonlar göstermektedir. Ancak, TOPSIS yöntemi, diğer yöntemlere göre biraz daha farklı sonuçlar üretebilmektedir. Genel anlamda, yöntemlerin çoğu arasında güçlü pozitif korelasyonlar olduğu gözlemlenmiştir, bu da yöntemlerin genellikle benzer sıralamalar ürettiğini göstermektedir.

Analyzing Technopark Company Performances with Multi-Criteria Decision Making Methods

Keywords

Technoparks
AHP,
DEMATEL,
TOPSIS,
ENTROPİ

Abstract: Technoparks are hybrid mechanisms that provide technological development as innovation ecosystems where companies of different sizes continue their innovation activities. While incentives and supports make being in a technopark quite attractive for companies, the physical capacity in technopark areas is limited. In order to evaluate the performance of companies in technoparks, literature was reviewed and performance criteria were determined for companies in technoparks by consulting expert opinions. The performances of companies were measured with composite variables created according to the determined criteria and AHP and DEMATEL methods that enable the decision maker to be involved in the process from multi-criteria decision-making (MCDM) methods, and TOPSIS and Entropy methods based on data. In the relative scale determined over the general

averages, companies with 0-15 points were considered unsuccessful, companies with 16-30 points were considered weak; companies with 30 and above were considered more successful. When the scores were examined, it was evaluated that the companies' ability to meet the determined criteria was weak. In addition, company rankings in each method were taken as data sets with the Sperman binary correlation method and the methods were compared pairwise. As a result, decision maker dependent methods (AHP and DEMATEL) and data dependent methods (TOPSIS and Entropy) generally show high correlations with each other. However, TOPSIS method may produce slightly different results than other methods. In general, strong positive correlations are observed between most of the methods, indicating that the methods generally produce similar rankings.

1. Giriş


Teknoloji geliştirme bölgeleri veya teknopark olarak adlandırılan yapılar bilgi ekonomisinin dayattığı ihtiyaçlarla, ilk olarak Amerika Birleşik Devletleri'nde ortaya çıkmıştır. ABD'de Stanford Üniversitesi'nde çalışan bir grup insanın iş fikirlerini ticarileştirme hedefi, bu süreci başlatmıştır. 1950 yılında ortaya çıkan teknopark kavramı, bugün Silikon Vadisi olarak bilinen inovasyon merkezinin gelişimini tetiklemiştir [1].

İlk olarak Stanford Araştırma Merkezinde ortaya çıkan Silikon Vadisi, teknopark kümelenmelerinin öncülleri arasında yer almaktadır. Günümüzde yüksek ciroya sahip binlerce teknoloji firması ve yüz binlerce çalışanı barındıran yapının kuruluşundan itibaren girişimciler, risk sermayesi mekanizması sayesinde Stanford Üniversitesi'ndeki akademik bilgi ile sanayi kuruluşları arasında iş birliği yapmışlardır. Akademik bilginin ticarileşmesi talebiyle oluşan bu yapı dünya genelindeki oluşumlara öncü olmuş, bugün adını sıkça duyduğumuz yüzlerce büyük teknoloji firmasının doğuşuna ve gelişimine ev sahipliği yapmıştır [2].

Fransız Rivierası'nda ise 1969 yılında bölgesel ve ekonomik kalkınmayı hızlandırmak amacıyla bir sivil toplum kuruluşunun liderliğinde ilk teknopark yapılanması (Sophia Antipolis) kurulmuştur. Britanya'da işsizlik ve ortaya çıkan sanayiye bağlı problemler küçük orta işletmelerin teknolojik açıdan desteklenmesini gerektirmiştir. Yenilikçi ürünler arayışında sanayi-üniversite ilişkisinin güçlenmesi sonucu 1972 yılında Edinburgh'ta Herriot-Watt ve Cambridge adında ilk teknopark kurulmuştur [3]. Avrupa'nın diğer güçlü ekonomisi Almanya'da ise yeni teknoloji firmalarının desteklenmesi amacıyla, Berlin Teknik Üniversitesi öncülüğünde Berlin Yenilik Merkezi kurulmuş ve 1985 yılına gelindiğinde bu merkez bir teknopark yapısına dönüşmüştür.

Uzak Doğu'da ise Japonya'da teknoparklar ön plandadır [4]. 1970'lerin başında Tsukuba Bilim Parkı, bölgesel gelişime katkıda bulunmak amacıyla şehirden uzakta, sanayi ve üniversite iş birliği için çekici bir alan oluşturmak amacıyla kurulan Japonya'nın ilk teknoloji parklarından biridir [5]. Uzak Asya'nın güçlü ekonomik ve insan gücünü oluşturan Çin ve Hindistan'da ise teknoparklar daha geç bir dönemde, 1980'lerin sonrasında kurulmuştur [6]. Rusya'da ise ilk başta 1990 yılında Tomsk şehrinde Tomsk Bilim ve Teknoloji Parkı kurulmuş; sonrasında üniversitelerin öncülüğünde kısa sürede birçok yerde teknoparklar kurulmuştur [7].

Türkiye'de teknoparklar ilgili kanun ile kurulurken (2001) ilgili devlet destekleriyle birer birer üniversiteler bünyesinde ortaya çıkmıştır [8]. Bu süreçte teknoloji firmalarının ve teknoloji çalışmalarının bir kümelenme içinde, sinerji ortamında gelişimi ve ticarileşmesi, teknoloji kökenli firmaların ülke içinde tutulmasına yönelik bir adım olmuştur. Ayrıca, tersine beyin göçü ile nitelikli eğitime sahip vatandaşların ülkeye dönüşü için fırsatlar ortaya çıkmıştır. Ek olarak, akademisyenlerin firma kurmasına olanak sağlanarak akademisyen girişimciliğinin önü açılmıştır. Şubat 2024 verilerine göre 2.527 akademisyen firması bulunmaktadır. Bu firmalar, toplam firmalar içindeki oranı yaklaşık olarak beşte bir kadardır [9]. Teknoloji Geliştirme Bölgelerinin sayısının özellikle son yıllarda hızla arttığı gözlenmiştir. 2001 yılında sadece 2 olan Teknoloji Geliştirme Bölgesi sayısı 2020 yılsonu itibarıyla 86'ya ve 2023 yılı Ağustos ayı itibarıyla 100'e ulaşmıştır [9]. Şekil 1'de yıllar itibarıyla Teknopark sayıları verilmektedir.



Şekil 1. Türkiye'de teknopark sayıları

Sanayi ve Teknoloji Bakanlığı'nın Şubat 2024 verilerine göre, ülkemizde ilan edilen 101 teknoparktan 89'u aktif durumda olup, bu teknoparklarda toplamda 10.000'den fazla firma ve yaklaşık 90.000'i Ar-Ge personeli olmak üzere 107.000 civarında çalışan bulunmaktadır [9].

Türkiye'deki Teknoloji Geliştirme Bölgeleri'nde faaliyet gösteren firmalar, yürüttükleri Ar-Ge, tasarım ve yazılım projeleri için çeşitli indirim ve muafiyetler ile desteklenmektedir. Sanayi ve Teknoloji Bakanlığı, bu bölgelerin kurumsal yapısını desteklemek amacıyla hibe destekleri sunmaktadır. Bu muafiyetler ve destekler arasında Gelir ve Kurumlar Vergisi Muafiyeti, Gelir Vergisi Stopajı Desteği, Gümrük Vergisi Muafiyeti, Damga Vergisi Muafiyeti, Katma Değer Vergisi Muafiyeti ve Sigorta Primi İşveren Hissesi Desteği bulunmaktadır. Ayrıca, Temel Bilim İstihdamı ve Doktora Mezunu Ar-Ge personeli istihdamında sağlanan hibe destekleri de mevcuttur. Teknoparklarda yer almak, firmalara proje bitirme belgesi ile Teknolojik Ürün Belgesi başvurusu yapabilme, ithal eşya taleplerinde kolaylık sağlama, akademi ve diğer teknoloji firmalarıyla işbirliği yapma ve prestij gibi birçok avantaj sunmaktadır. Ancak, teknoparklarda sınırlı kiralanabilir alan bulunması nedeniyle birçok firma bu alanlarda yer almak için beklemektedir.

Teknopark Yönetici A.Ş., bünyesindeki Ar-Ge firmalarının seçiminde ve devamlılığında proje komisyon değerlendirmesi ve kurul onayı süreçlerini yürütmektedir. Proje bazlı seçimlerde firmaların mevcut yeterliliklerinden ziyade proje değerlendirmesi esas alınmaktadır. Buna karşın mevcut firmaların devamlılığının sürdürülmesi, teknoparklarda kapasite sorunları nedeniyle birçok genç ve donanımlı firmanın dışarıda kalmasına sebep olabilmektedir. Aynı zamanda mevcut firmaların devamlılığı proje bazlı değerlendirildiğinden, firmanın ekosisteme katkısı yeterince ölçülememektedir.

Teknoparklarda yer alan firmalar vergi muafiyetlerinden yararlanmaktadır. Kamu yararı açısından, bu muafiyetlerden faydalanan firmaların faaliyetlerinin ekosisteme katkıları da değerlendirilmelidir. Mevcut sistemde ise bu değerlendirme yeterli düzeyde yapılmamakta, proje bazlı değerlendirme ön planda tutulmaktadır. Milli Ar-Ge ve Teknoloji hedeflerine ulaşmak ve teknopark etkinliklerini artırmak için, firmaların inovasyon performanslarının ölçülmesi gerektiği değerlendirilmektedir.

Çalışma kapsamında, teknoparklarda faaliyet gösteren firmaların performans başarı ölçütlerinin belirlenmesi ve belirlenen başarı ölçütlerine göre firma performanslarının ÇKKV yöntemleri kullanılarak değerlendirilmesi amaçlanmıştır. Bu sayede;

- ✓ Özellikle yüksek vergi muafiyeti sağlayan fakat yaygın etkisi ölçülemeyen firmaların durum tespiti yapılacaktır;
- ✓ Ulusal teknoloji ve yenilik ekosistemine katkı sağlayabilecek firmaların teknoparklarda yer almasını sağlayabilecek bir modelin ilk basamağı oluşturulacaktır;
- ✓ Ulusal teknoloji ve yenilik ekosistemine yeterli ölçüde katkı sağlayamayan firmaların teşvik sisteminden çıkarılmasına olanak sağlanacaktır.

Literatürde 2010 yılı ve sonrasındaki teknopark firmaları, yönetici firmalar ve firma performansları ile ilgili öne çıkan çalışmalar incelenmiştir. Ulusal çalışmalarda Baykul [10] ve Demirel [11], Türkiye'de teknopark yönetici şirketleri ile TR42 Doğu Marmara Bölgesi'ndeki bilişim firmalarının performanslarını Veri Zarflama Analizi (DEA) kullanarak değerlendirmiştir. Çakır [12], teknoloji sektöründe yer alan firmaların etkinliğini Bulanık Veri Zarflama Analizi (BVZA) ile ölçerken, Karagöz [13] üniversitelerin girişimcilik ve yenilik performanslarını analiz etmiştir. Güzel ve Ünlü [14] Teknoloji Geliştirme Bölgelerinin Ar-Ge, yönetim ve ekonomik etkinliklerini iki aşamalı veri zarflama analizi ile değerlendirirken; Önal [15] TR42 Doğu Marmara Bölgesi'nin performansını CRITIC tabanlı WASPAS ve SAW yöntemleriyle analiz etmiştir. Ayrıca, Hatice Batmantaş [16]. Teknoparkların bölgesel

kalkınmaya etkilerini incelerken, Akal Yılmaz, [17] teknopark yönetici şirketlerinin işbirliği alternatiflerini Bulanık Analitik Hiyerarşi Süreci (BAHP) ile değerlendirmiştir. Furkan Çiftçi [18] ise Türkiye'deki teknoloji transfer ofislerinin (TTO) performansını ölçmek için yeni kriterler geliştirmiştir.

Uluslararası çalışmalarda Bigliardi vd. [19] ve Fukugava [20], İtalya ve Japonya'daki bilim parklarının teknoloji firmalarına sunduğu katma değeri incelemiştir. Albahari ve arkadaşları [21], İtalya'daki ve İspanyadaki ulusal bilim parkları sistemlerini incelerken; Sohn ve Kim [22], Koreli start-up firmalar için teknoloji kredi puanlama sistemi geliştirirken, Yu vd. [23]. Çin'deki teknoloji firmaların inovasyon performansını incelemiştir. Da Silva ve arkadaşları [24]. Brezilya'daki teknoparklar için performans kriterlerinin doğrulamasını araştırırken; Kharabsheh [25]. Avustralya teknoparkları için kritik başarı faktörlerini araştırmıştır. Bu çalışmalar, bilim parklarının firmalara sunduğu çok boyutlu katkıları kapsamlı şekilde ortaya koymaktadır. Diğer yandan Yılında Guadix ve arkadaşları [26] da yapmış oldukları çalışmada teknopark performansları ile ilgili yapılan çalışmaları derlemişlerdir. Tablo'1 de literatürdeki çalışmalar ve mevcut çalışmanın içeriği ile ilgili bilgiler yer almaktadır.

Tablo 1. Literatürdeki çalışmalar ve mevcut çalışmanın içeriği

| | Yazarlar | Teknoloji Firması Performans Kriteri/ Ölçümü | Yönetimsel Etkinlik | Pratik Uygulama |
|-------------------------|---------------------------|--|---------------------|-----------------|
| Ulusal | Baykul (2015) | ✓ | ✓ | x |
| | Demirel (2015) | ✓ | ✓ | x |
| | Çakır (2015) | x | ✓ | x |
| | Karagöz (2020) | ✓ | ✓ | x |
| | Dilşad Akal Yılmaz (2022) | ✓ | ✓ | x |
| | Tuğba Güzel (2023) | ✓ | x | x |
| | Müge Önal (2023) | x | ✓ | x |
| | Furkan Çiftçi (2023) | ✓ | ✓ | x |
| Hatice Batmantaş (2024) | x | x | x | |
| Uluslararası | Bigliardi vd. (2006) | ✓ | ✓ | x |
| | Fukugava (2006) | ✓ | ✓ | x |
| | Sohn ve Kim (2012) | ✓ | ✓ | x |
| | Kharabsheh (2012) | ✓ | x | x |
| | Albahari vd (2013) | x | ✓ | x |
| | Guadix vd. (2016) | ✓ | x | x |
| | Yu vd. (2021) | ✓ | x | ✓ |
| | Da Silva (2023) | x | x | x |
| | Yapılan Çalışma | ✓ | ✓ | ✓ |

2. Materyal ve Metot

2.1. Teknopark Firmaları İçin Performans Kriterleri ve Kompozit Göstergelerin Oluşturulması

Dünya genelinde inovasyon çıktılarının ölçülmesine dair pek çok çalışma yapılmakta ve bu konuda farklı yaklaşımlar sergilenmektedir [27]. Teknoloji Geliştirme Bölgeleri ve firmalarının performanslarının ölçülmesi de temelde bu yaklaşımlara dayanmaktadır, ancak farklı değerlendirme kriterlerinin de önemli olduğu görülmektedir. Guadix ve arkadaşları [26], yaptıkları çalışmada teknoparklardaki performans kriterleri ile ilgili literatürü taramış ve öne çıkan kriterleri ortaya koymuşlardır.

Çalışmada, Guadix ve arkadaşlarının [26] belirlediği kriterler doğrultusunda, teknopark yöneticileri ve bakanlık uzmanlarına Türkiye Teknopark Ekosistemi için bu kriterlerin uygun olup olmadığı ve ek kriter gerekip gerekmediği sorulmuş, bu konuda uzman görüşleri alınmıştır. Bu doğrultuda performans kriterlerinin "İşbirlikleri, Projeler ve Çıktılar", "Ar-Ge Gelir ve Harcamaları" ve "Büyüme, Uzmanlaşma ve Nitelikli İstihdam" olmak üzere üç ana başlık altında toplanması görüşü öne çıkmıştır. Ayrıca, Türkiye teknopark ekosistemi için kriterlerin firma ölçeklerine göre değerlendirilmesi gerektiği belirtilerek, bu kriterler arasında yer almayan ticarileşme ile ilgili yeni alt kriter önerileri de sunulmuştur. Sonuç olarak teknoparklarda yer alan firmalar için performans kriterleri üç ana başlık altında 13 kriter olarak belirlenmiştir. Yine uzman görüşü doğrultusunda Fikri Mülkiyet Hakkı edinimi

ve ihracat ile ilgili kriterlerin, gerçekte sayının azlığı ve farklı yıllarda ihracat ile ilgili verilerin değişkenliği nedeniyle ayrıca değerlendirilmesi gerektiği görüşüne varılmıştır. Ortaya çıkan kriterler Tablo 2’de verilmektedir.

Tablo 2. Kriterler

| | |
|---|---|
| 1-İşbirlikleri, Projeler ve Çıktılar | 1.Toplam İşbirliği |
| | 2.Toplam Proje Sayısı /Toplam Ar-Ge Personeli |
| | 3.Toplam Ar-Ge Personel Sayısı/Devam Eden Proje Sayısı |
| 2-Ar-Ge Gelir ve Harcamaları | 4.Toplam Ar-Ge Harcaması /Toplam Ar-Ge Personel Sayısı |
| | 5. Toplam Ar-Ge Geliri /Toplam Ar-Ge Personel Sayısı |
| | 6. Alınan Destek Fonları /Teknoparkta Geçirilen Süre |
| | 7. Ticarileşen Projeler Toplam Geliri /Tamamlanan Proje Sayısı |
| | 8. Ticarileşen projeler Toplam Geliri |
| | 9. Ticarileşen Proje Sayısı (Ar-Ge Gelir ve Harcamaları) |
| 3-Büyüme, Uzmanlaşma ve Nitelikli İstihdam | 10.Doktoralı Personel Sayısı /Toplam Ar-Ge Sayısı |
| | 11. Kadın Ar-Ge-Personeli Sayısı/Toplam Ar-Ge Personeli Sayısı |
| | 12. Ticarileşme Oranları |
| | 13. Büyüme İstihdam (Ar-Ge Personeli Sayısı /Teknoparkta Geçirilen Yıl) |

Kompozit göstergeler birden fazla bireysel göstergenin belirli bir yöntemle göre birleştirilmesiyle oluşturulan ve karmaşık, çok boyutlu fenomenleri tek bir ölçüt ile ifade eden ölçüm araçlarıdır. Bu tür göstergeler, ekonomik, sosyal, çevresel veya kurumsal performansın genel bir resmini sunar ve karşılaştırmaların daha kolay yapılmasını sağlar [28]. Çalışmada oluşturulan kriter seti teknopark firmalarının farklı alanlardaki verileri /performanslarını tek düzlemde ölçebilmesi açısından bu kapsamda değerlendirilmiştir.

Kompozit göstergelerin oluşmasında pratik açıdan üç aşamanın olduğu belirtilmiştir [29]. Bu aşamalar:

- Normalizasyon,
- Ağırlıklandırma,
- Aggregation (Birleştirme-Sıralama/ Toplama).

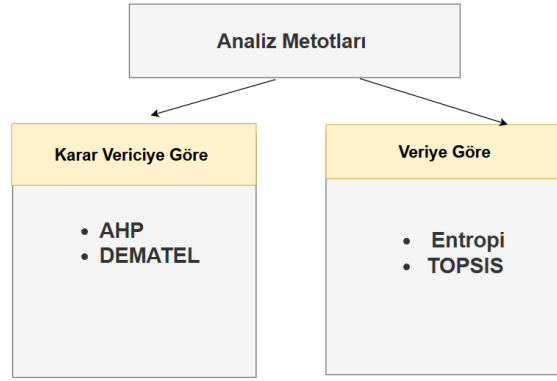
Ayrıca bu değişkenlerin ağırlıklandırılmasından sonra birleştirme-sıralama/ toplama aşaması için beş yaklaşımın ön plana çıktığı belirtilmiştir. Bu yaklaşımlar:

1. Temel Yöntemler: Simple Additive Weighting (SAW), Basit Ağırlıklandırma ve Weighted Product (WP) Ağırlıklandırma gibi yöntemler,
2. Değer ve Fayda Temelli Yöntemler: MAUT MAVT, SMART, MACBETH, DEMATEL gibi yöntemler (karar vericilerin değer yargılarına dayalı olarak her bir alternatifle gerçek bir sayı ilişkilendirme ve alternatifler için bir tercih sıralaması üretme),
3. Üstünlük İlişkisi Yaklaşımı (a alternatifi b ye göre durumu): ELECTRE, PROMETHEE gibi yöntemler
4. Veri Zarflama Yöntemi,
5. Uzaklık Temelli Yaklaşımlar: Gri İlişkisel Yöntem, TOPSIS gibi yöntemler.

2.2. Çok Kriterli Karar Verme

ÇKKV yöntemleri, karar verme süreçlerinde kullanılan farklı yaklaşımları ifade eder. Bu yöntemler, karar vericilerin çok sayıda ve genellikle birbiriyle çelişen kriterleri değerlendirerek en iyi kararı vermelerine yardımcı olmayı amaçlar.

Çalışmada elde edilen verilerin normalizasyonundan sonra ağırlıklandırma ve sıralama ile ilgili iki görüş ön plana çıkmaktadır. İlk görüş karar vericilerin görüşleri doğrultusunda ağırlıkların ve sıralamanın yapıldığı yöntemler, ikinci görüş ise verilere göre ağırlıkların ve sıralamanın yapıldığı yöntemlerdir. Çalışmada ağırlıklandırma ve sıralama için kullanılan yöntemler Şekil 1’de görülmektedir.



Şekil 1. Kullanılan yöntemler

Çalışmada verilerin normalizasyonundan sonra karar vericinin dahil olduğu değerlendirmede AHP ve DEMATEL yöntemleriyle ağırlıklandırma yapılmış ve elde edilen ağırlıklarla firma puanları hesaplanmıştır. Veriye göre değerlendirmede ise hem Entropi yöntemiyle ağırlıklandırma yapılarak elde edilen ağırlıklarla hem de Entropi yönteminden gelen ağırlıklar kullanılarak TOPSIS yöntemi ile firma puanları hesaplanmıştır. Böylece reel verileri veriden gelen bilgi ve karar vericinin görüşünden gelen bilgiyle, yani kriter ağırlıklarıyla değerlendirilerek performans ölçümü yapılmıştır. Çalışmada kullanılan yöntemlerle ilgili bilgiler aşağıda verilmiştir.

2.2.1. Entropi

Entropi yöntemi, bilgi teorisine dayanarak kriterlerin ağırlıklarını belirler. Bu yöntem, her bir kriterin belirsizlik seviyesini hesaplar ve belirsizliği en düşük olan kriterlerin daha önemli olduğunu varsayar. Böylece, objektif bir şekilde kriterlerin ağırlıkları belirlenir [30]. ÇKKV yöntemlerden biridir ve belirli kriterler altında çeşitli alternatiflerin değerlendirilmesi ve en uygun seçeneğin belirlenmesi için kullanılır. Bu yöntem, karar verme sürecinde kriterlerin ağırlıklarının hesaplanmasında önemli bir rol oynar. Entropi yönteminin adımları aşağıda verilmektedir[31]:

- Karar Matrisi Oluşturma:

Karar matrisi, her bir alternatife her bir kriter altında aldığı değerlerin düzenlendiği bir tablo oluşturulur:

$$X = \begin{pmatrix} X_{11} & X_{12} & \dots & X_{1n} \\ X_{21} & X_{22} & \dots & X_{2n} \\ \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \dots & \vdots \\ X_{m1} & X_{m2} & \dots & X_{mn} \end{pmatrix} \quad (1)$$

- Normalizasyon:

Verilerin karşılaştırılabilmesi için karar matrisi normalleştirilir. Genelde aşağıdaki formül kullanılır:

$$r_{ij} = \frac{X_{ij}}{\sum_{i=1}^m X_{ij}} \quad (2)$$

Burada r_{ij} normalleştirilmiş değerlerdir [30-32].

- Entropi Değerlerinin Hesaplanması:

Her bir kriter için Entropi değeri hesaplanır. Entropi değeri, kriterlerin bilgi miktarını ve belirsizliğini ölçer. Entropi hesaplama formülü:

$$e_j = -k \sum_{i=1}^m r_{ij} \ln(r_{ij}) \quad (3)$$

Burada k, normalizasyon sabitidir [32] ve genellikle;

$$k = \frac{1}{\ln(m)} \quad (4)$$

formülüyle ifade edilir .

- Bilgi İçeriği

Kriterlerin bilgi içeriği veya çeşitliliği hesaplanır.

$$d_j = 1 - e_j (\%) \quad (5)$$

- Kriter Ağırlıklarının Hesaplanması:

Kriter ağırlıkları, her bir kriterin bilgi içeriğinin toplam bilgi içeriğine oranı olarak hesaplanır:

$$w_j = \frac{1 - e_j}{\sum_{j=1}^n 1 - e_j} \quad (6)$$

- Karar Matrisinin Ağırlıklı Normalize Edilmesi:

Normalize edilmiş karar matrisi, kriter ağırlıkları ile çarpılarak ağırlıklı normalize edilmiş karar matrisi elde edilir.

$$v_{ij} = r_{ij} \cdot w_j \quad (7)$$

- Alternatiflerin Skorlanması ve Sıralanması:

Her bir alternatif için toplam skor hesaplanır. Toplam skor, alternatifin ağırlıklı normalize edilmiş değerlerinin toplamıdır.

$$S_i = \sum_{j=1}^n v_{ij} \quad (8)$$

2.2.2. TOPSIS Yöntemi

TOPSIS (Technique for Order of Preference by Similarity to Ideal Solution) yönteminde alternatiflerin ideal çözümlere mesafeleri hesaplanır. Ardından alternatifler, bu uzaklıkların oranlarına göre sıralanır. Son olarak, en uygun olanı seçilir [33]. TOPSIS yöntemi, karar verme problemlerinde alternatiflerin ideal çözümlere göre sıralanmasında kullanılır ve özellikle performans değerlendirmesi gerektiren ÇKKV durumlarında etkilidir [34]. 1981 yılında Hwang ve Yoon tarafından geliştirilmiştir. Bu yöntemde, karar verme problemi için alternatiflerin ideal çözümlere olan benzerlikleri ölçülerek sıralama yapılır. Yöntemin temel aşamaları aşağıdaki gibidir [35]:

- Kriterlerin ve Alternatiflerin Belirlenmesi:

Karar verme problemi için kriterler ve bu kriterlere göre değerlendirilecek alternatifler belirlenir.

- Normalizasyon:

Alternatiflerin performans değerleri normalleştirilir. Bu aşamada, farklı ölçeklerdeki verilerin karşılaştırılabilir hale getirilmesi sağlanır. Genellikle 0 ile 1 arasında değerler elde edilir.

- İdeal ve Negatif İdeal Çözümlerin Belirlenmesi:

Pozitif ideal çözüm (A^+) ve negatif ideal çözüm (A^-) belirlenir.

A^+ için her bir kriterde maksimum performans değeri, A^- için ise her bir kriterde minimum performans değeri kullanılır [3].

- Alternatiflerin Pozitif ve Negatif İdeal Çözümlere Olan Yakınlığının Hesaplanması:

Her alternatif için pozitif ideal çözüme olan uzaklıklar Euclidean (Öklid) uzaklık formülleri yardımıyla hesaplanır.

$$d^+ (A_i) = \sqrt{\sum_{j=1}^m (x_{ij} - A_j^+)^2} \quad (9)$$

$$d^- (A_i) = \sqrt{\sum_{j=1}^m (x_{ij} - A_j^-)^2} \quad (10)$$

- Yakınlık Skorlarının Hesaplanması:

Seçeneklerin, ideal çözüme uzaklıkları dikkate alınarak bir yakınlık skoru ile değerlendirilir:

$$C_i = \frac{d^-}{d^+ + d^-} \quad (11)$$

Bu skor, alternatifin pozitif ideal çözüme olan yakınlığını ölçer. En yüksek C skoruna sahip alternatif, en çok tercih edilen alternatif olarak kabul edilir.

2.2.3. AHP Yöntemi

AHP (Analitik Hiyerarşi Süreci) yöntemi, kriter ve seçenekler ve alternatifler arasındaki öncelik ve önem derecelerini belirlemede kullanılır. İkili karşılaştırmalar yaparak bu değerler sözel olarak belirlenir belirlenir ve sonrasında bu veriler matematiksel olarak analiz edilir [36]. AHP, bir seçim metodolojisi olarak kullanıldığı gibi, karmaşık yapıların yapılandırılması ve ölçek oluşturulması için de bir araçtır. Bu nedenle AHP metodolojisinde kriterlerin ağırlıklandırılması, girişimci için karar verme sürecinde kritik bir rol oynar [37]. AHP'nin teorik temeli dört aksiyoma dayanmaktadır. Bu önermeler arasında önem derecelerinde karşılıklı ilişkisi bulunması, herhangi iki kriterin karşılaştırılmasında sonsuz önemin olmadığı, kriterlerin ve alternatiflerin bağımsız bir yapıda olduğu ve hiyerarşik bir yapıda sunulabileceği vurgulanır [38].

Bu çalışmada, belirlenen alt kriterler arasında doğrudan ilişki olmadığı varsayımıyla hareket edilmektedir. Ancak bu kriterlerin, çeşitli varsayımlar veya kabullerle dolaylı olarak bir ilişki içinde olabileceği göz önünde bulundurulabilir. Yöntem, kriterlerin ağırlıklandırılmasında aşağıdaki adımları izler [38]:

- Modelin Belirlenmesi:

AHP problemine konu olan kriterlerin ve karar noktalarının belirlenmesi sağlanır.

- Karşılaştırma Matrisinin Oluşturulması:

Karşılaştırma matrisi, nxn boyutlu bir kare matristir. Bu matris;

$$A = \begin{pmatrix} a_{11} & a_{12} & \cdot & \cdot & \cdot & a_{1n} \\ a_{21} & a_{22} & \cdot & \cdot & \cdot & a_{2n} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ a_{n1} & a_{n2} & \cdot & \cdot & \cdot & a_{nm} \end{pmatrix} \quad (12)$$

şeklinde gösterilir. Kriterlerin kıyaslanması yapılmaktadır. Köşegen değerleri, 1'dir ve bu değer ilgili alternatifin ya da kriterin kendisiyle kıyaslanması sonucunda ortaya çıkmıştır. Bu kıyaslamaların sayısal değerleri Tablo 3'e göre gerçekleştirilir. Bu sayede uzman görüşünün sözel ifadesi sayısal karşılık bulmuş olur [39].

Tablo 3. AHP yöntemi/sözel ifade ve değerler

| Önem Değerleri | Değer Tanımları |
|----------------|---|
| 1 | Her iki faktörün eşit öneme sahip olması durumu |
| 3 | i. Faktörün j. faktörden daha önemli olması durumu |
| 5 | i. Faktörün j. faktörden çok önemli olması durumu |
| 7 | i. Faktörün j. faktöre nazaran çok güçlü bir öneme sahip olması durumu |
| 9 | i. Faktörün j. faktöre nazaran mutlak üstün bir öneme sahip olması durumu |
| 2,4,6,8 | Ara değerler |

- Normalleştirilmiş Matris Oluşturulması:

Karşılaştırma Her sütun kendi sütunundaki elemanların toplamına bölünerek hesaplanır

(13)

$$X = \begin{bmatrix} b_{11} \\ b_{21} \\ \cdot \\ \cdot \\ \cdot \\ b_{n1} \end{bmatrix} \quad b_{ij} = \frac{b_{ij}}{\sum_{i=1}^n b_{ij}}$$

formülüyle gerçekleştirilir.

- Önem vektörünün oluşturulması:
Oluşturulan normalleştirilmiş matris (C);

$$C = \begin{bmatrix} c_{11} & c_{12} & \cdot & \cdot & \cdot & c_{1n} \\ c_{21} & c_{22} & \cdot & \cdot & \cdot & c_{2n} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ c_{n1} & c_{n2} & \cdot & \cdot & \cdot & c_{nn} \end{bmatrix} \quad (14)$$

şeklinde gösterilir. Bu matriste her bir satırın ortalaması alınarak öncelik vektörü (W)

$$W = \begin{bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ \cdot \\ w_n \end{bmatrix} \quad (15)$$

şeklinde oluşturulmuştur. Bu vektördeki değerler kriterlere ait önem ağırlıklarıdır.

- Tutarlılığın Ölçülmesi:
Karşılaştırma matrisi ile öncelik vektörünün çarpılması sonucu elde edilen matris için;

$$\lambda = \frac{\sum_{i=1}^n E_i}{n} \quad (16)$$

formülü yardımıyla karşılaştırma değeri olan (λ) bulunur. Bu çarpım:

$$D = \begin{bmatrix} a_{11} & a_{12} & \cdot & \cdot & \cdot & a_{1n} \\ a_{21} & a_{22} & \cdot & \cdot & \cdot & a_{2n} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ a_{n1} & a_{n2} & \cdot & \cdot & \cdot & a_{nn} \end{bmatrix} \times \begin{bmatrix} w_1 \\ w_2 \\ \cdot \\ \cdot \\ \cdot \\ w_n \end{bmatrix} \quad (17)$$

biçiminde ifade edilmiştir.

- Tutarlılık indeksi, CI

$$CI = \frac{\lambda - n}{n - 1} \quad (18)$$

formülüyle hesaplandıktan sonra indeks değerine bölünerek oran hesaplanır(CR). $CR=CI/RI$ olarak hesaplanır. Buradaki RI (Rastgelelik İndeksi) değeri Tablo 4 'ten elde edilir [40].

Tablo 4. Rastgelelik İndeksi

| n | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 |
|----|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|
| RI | 0,00 | 0,00 | 0,58 | 0,90 | 1,12 | 1,24 | 1,32 | 1,41 | 1,45 | 1,49 | 1,51 | 1,48 | 1,56 | 1,57 | 1,59 |

2.2.4. DEMATEL Yöntemi

DEMATEL (Decision Making Trial and Evaluation Laboratory) yönteminde, karar vericilerin uzmanlık ve deneyimlerine dayanarak kriterler arasındaki etkileşimler belirlenir. Bu yöntem, kriterler arasındaki doğrudan ve dolaylı ilişkileri tespit eder ve bu ilişkiler grafik halinde görselleştirilir [42]. DEMATEL yöntemi, karmaşık karar verme problemlerini analiz etmek ve ilişki ağırlıklarını belirlemek için kullanılan bir ÇKKV yöntemidir. DEMATEL yönteminin aşamaları aşağıda tanımlanmaktadır:

- Problem Yapısının Belirlenmesi:

İlk adım olarak, karar verme problemi için yapının belirlenmesi gereklidir. Bu aşamada genellikle bir hiyerarşik yapı oluşturulur ve problem kriterleri tanımlanır.

- İlişki Matrisinin Oluşturulması:

Belirlenen kriterler arasındaki karşılıklı etkileşimlerin analiz edilmesi için bir ilişki matrisi oluşturulur. Bu matris, kriterler arasındaki ilişkilerin varlığını ve gücünü gösterir [41]. Bu matris oluşturulurken kullanılan skala Tablo 5'de verilmiştir:

Tablo 5 DEMATEL değerlendirme skalası

| Tanım | Değer |
|--------------------------|-------|
| Etkisiz | 0 |
| Düşük etki | 1 |
| Orta derecede etki | 2 |
| Yüksek derecede etki | 3 |
| Çok yüksek derecede etki | 4 |

- İlişki Matrisinin Normalize Edilmesi:

Oluşturulan ilişki ilişkilerin karşılaştırılabilmesi için standart hale getirilerek normalleştirilir.

- Toplam Etki ve Neden-Sonuç Analizi:

Normalize edilmiş matristen hareketle, her kriterin toplam etkisi ve neden-sonuç ilişkileri analiz edilir.

- Ağırlıkların Hesaplanması:

2.2.5. Yöntemlerin Değerlendirilmesi

AHP yöntemi, karar kriterlerine göre önceliklendirme yaparak, karar vericilerin her kriteri ve alternatif arasındaki çift yönlü karşılaştırmalarına dayalı bir ağırlıklandırma süreci sunar. Bu yöntemin avantajları arasında, çift yönlü karşılaştırma sayesinde karar vericinin tercihlerine uygun ağırlıklandırma yapılabilmesi ve sayısal olmayan niteliksel kriterlerin de hesaba katılabilmesi bulunur. Ancak, karmaşık kriter setlerinde sürecin uzun sürmesi ve yöntemin subjektif olması nedeniyle karar vericinin öznel değerlendirmelerine dayanması zayıf yönleri arasındadır [36-38].

DEMATEL yöntemi, kriterler arasındaki nedensel ilişkileri inceleyerek ağırlıkları belirler ve bu ilişkiler doğrultusunda kriterlerin birbirleri üzerindeki etkisini değerlendirir. Bu yöntemin avantajları, kriterler arasındaki etkileri belirleyerek daha derin bir analiz sunması ve karmaşık sistemlerde faktörler arası bağımlılıkları ortaya çıkararak hangi kriterlerin daha kritik olduğunu göstermesidir. Ancak, kriterler arasındaki etki derecelerini belirlemek zorlayıcı olabilir ve yöntem subjektif değerlendirmelere dayanabilir; ayrıca, kriterler arasındaki nedensel ilişkileri anlamak her durumda pratik olmayabilir [36, 42].

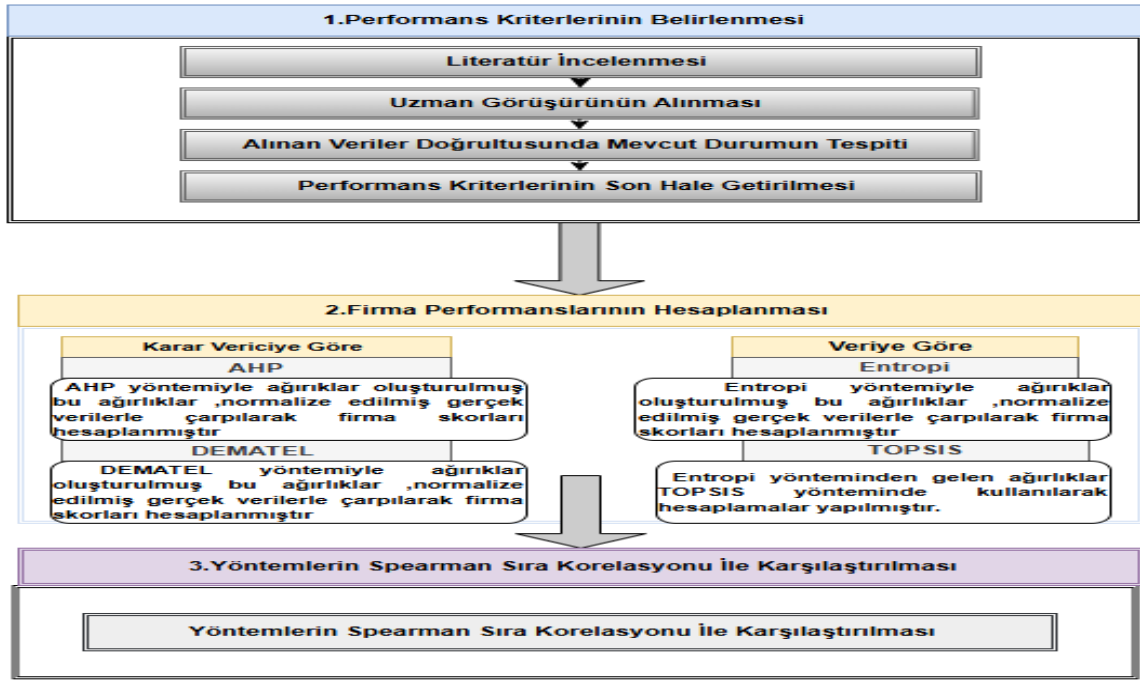
Entropi yöntemi, veri içindeki bilgilere dayalı olarak objektif ağırlıklar belirler ve kriterlerin kendi dağılımlarındaki bilgi miktarını kullanarak ağırlık hesaplaması yapar. Bu yöntemin avantajları, nesnel bir yapıya sahip olması ve karar vericinin subjektif değerlendirmelerini içermemesi, ayrıca veri odaklı olduğu için karar vericinin yorumu olmadan belirli bir güvenilirlik sunmasıdır. Ancak, kriterlerdeki değişkenliğin az olduğu durumlarda etkisiz kalabilir ve tamamen verilere dayalı olduğu için karar vericinin tercihlerine uygun olmayan sonuçlar ortaya çıkabilir [43].

TOPSIS yöntemi, ideal ve negatif ideal çözümlere olan mesafelere göre alternatifleri sıralayarak ağırlıklandırma yapar. Ağırlıklar genellikle başka bir yöntemle belirlenir, ancak doğrudan veri üzerinden hesaplanması veya karar verici tarafından belirlenmesi de mümkündür. Bu yöntemin avantajları arasında, ideal çözüme en yakın ve negatif çözüme en uzak alternatifin belirlenmesini sağlaması, basit, anlaşılır ve uygulaması kolay olması bulunmaktadır. Ancak zayıf yönleri arasında ağırlıkların belirlenmesi için genellikle başka bir yöntemle ihtiyaç duyması ve kriterlerin bağımsız olması varsayımıyla çalışması yer alır; bu nedenle, kriterler arasında ilişkiler varsa uygun olmayabilir. TOPSIS, hem objektif hem de subjektif kriterlerin olduğu durumlarda en iyi alternatifini belirlemek için tercih edilir. [35]. Yöntemlerde ağırlıklandırma ile ilgili karşılaştırma Tablo' 6 da verilmiştir.

Tablo 6 Kullanılan ÇKKV yöntemlerinin karşılaştırılması

| Yöntem | Ağırlıklandırma Türü | Avantajları | Dezavantajları |
|----------------|---|---|---|
| AHP | Karar vericinin tercihinine dayalı | Çift yönlü karşılaştırma, niteliksel kriterler | Subjektif, karmaşık kriterlerde uzun hesaplama |
| DEMATEL | Karar vericinin tercihi/Kriterler arası nedensel ilişkiler | Nedensel ilişkiler analizi, bağımlılıkları belirler | Subjektif, karmaşık kriterlerde uzun hesaplama |
| Entropi | Veri odaklı, objektif | Nesnel ağırlıklandırma, veri güvenilirliği | Düşük değişkenlikte az etki, karar verici tercihi yansıtmaz |
| TOPSIS | Genellikle başka bir yöntemle belirlenir, ya da doğrudan veri | İdeal çözüme yakınlık, Anlaşılır, alternatif sıralama | Kriter bağımsızlığı varsayımı, ağırlık belirleme ihtiyacı |

Performans metriklerinin oluşturulması aşamasında, önce literatür taraması yapılmış ve ardından uzman görüşleri alınarak metrikler belirlenmiştir. Metriklerin belirlenmesinin ardından, firma performanslarının hesaplanması adımına geçilmiş ve bu süreçte verilerin normalizasyonu, ağırlıklandırılması ve sıralaması yapılmıştır. Hesaplamalar, karar vericiye göre AHP ve DEMATEL yöntemlerinden elde edilen ağırlıklar kullanılarak 13 kritere ait normalize edilmiş değerlerin bu ağırlıklarla çarpılarak firmaların performans skorları elde edilmiştir. Ayrıca veriye göre Entropi yöntemi sonucunda elde edilen ağırlıklar kritere ait normalize edilmiş değerlerle çarpılarak Entropi ağırlıklarıyla firmaların performans skorları belirlenmiştir. Yine veriye göre Entropi yöntemiyle elde edilen ağırlıklar TOPSIS yönteminde kullanılarak firmaların performans skorları elde edilmiştir. Ardından Sperman ikili korelasyon yöntemiyle her bir yöntemdeki firma sıralamaları alınmış ve yöntemler ikili olarak karşılaştırılmıştır. Şekil 2'de çalışmanın aşamaları yer almaktadır.



Şekil 2 Çalışma akış şeması

3. Bulgular

Çalışmada, karar vericiye göre AHP ve DEMATEL yöntemlerinden elde edilen ağılıklar ve Entropi yöntemi sonucunda elde edilen ağırlıklar kullanılarak 13 kritere ait normalize edilmiş değerlerin bu ağırlıklarla çarpılarak firmaların performans puanları elde edilmiştir. Ayrıca TOPSİS yönteminde kritere ait normalize edilmiş değerler Entropi ağırlıklarıyla çarpılarak firmaların performans puanları belirlenmiştir. Yöntemlerle elde edilen puanlar incelendiğinde genel olarak firma performanslarının belirlenen metrikler açısından yeterli düzeyde olmadığı değerlendirilmiştir. Bu nedenle firmaların sınıflandırmasına karar verilmiş ve tüm yöntemler için firmaların min-max ve ortalama puanları hesaplanmıştır. Firmaların min-max ve ortalama puanları Tablo 7 de verilmiştir.

Tablo 7. Firmaların min-max ve ortalama puanları

| | AHP | DEMATEL | ENTROPİ | TOPSIS |
|-----------------|-------|---------|---------|--------|
| MİN | 4 | 6 | 4 | 4 |
| MAX | 62 | 54 | 58 | 53 |
| ORTALAMA | 15,92 | 16,8 | 16,5 | 15,5 |

Tablo 7 incelendiğinde yöntemlerin çoğunluğunda ortalamanın 15-16 civarında olduğu görülmektedir. Bu nedenle genel ortalamalar üzerinden belirlenen bağıl ölçekte 0-15 puan arası başarısız kabul edilip kırmızı renk ile gösterilmiştir. 16-30 puan alan firmalar zayıf olarak nitelendirilmiştir. Performanslarının düzeltilmesi gerektiği değerlendirilen bu firmalar sarı renk ile gösterilmiştir. 30 ve üzerinde alan firmalar performansı daha başarılı firmalar kabul edilmiş ve yeşil renk ile gösterilmiştir.

Kriterler belirlenirken uzmanlarla yapılan görüşmelerde son derece önemli olan "İhracat ve fikri mülkiyet" kriterleri de ön plana çıkmış ancak ihracat ve fikri mülkiyet ile ilgili veriler tüm firmalar tarafından sağlanamadığı için model içine dahil edilmesinin sakıncalı olacağı; kriterlerin ek başarı kriterleri olarak değerlendirilmesinin daha uygun olacağı, firmaların ayırt edici yönleri olarak vurgulanabileceği ve bu nedenle puan ve skordardan bağımsız olarak bu göstergelere sahip firmalara ayrıca kod verilmesinin uygun olacağı değerlendirilmiştir.

Uluslararası fikri mülkiyet edinimi B1, Ulusal fikri mülkiyet edinimi B2 olarak belirlenmiştir. İhracat rakamları ile ilgili olarak 1 milyon doların üstünde ihracat yapan firmalar A1 kategorisinde, 100 bin ile 1 milyon dolar arasında ihracat yapan firmalar A2 kategorisinde ve 100 bin altında ihracat yapan firmalar ise A3 kategorisinde değerlendirilmiştir. Daha sonraki hesaplamalarda da kullanılacak bu sınıflama Tablo 8'de toplu olarak şematize edilmiştir.

Tablo 8. Sınıflama

| Puana Göre | | Ek Kriterlere Göre | | | |
|------------|-------------|------------------------|-------|------------------------------|-------|
| Yeşil: Y | 30 ve üzeri | Fikri Mülkiyet Edinimi | Sınıf | İhracat Tutarı (ABD Doları) | Sınıf |
| Sarı: S | 16-29 | Uluslararası | B1 | > 1.000.000 | A1 |
| Kırmızı: K | 0-15 | Ulusal | B2 | 100.000-1.000.000 | A2 |
| | | | | <100.000 | A3 |

3.1. Entropi Bulguları

Mevcut veriler kullanılarak Entropi yöntemi ile ağırlıklandırma yapılmış ve veri ağırlıkları Tablo 9'da verildiği gibi elde edilmiştir.

Tablo 9 . Entropi ağırlık tablosu

| Kriterler | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 |
|----------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| Ağırlık | 0,023 | 0,044 | 0,053 | 0,044 | 0,089 | 0,014 | 0,056 | 0,082 | 0,103 | 0,155 | 0,085 | 0,153 | 0,099 |

Tablo 9 'daki ağırlıklar kullanılarak elde edilen Entropi sıralamaları Tablo 10'da verilmektedir.

Tablo 10. Entropi sonuçları

| Firma | Puan | Sınıf | Firma | Puan | Sınıf |
|----------|------|-------|----------|------|-------|
| Firma 01 | 7 | | Firma 21 | 16 | |
| Firma 02 | 7 | | Firma 22 | 19 | A1 |
| Firma 03 | 12 | | Firma 23 | 10 | |
| Firma 04 | 18 | | Firma 24 | 8 | |
| Firma 05 | 58 | A1/B2 | Firma 25 | 50 | B2 |
| Firma 06 | 7 | | Firma 26 | 7 | A1 |
| Firma 07 | 10 | | Firma 27 | 26 | |
| Firma 08 | 12 | | Firma 28 | 11 | |
| Firma 09 | 15 | | Firma 29 | 22 | |
| Firma 10 | 44 | | Firma 30 | 12 | A2 |
| Firma 11 | 13 | | Firma 31 | 15 | A3 |
| Firma 12 | 14 | | Firma 32 | 9 | A2 |
| Firma 13 | 7 | | Firma 33 | 25 | |
| Firma 14 | 30 | | Firma 34 | 17 | B1 |
| Firma 15 | 5 | | Firma 35 | 15 | |
| Firma 16 | 11 | | Firma 36 | 23 | |
| Firma 17 | 15 | A3 | Firma 37 | 4 | B2 |
| Firma 18 | 12 | | Firma 38 | 23 | |
| Firma 19 | 19 | | Firma 39 | 9 | |
| Firma 20 | 13 | | Firma 40 | 10 | |

Tablo 10 incelendiğinde, 4 firmanın yeşil kategoride, 12 firmanın sarı kategoride ve 24 firmanın kırmızı kategoride yer aldığı görülmektedir. Firmaların ortalama puanı 16,5' dir. Ayrıca 3 firma A1, 2 firma A2, 2 firma A3, 1 firma B1 ve 2 firma B2 kategorisinde yer almaktadır.

3.2. TOPSİS Bulguları

Entropi yönteminden elde edilen ağırlıklar kullanılarak TOPSİS yöntemi ile elde edilen sonuçlar Tablo 11'de verilmektedir.

Tablo 11. TOPSİS sonuçları

| Firma | Puan | Sınıf | Firma | Puan | Sınıf |
|----------|------|-------|----------|------|-------|
| Firma 01 | 7 | | Firma 21 | 12 | |
| Firma 02 | 5 | | Firma 22 | 14 | A1 |
| Firma 03 | 8 | | Firma 23 | 10 | |
| Firma 04 | 22 | | Firma 24 | 6 | |
| Firma 05 | 53 | A1 | Firma 25 | 42 | B2 |
| Firma 06 | 6 | | Firma 26 | 7 | A1 |
| Firma 07 | 10 | | Firma 27 | 19 | |
| Firma 08 | 12 | | Firma 28 | 9 | |
| Firma 09 | 14 | | Firma 29 | 24 | |
| Firma 10 | 38 | | Firma 30 | 18 | A2 |
| Firma 11 | 10 | | Firma 31 | 15 | A3 |
| Firma 12 | 11 | | Firma 32 | 5 | A2 |
| Firma 13 | 11 | | Firma 33 | 22 | |
| Firma 14 | 26 | | Firma 34 | 47 | B1 |
| Firma 15 | 4 | | Firma 35 | 11 | |
| Firma 16 | 9 | | Firma 36 | 19 | |
| Firma 17 | 13 | A3 | Firma 37 | 13 | B2 |
| Firma 18 | 11 | | Firma 38 | 17 | |
| Firma 19 | 14 | | Firma 39 | 8 | |
| Firma 20 | 10 | | Firma 40 | 9 | |

Tablo 11 incelendiğinde, 4 firmanın yeşil kategoride, 9 firmanın sarı kategoride ve 23 firmanın kırmızı kategoride yer aldığı görülmektedir. Firmaların ortalama puanı 15,5' dir. Ayrıca 3 firma A1, 2 firma A2, 2 firma A3, 1 firma B1 ve 2 firma B2 kategorisinde yer almaktadır.

3.3. AHP Bulguları

Verilerin ağırlıklandırılması AHP yönetimi ile gerçekleştirilmiştir. Buna göre belirlenen kriterlerin karşılaştırılması Bakanlıkta görevli 4 uzmanın ve 4 teknopark yöneticisinin girdileriyle gerçekleştirilmiş bu görüşler neticesinde ağırlık matrisi oluşturulmuştur. Buna göre karşılaştırma matrisi ve ortaya çıkan kriter ağırlıkları Tablo 12'de verilmiştir.

Tablo 12 Karşılaştırma matrisi ve kriter ağırlıkları

| Amaç | M1 | M2 | M3 | M4 | M5 | M6 | M7 | M8 | M9 | M10 | M11 | M12 | M13 | Ağırlık |
|------------|-----|----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|---------|
| M1 | 1 | 9 | 9 | 5 | 3 | 7 | 7 | 5 | 7 | 1/3 | 2 | 1/2 | 3 | 0,15 |
| M2 | 1/9 | 1 | 1/2 | 1/5 | 1/9 | 1/3 | 1/3 | 1/3 | 1/4 | 1/9 | 1/7 | 1/8 | 1/9 | 0,01 |
| M3 | 1/9 | 2 | 1 | 1/5 | 1/8 | 1/3 | 1/3 | 1/3 | 1/3 | 1/9 | 1/7 | 1/8 | 1/9 | 0,01 |
| M4 | 1/5 | 5 | 5 | 1 | 1/3 | 3 | 4 | 2 | 3 | 1/6 | 1/3 | 1/4 | 1/2 | 0,05 |
| M5 | 1/3 | 9 | 8 | 3 | 1 | 5 | 5 | 3 | 4 | 1/4 | 1/2 | 1/3 | 2 | 0,09 |
| M6 | 1/7 | 3 | 3 | 1/3 | 1/5 | 1 | 2 | 1/2 | 1/2 | 1/7 | 1/5 | 1/7 | 1/3 | 0,02 |
| M7 | 1/7 | 3 | 3 | 1/4 | 1/5 | 1/2 | 1 | 1/2 | 1/2 | 1/7 | 1/5 | 1/6 | 1/3 | 0,02 |
| M8 | 1/5 | 3 | 3 | 1/2 | 1/3 | 2 | 2 | 1 | 2 | 1/7 | 1/5 | 1/6 | 1/2 | 0,03 |
| M9 | 1/7 | 4 | 4 | 1/3 | 1/4 | 2 | 2 | 1/2 | 1 | 1/8 | 1/5 | 1/6 | 1/3 | 0,03 |
| M10 | 3 | 9 | 9 | 6 | 4 | 7 | 7 | 7 | 8 | 1 | 3 | 2 | 5 | 0,23 |
| M11 | 1/2 | 7 | 7 | 3 | 2 | 5 | 5 | 5 | 5 | 1/3 | 1 | 1/3 | 3 | 0,11 |
| M12 | 2 | 8 | 8 | 4 | 3 | 7 | 6 | 6 | 6 | 1/2 | 3 | 1 | 3 | 0,17 |
| M13 | 1/3 | 9 | 9 | 2 | 1/2 | 3 | 3 | 2 | 3 | 1/5 | 1/3 | 1/3 | 1 | 0,07 |

Hesaplanan ağırlıklar, teknopark firmalarının normleştirilmiş verileri ile çarpılarak firmaların puanları hesaplanmıştır. AHP yöntemi kullanılarak elde edilen sonuçlar Tablo 13'de verilmektedir.

Tablo 13. AHP sonuçlar

| Firma | Puan | Sınıf | Firma | Puan | Sınıf |
|----------|------|-------|----------|------|-------|
| Firma 01 | 6 | | Firma 21 | 11 | |
| Firma 02 | 9 | | Firma 22 | 17 | A1 |
| Firma 03 | 13 | | Firma 23 | 4 | |
| Firma 04 | 23 | | Firma 24 | 5 | |
| Firma 05 | 62 | A1/B2 | Firma 25 | 57 | |
| Firma 06 | 7 | | Firma 26 | 8 | A1 |
| Firma 07 | 4 | | Firma 27 | 24 | |
| Firma 08 | 9 | | Firma 28 | 9 | |
| Firma 09 | 11 | | Firma 29 | 22 | |
| Firma 10 | 48 | | Firma 30 | 10 | A2 |
| Firma 11 | 11 | | Firma 31 | 12 | A3 |
| Firma 12 | 12 | | Firma 32 | 9 | A2 |
| Firma 13 | 5 | | Firma 33 | 20 | |
| Firma 14 | 36 | | Firma 34 | 22 | B1 |
| Firma 15 | 8 | | Firma 35 | 14 | |
| Firma 16 | 14 | | Firma 36 | 16 | |
| Firma 17 | 13 | A3 | Firma 37 | 6 | B2 |
| Firma 18 | 10 | | Firma 38 | 21 | |
| Firma 19 | 17 | | Firma 39 | 10 | |
| Firma 20 | 10 | | Firma 40 | 12 | |

Tablo 13 incelendiğinde, 4 firmanın yeşil kategoride, 9 firmanın sarı kategoride ve 27 firmanın kırmızı kategoride yer aldığı görülmektedir. Firmaların ortalama puanı 15,93' dir. Ayrıca 3 firma A1, 2 firma A2, 2 firma A3, 1 firma B1 ve 2 firma B2 kategorisinde yer almaktadır.

3.4. DEMATEL Bulguları

Uzman görüşü ile belirlenen DEMATEL ilişki matrisi Tablo 14'de verilmiştir.

Tablo 14. DEMATEL ilişki matrisi

| Kriterler | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 |
|--|---|---|---|---|---|---|---|---|---|----|----|----|----|
| 1.Toplam İşbirliği | 0 | 2 | 3 | 1 | 1 | 2 | 1 | 1 | 1 | 3 | 3 | 2 | 2 |
| 2.Toplam Proje Sayısı/Toplam Ar-Ge Personeli | 2 | 0 | 2 | 1 | 1 | 1 | 1 | 1 | 1 | 2 | 2 | 1 | 1 |
| 3.Ticarileşen Projeler Toplam Geliri /Tamamlanan Proje Sayısı | 3 | 2 | 0 | 2 | 2 | 1 | 1 | 1 | 1 | 4 | 4 | 4 | 3 |
| 4.Toplam Ar-Ge Harcaması /Toplam Ar-Ge Personel Sayısı | 1 | 1 | 2 | 0 | 3 | 1 | 1 | 1 | 1 | 3 | 3 | 3 | 3 |
| 5. Toplam Ar-Ge Geliri /Toplam Ar-Ge Personel Sayısı | 1 | 1 | 2 | 3 | 0 | 2 | 3 | 1 | 1 | 3 | 3 | 3 | 2 |
| 6. Alınan Destek Fonları /Teknoparkta Geçirilen Süre | 2 | 1 | 1 | 1 | 2 | 0 | 2 | 1 | 1 | 2 | 2 | 2 | 2 |
| 7.Toplam Ar-Ge Personel Sayısı/Devam Eden Proje Sayısı | 1 | 1 | 1 | 1 | 3 | 2 | 0 | 1 | 1 | 2 | 2 | 2 | 3 |
| 8.Doktoralı Personel Sayısı /Toplam Ar-Ge Sayısı | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 0 | 1 | 1 | 1 | 1 | 2 |
| 9.Kadın Arge-Personeli Sayısı/Toplam Ar-Ge Personeli Sayısı | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 0 | 1 | 1 | 1 | 2 |
| 10. Ticarileşen projeler Toplam Geliri | 3 | 2 | 4 | 3 | 3 | 2 | 2 | 1 | 1 | 0 | 4 | 4 | 4 |
| 11. Ticarileşen Proje Sayısı | 3 | 2 | 4 | 3 | 3 | 2 | 2 | 1 | 1 | 4 | 0 | 4 | 4 |
| 12.Ticarileşme Oranları (Ticarileşen Projeler Toplam Geliri /Teknoparkta Kalma Süresi) | 2 | 1 | 4 | 3 | 3 | 2 | 2 | 1 | 1 | 4 | 4 | 0 | 4 |
| 13.Büyüme İstihdam (Ar-Ge Personeli Sayısı /Teknoparkta Geçirilen Yıl) | 2 | 1 | 3 | 3 | 2 | 2 | 3 | 2 | 2 | 4 | 4 | 4 | 0 |

Bulunan ağırlıklar, teknopark firmalarının normalleştirilmiş verileri ile çarpılarak firmaların puanları hesaplanmıştır. DEMATEL yöntemi kullanılarak elde edilen sonuçlar Tablo 15'de verilmiştir.

Tablo 15. DEMATEL sonuçları

| Firma | Puan | Sınıf | Firma | Puan | Sınıf |
|----------|------|-------|----------|------|-------|
| Firma 01 | 7 | | Firma 21 | 14 | |
| Firma 02 | 9 | | Firma 22 | 19 | A1 |
| Firma 03 | 14 | | Firma 23 | 7 | |
| Firma 04 | 23 | | Firma 24 | 7 | |
| Firma 05 | 54 | A1/B2 | Firma 25 | 50 | |
| Firma 06 | 8 | | Firma 26 | 11 | A1 |
| Firma 07 | 7 | | Firma 27 | 28 | |
| Firma 08 | 9 | | Firma 28 | 10 | |
| Firma 09 | 13 | | Firma 29 | 25 | |
| Firma 10 | 42 | | Firma 30 | 11 | A2 |
| Firma 11 | 12 | | Firma 31 | 15 | A3 |
| Firma 12 | 16 | | Firma 32 | 9 | A2 |
| Firma 13 | 6 | | Firma 33 | 27 | |
| Firma 14 | 32 | | Firma 34 | 24 | B1 |
| Firma 15 | 7 | | Firma 35 | 14 | |
| Firma 16 | 15 | | Firma 36 | 19 | |
| Firma 17 | 12 | A3 | Firma 37 | 7 | B2 |
| Firma 18 | 10 | | Firma 38 | 24 | |
| Firma 19 | 20 | | Firma 39 | 12 | |
| Firma 20 | 11 | | Firma 40 | 12 | |

Tablo 15 incelendiğinde, 4 firmanın yeşil kategoride, 9 firmanın sarı kategoride ve 27 firmanın kırmızı kategoride yer aldığı görülmektedir. Firmaların ortalama puanı 16,8 dir. Ayrıca 3 firma A1, 2 firma A2, 2 firma A3, 1 firma B1 ve 2 firma B2 kategorisinde yer almaktadır.

3.5. Spearman İkili Korelasyon Karşılaştırması İle Yöntemlerin İncelenmesi

Spearman ikili korelasyon karşılaştırması, iki değişken arasındaki monoton ilişkiyi incelemek için kullanılır. Spearman'ın sıralama korelasyon katsayısı, veri setlerindeki sıralamaların korelasyonunu ölçer [44] ve Pearson korelasyon katsayısından farklı olarak verilerin dağılımına bağlı değildir. Yöntemin genel formülasyonu aşağıdaki gibidir [45].

Aşamalar

- Veri Toplanması ve Sıralanması: İki değişken için veri setleri belirlenir. Her bir veri seti için değerler sıralanır ve sıralama numaraları atanır.
- Sıralama Farklarının Hesaplanması: Her bir çift için sıralama farkları d_i hesaplanır.
- Spearman Korelasyon Katsayısının Hesaplanması: Spearman korelasyon katsayısı ρ hesaplanır.

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (20)$$

Çalışmada Spearman ikili korelasyon yöntemiyle veri setleri olarak her bir yöntemdeki firma sıralamaları alınmış ve yöntemler ikili olarak karşılaştırılmıştır. Karşılaştırma tablosu Tablo 16 da verilmektedir.

Tablo 16 Korelasyon ilişkileri

| SIRALAMA | AHP | DEMATEL | ENTROPİ | TOPSIS |
|----------|-------|---------|---------|--------|
| AHP | 1,00 | 0,950 | 0,892 | 0,653 |
| DEMATEL | 0,950 | 1,000 | 0,928 | 0,693 |
| ENTROPİ | 0,892 | 0,928 | 1,000 | 0,755 |
| TOPSIS | 0,653 | 0,693 | 0,755 | 1,000 |

Korelasyon testine göre 0.9 ve üzeri korelasyon değerleri, yöntemler arasında çok yüksek düzeyde bir ilişki bulunduğunu; 0.7 ve 0.89 arasındaki korelasyon değerleri, yöntemler arasında yüksek bir ilişki bulunduğunu; 0.5 ve 0.69 arasındaki korelasyon değerleri, yöntemler arasında orta düzeyde bir ilişki bulunduğunu ve 0.49 ve altındaki korelasyon değerleri, yöntemler arasında zayıf düzeyde bir ilişki bulunduğunu göstermektedir.

Tablo 15 incelendiğinde, Karar vericiye bağlı yöntemler (AHP ve DEMATEL) ve veriye bağlı yöntemlerin (Entropi ve TOPSIS) genel olarak birbirleriyle yüksek düzeyde ilişki gösterdiği; TOPSIS yönteminin diğer yöntemlerden belirli ölçüde farklı sonuçlar ürettiği görülmektedir. Bununla birlikte 0,49 ve altında değer olmaması ekseriyetle yöntemlerin arasında güçlü pozitif korelasyonlar olduğunu ve bunun da yöntemlerin genellikle benzer sıralamalar ürettiğini ifade etmektedir.

4. Tartışma ve Sonuç

Çalışmada, teknoparklarda yer alan 40 firmanın 2016-2022 yılları arasındaki performansları, ÇKKV yöntemlerinden AHP, DEMATEL, Entropi ve TOPSIS yöntemleriyle ölçülmüştür. Verilerin alınmasında teknopark ve firma isimleri anonim tutulmuş, devamlılık esasına göre seçilen firmalar incelenmiştir. Puanlar göz önüne alındığında, firmaların belirlenen kriterlere uyum sağlama kapasitelerinin genellikle zayıf olduğu tespit edilmiştir. Tüm yöntemlerle yapılan hesaplamalar incelendiğinde çok az sayıda firma yeşil kategoride yer alırken birçok firma kırmızı kategoride yer almıştır.

Spearman ikili korelasyon analizi, yöntemler arasındaki ilişkiyi ortaya koymuştur. AHP ve DEMATEL arasında çok güçlü bir pozitif korelasyon (0,95) bulunmuş, bu da karar vericilerin benzer yargılarının yöntem sonuçlarını etkilediğini göstermektedir. Diğer çok güçlü pozitif korelasyon DEMATEL-Entropi (0,928) yöntemleri arasında gözlemlenmiştir. Bu durum, karar vericiye bağlı yöntemler ile veriye dayalı yöntemlerin genel olarak benzer sonuçlar ürettiğini ortaya koymaktadır.

Öte yandan, Entropi ve TOPSIS (0,755) yöntemleri arasında güçlü bir pozitif ilişkiye işaret etmesi veriye dayalı yöntemlerin de kendi aralarındaki tutarlılığı desteklemekte olduğunu göstermektedir. Diğer güçlü pozitif korelasyon AHP ve Entropi (0,892) yöntemleri arasında gözlemlenmiştir. Bu durumda, karar vericiye bağlı yöntemler ile veriye dayalı yöntemlerin genel olarak benzer sonuçlar ürettiğini ortaya koymaktadır.

Son olarak, AHP ve TOPSIS (0,653) ve DEMATEL ve TOPSIS (0,693) arasında orta düzeyde pozitif korelasyonlar bulunmuştur. Bu, TOPSIS'in veriye daha duyarlı olması nedeniyle, diğer yöntemlerle kıyaslandığında farklı sonuçlar üretebileceğini göstermektedir. Sonuç olarak, karar vericiye bağlı yöntemler (AHP ve DEMATEL) ile veriye bağlı yöntemler (Entropi ve TOPSIS) arasında genel olarak yüksek korelasyonlar bulunmuş, ancak TOPSIS'in diğer yöntemlerden daha farklı sonuçlar üretebileceği de tespit edilmiştir. Bu bulgular, yöntemlerin genellikle benzer sıralamalar ürettiğini, ancak veri duyarlılığının sonuçları etkileyebileceğini göstermektedir. Elde edilen sonuçlar, teknopark yönetimi ile paylaşılmış olup, gelecekte performans ölçümlerinin kararlarda daha etkin kullanılabilmesi için değerlendirilmektedir.

Kaynakça

- [1] Kiper M., Dünyada ve Türkiye’de Üniversite-Sanayi İşbirliği ve Bu Kapsamda Üniversite-Sanayi Ortak Araştırma Merkezleri Programı (ÜSAMP), Türkiye Teknoloji Geliştirme Vakfı Yayını, Ankara, 2010.
- [2] Alkibay S., Orhaner E., Korkmaz S. Sertoğlu A.E., Üniversite sanayi işbirliği çerçevesinde teknokentler, yönetsel sorunları ve çözüm önerileri, Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 26 (2), 65-90, 2012.
- [3] Kaygın E., Güven B., Girişimcilik: Temel Kavramlar, Girişimcilik Türleri, Girişimcilikte Güncel Konular, Siyahinci Akademi, İstanbul, 2015.
- [4] Wicaksono A., Ririh K.R., Understanding technological knowledge spillover in a science technology park ecosystem: An ethnographic study. *Asian Journal of Technology Innovation*, 30 (3), 559-580, 2021.
- [5] Erenler Y., Teknopark alanlarının fiziki planlama ilkelerinin irdelenmesi üzerine bir araştırma, Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya, 2007.
- [6] Eren M., Türkiye’nin teknolojik gelişmesinde teknokentler ve Ar-Ge desteği, Yüksek Lisans Tezi, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul, 2011.
- [7] Nosonov A., Letkina N., Technoparks as centers of regional economic development, *International Journal of Innovative Technology and Exploring Engineering*, 8 (12), 4213-4218, 2019.
- [8] Cansız M., 2023’e Doğru Türkiye Teknoparkları, Kalkınma Bakanlığı Yayınları, Ankara, 2017.
- [9] T.C. Sanayi ve Teknoloji Bakanlığı, İstatistik verileri. <https://www.sanayi.gov.tr/istatistikler/istatistikleri-bilgiler/mi0203011501>. Yayın tarihi Temmuz 7, 2023. Erişim tarihi Nisan 10, 2023.
- [10] Baykul, H. (2015). Türkiye'deki Teknoloji Geliştirme Bölgeleri yönetici şirketlerinin etkinlik analizi (Doktora tezi). Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İktisat Anabilim Dalı.
- [11] Demirel, O. (2015). TR42 Doğu Marmara Bölgesi teknokentlerinde bilişim işletmelerinin inovasyon süreç performansı (Yüksek lisans tezi). Düzce Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı.
- [12] Çakır, F. (2015). Borsa İstanbul’da kote olan teknoloji/bilişim şirketlerinin etkinlik analizi: Bulanık Veri Zarflama Analizi (BVZA) uygulaması (Yüksek lisans tezi). Karadeniz Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, İşletme Bilim Dalı.
- [13] Karagöz, Ö. (2020). Türkiye'deki üniversitelerin etkinlik ölçümü ve performanslarının karşılaştırılması: Panel veri analizi (Doktora tezi). Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, Ekonometri Bilim Dalı.
- [14] Güzel, T., & Ünlü, H. (2024). Türkiye’deki Teknoloji Geliştirme Bölgelerinin Etkinliğinin İki Aşamalı Veri Zarflama Analizi ile Değerlendirilmesi. *Politeknik Dergisi* 1-1. <https://doi.org/10.2339/politeknik.1375638>
- [15] Önal, M. (2023). TR42 Doğu Marmara Teknoloji Geliştirme Bölgesi performans analizi: CRITIC tabanlı WASPAS ve SAW uygulaması (Yüksek lisans tezi). Bolu Abant İzzet Baysal Üniversitesi, Lisansüstü Eğitim Enstitüsü, İşletme Anabilim Dalı, İşletme Bilim Dalı.
- [16] Batmantaş, H. (2024). Teknoparkların bölgesel kalkınma üzerindeki etkisinde kuruluş yeri ve yapısının düzenleyici rolü ile yenilik ve verimliliğin aracı rolü Bandırma Onyediy Eylül Üniversitesi / Sosyal Bilimler Enstitüsü / İşletme Ana Bilim Dalı / İşletme Bilim Dalı
- [17] Akal Yılmaz, D. (2022). Teknoloji geliştirme bölgeleri yönetici şirketlerinin işbirliği alternatiflerinin araştırılması: Bir karar verme modeli olarak bulanık AHP uygulaması (Yüksek lisans tezi). Ankara Yıldırım Beyazıt Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Yönetimi Bilim Dalı.
- [18] Çiftçi, F. (2017). Teknoloji transfer ofislerinin (TTO) performanslarının ölçülmesi: Türkiye örneği (Yüksek lisans tezi). Orta Doğu Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, Bilim ve Teknoloji Politikası Çalışmaları Anabilim Dalı.
- [19] Bigliardi, B., Dormio, A. I., Nosella, A., & Petroni, G. (2006). "Assessing Science Parks' Performance: A Assessing science parks' performances: directions from selected Italian case studies." *Technovation*, 26(4), 489-504.
- [20] Fukugava, N. (2006). "Science Parks in Japan and Their Value-Added Contributions to New Technology-Based Firms." *International Journal of Industrial Organization*, 24(2), 381-400.
- [21] Evaluation of national science park systems: a theoretical framework and its application to the Italian and Spanish systems A Albahari, G Catalano, P Landoni - *Technology Analysis & Strategic Management*, 2013
- [22] Sohn, S. Y., & Kim, Y. G. (2012). "Decision Tree Based Technology Credit Scoring for Start-Up Firms." *Expert Systems with Applications*, 39(7), 5992-5997.

- [23] Yu, A., Shi, Y., You, J., & Zhu, J. (2021). Innovation performance evaluation for high-tech companies using a dynamic network data envelopment analysis approach. *European Journal of Operational Research*, 292(1), 199-212. <https://doi.org/10.1016/j.ejor.2020.10.011>
- [24] Cardoso da Silva, D. J., de Oliveira Gibbon, A. R., Teixeira, C. S., Piqué Huerta, J. M., Pereira da Veiga, C., & Flores, L. F. (2023). Defining indicators for performance evaluation in science and technology parks. *IEEE Engineering Management Review*, 51(3), 77-85.
- [25] Kharabsheh, R. (2012). Critical success factors of technology parks in Australia. *International Journal of Economics and Finance*, 4(7), 57-65. <https://doi.org/10.5539/ijef.v4n7p57>
- [26] Ng W.K.B., Appel-Meulenbroek R., Cloodt M., Arentze T., Perceptual measures of scienceparks: Tenant firms' associations between science park attributes and benefits, *Technological Forecasting and Social Change*, 163, 120408, 2021.
- [27] Guadix J., Carillo-Castrillo J., Onieva L., Navascues J., Success variables in science and technology parks, *Journal of Business Research*, 69, 4870-4875, 2016.
- [28] https://www.oecd-ilibrary.org/docserver/9789264043466_en.pdf?expires=1719491758&id=id&accname=oid025921&checksum=A0F6FF8AABF9C7C2BCD02C45C99BEA7B
- [29] Samira El Gibari & Trinidad Gómez & Francisco Ruiz, 2019. "Building composite indicators using multicriteria methods: a review," *Journal of Business Economics*, Springer, vol. 89(1), pages 1-24, February.
- [30] Wang, T.C., & Lee, H.D. (2009). Developing a fuzzy TOPSIS approach based on subjective weights and objective weights. *Expert Systems with Applications*, 36(5), 8980-8985.
- [31] Zavadskas, E. K., & Turskis, Z. (2010). "A new additive ratio assessment (ARAS) method in multicriteria decision-making". *Technological and Economic Development of Economy*
- [32] Hwang, C. L., & Yoon, K. (1981). "Multiple Attribute Decision Making: Methods and Applications". Springer.
- [33] Wu, W.W., & Lee, Y.T. (2007). Developing global managers' competencies using the fuzzy DEMATEL method. *Expert Systems with Applications*, 32(2), 499-507
- [34] Deng, H., Yeh, C. H., & Willis, R. J. (2000). "Inter-company comparison using modified TOPSIS with objective weights". *Computers & Operations Research*.
- [35] Wang, T.C., & Lee, H.D. (2009). Developing a fuzzy TOPSIS approach based on subjective weights and objective weights. *Expert Systems with Applications*, 36(5), 8980-8985.
- [36] Saaty, T.L. (2008). Decision making with the analytic hierarchy process. *International Journal of Services Sciences*, 1(1), 83-98.
- [37] Liberatore, M.J. & Nydick, R.L. (2008). The analytic hierarchy process in medical and health care decision making: A literature review. *European Journal of Operational Research*, 189(1), 194-207.
- [38] Yaraloğlu, K, Performans Değerlendirmede Analitik Hiyerarşi Proses, DEÜ İktisadi ve İdari Bilimler Fakültesi Dergisi, Cilt 16, Sayı 1, 2001.
- [39] Aydın, Ö, Akçalı, E, Öznehir S, Ankara için optimal hastane yeri seçiminin analitik hiyerarşi süreci ile modellenmesi, Süleyman Demirel Üniversitesi İ.İ.B.F Dergisi C.14, s.2 s.69-86, 2009.
- [40] Zhu, J. & Fan, W. (2011). A methodology for evaluating enterprise mashup platforms based on DEMATEL and ANP. *Expert Systems with Applications*, 38(1), 1117-1126.
- [41] Wang, T.C. & Elhag, T.M.S. (2006). A fuzzy TOPSIS based approach for strategic alliance partner selection in the airline industry. *Expert Systems with Applications*, 30(4), 726-733.
- [42] W. H. Tsai, W. C. Chou and C. W. Lai, "An Effective Evaluation Model and Improvement Analysis for National Park Websites: A Case Study of Taiwan," *Tourism Management*, Vol. 31, No. 6, 2010, pp. 936-952 doi:10.1016/j.tourman.2010.01.016
- [43] Yang, Z., Liu, P., Xu, X., & Xu, C. (2016). Multiobjective evaluation of midblock crosswalks on urban streets based on TOPSIS and entropy methods. *Transportation Research Record: Journal of the Transportation Research Board*, (2588), 1-8.
- [44] Holm, S., & Björk, J. (2003). A simple sequentially rejective multiple test procedure. *Scandinavian Journal of Statistics*, 6(2), 65-70.
- [45] Gibbons, J. D., & Chakraborti, S. (2011). *Nonparametric Statistical Inference*. CRC Press.

A Hybrid Deep Learning Model for Traffic Flow Prediction

Alper Talha Karadeniz^{*1}, Yavuz Canbay²

^{*1} Samsun University Faculty of Engineering and Natural Sciences Software
Department of Engineering, Samsun, Türkiye

² Department of Computer Engineering, Faculty of Engineering and Architecture, Sutcu Imam University,
Kahramanmaraş, Turkey

(Alınış / Received: 04.08.2024, Kabul / Accepted: 01.10.2024, Online Yayınlanma / Published Online: 30.12.2024)

Keywords

traffic flow,
prediction,
deep learning

Abstract: Urbanization has led to increase traffic issues, resulting in economic losses and accelerating environmental pollution, so reducing the quality of life for city residents. Proactively identifying traffic issues and reducing congestion is crucial. Traffic flow prediction involves the examination of historical and present traffic data to predict future traffic conditions. Precise predictions enable individuals to make informed choices on travel routes and methods of transportation. This minimizes travel duration and enhances comfort with traffic conditions. Traditional traffic prediction methods rely on statistical techniques or fundamental time series analysis. Nonetheless, these methods cannot adequately consider for the complex geographical and temporal relationships found in traffic data. Recent advancements in artificial intelligence have enabled the development of complex and data-driven models for prediction. This study introduces a novel hybrid model for predicting traffic flow using deep learning techniques. The proposed model employs a CNN for feature extraction and a BiLSTM for prediction. The effectiveness of the proposed hybrid model was evaluated against other baseline algorithms using a real-world dataset. The experiments indicated that the proposed hybrid model outperformed other models, achieving 5.1834 MAE, 54.4060 MSE, 7.3760 RMSE, and 0.9923 R² values. The results demonstrate the potential of deep learning methods in predicting traffic flow and offer direction for future studies.

Trafik Akış Tahmini İçin Hibrit Bir Derin Öğrenme Modeli

Anahtar Kelimeler

trafik akışı,
tahmin,
derin öğrenme

Öz: Kentleşme, trafik sorunlarının artmasına yol açmakta, bu durum yalnızca ekonomik kayıpları beraberinde getirmekle kalmayıp aynı zamanda çevresel bozulmaya da neden olarak kent sakinlerinin yaşam kalitesini tehdit etmektedir. Trafik sorunlarını tespit etmek ve trafik sıkışıklığını proaktif olarak azaltmak son derece önemlidir. Trafik akışı tahmini, gelecekteki trafik koşullarını öngörmek için geçmiş ve güncel trafik verilerinin analiz edilmesiyle yapılır. Kesin tahminler, insanların seyahat rotaları ve ulaşım yöntemleri konusunda bilinçli seçimler yapmasına olanak tanır. Bu durum, yolculuk süresini azaltır ve trafik koşullarından memnuniyet düzeyini artırır. Geleneksel trafik tahmin yöntemleri istatistiksel tekniklere veya basit zaman serisi analizine dayanır. Ancak bu analizler, trafik verilerindeki karmaşık mekânsal ve zamansal bağımlılıkları yakalama konusunda beklenileni vermemektedir. Yapay zekâdaki son gelişmeler, karmaşık ve veriye dayalı tahmin modellerinin oluşturulmasına olanak sağlamıştır. Bu makalede, derin öğrenme tekniklerini kullanarak trafik akışını tahmin etmek için yeni bir hibrit model önerilmektedir. Önerilen modelin performansı, gerçek dünya veri kümesi üzerinde bazı temel algoritmalara göre değerlendirilmiştir. Yapılan deneylerde önerilen hibrit modelin 5,1834 MAE, 54,4060 MSE, 7,3760 RMSE ve 0,9923 R² değerleriyle diğer modellerden daha iyi performans gösterdiği görülmüştür.

Sonuçlar, trafik akış tahmini alanında derin öğrenme yöntemlerinin potansiyelini vurgulamakta ve gelecekteki araştırmalar için yol gösterici olduğunu göstermektedir.

1. INTRODUCTION

The effective management of cities depends significantly on the existence of robust transportation systems, which grow more crucial with the acceleration of urbanization. Traffic congestion adversely impacts economic productivity and degrades the quality of life for city residents owing to environmental pollution. Therefore, it is essential to address possible concerns to prevent traffic congestion. There is an increasing interest in the advancement of innovative systems and methodologies for traffic flow prediction [1, 2].

Traffic flow prediction employs historical and current traffic data to forecast eventual conditions. Accurate forecasts allow individuals to make informed decisions regarding travel routes and travel methods, leading to decreased travel time and increased satisfaction concerning traffic conditions [3]. The forecast of traffic flow is a complex issue influenced by various factors, including road shape, weather conditions, traffic density, and human behavior. Conventional traffic prediction methods typically emphasize fundamental statistical analysis, which may insufficiently represent the complex spatiotemporal relationships present in traffic data. Recent breakthroughs in deep learning and machine learning can significantly improve traffic flow prediction by enabling the development of complex predictive models based on traffic data [4, 5].

Numerous studies on traffic flow prediction are present in the literature. Hao Peng et al. introduced a methodology for forecasting traffic flow over longer periods via dynamic graphs. The traffic network was illustrated through dynamic traffic flow probability graphs, and spatial information was retrieved by graph convolution. This approach combines Long Short-Term Memory (LSTM) units with graph convolution to capture temporal characteristics. Effective long-term traffic flow estimates were accomplished by applying the approach to urban cycling data from New York City [6]. Jiawei Wang et al. presented a road-based deep learning model that guarantees both reliability and interpretability inside the urban transportation sector. This method also improves traffic speed forecasting on a city scale. To improve the interpretability of traffic flow in the study, the road network was segmented. Subsequently, a Bidirectional Long Short-Term Memory Network (BiLSTM) is utilized to simulate each road, yielding several BiLSTM layers that incorporate temporal information. During the traffic prediction phase, the spatial-temporal characteristics derived from these processes are conveyed to a fully interconnected layer. Finally, the outcomes for each route are aggregated to determine the traffic speed across the network. The experiments confirm the model's efficiency [7].

This study presents a novel hybrid model utilizing deep learning for traffic flow prediction. The proposed model employs CNN algorithm for feature extraction and BiLSTM algorithm for flow prediction. The proposed model was evaluated against multiple deep learning models and machine learning methods. An experimental study was conducted utilizing a publicly available dataset. The algorithms' performances were assessed utilizing established regression metrics such as MSE, MAE, RMSE, and R^2 . The findings indicated that the proposed model had the lowest error rates, with 5.1834 MAE, 54.4060 MSE, 7.3760 RMSE, and 0.9923 R^2 values. This work introduces a hybrid model that employs both CNN and BiLSTM for flow prediction.

The paper is organized as following. Section 2 explains the materials and methods utilized in the study. The proposed hybrid model was presented in Section 3. Section 4 shows the outcomes of the performed experimental studies and their results. Finally, Section 5 concludes the paper.

2. MATERIALS and METHODS

2.1. Dataset

Experimental studies were performed using a publicly available dataset from the Caltrans Performance Measurement System (PeMS) [8]. The dataset comprises traffic data from San Bernardino for July 2016. Detectors are located at 170 distinct locations. These detectors capture traffic data every five minutes. The dataset comprises three attributes: flow, occupancy, and speed. The flow variable in the dataset indicates the quantity of cars passing every five minutes. The occupancy variable indicates the time interval utilized by each vehicle. The speed variable represents the average velocity of vehicles passing within a 5-minute interval.

The dataset collection comprises 3,035,520 records from 170 detectors, each containing 17,856 data points. The data is scaled, standardized, and optimized through the use of data science engineering. Figures 1-3 demonstrate the histogram graphs for the variables of flow, occupancy, and speed, respectively [8].




Figure 1. Histogram of flow data




Figure 2. Histogram of occupancy data




Figure 3 . Histogram of speed data

2.2. CNN

Convolutional Neural Networks (CNNs) have currently attained substantial popularity as a competitive kind of deep learning. These networks are constructed with artificial neural networks and have demonstrated significant success, especially in domains such as image and video processing, pattern recognition, and computer vision applications. CNNs are designed to adaptively acquire spatial hierarchies of features from input data via several layers. A standard CNN design comprises three primary types of layers: convolutional, pooling, and fully connected layers.

Convolutional Layer: This layer performs a mathematical operation known as convolution by applying a sequence of filters (or kernels) to the input data. Each filter identifies particular characteristics in the data, such as edges or textures.

Pooling Layer: This layer minimizes computational load, regulates overfitting, and enhances the model's invariance to minor changes or rotations in the input data.

Fully Connected Layer: fully connected layers combine the features acquired by previous levels to generate predictions.

The combination of these layers makes CNNs remarkable at extracting significant characteristics from large and complex datasets, hence enhancing their efficiency in tasks such as image classification, object recognition, and natural language processing [9, 10].

2.3. Multi Layer Perceptron

Multi Layer Perceptron (MLP), a feed-forward artificial neural network, employs backpropagation, a supervised learning approach, for network training. It performs tasks such as classification, regression, and pattern recognition, and is efficient at representing complex input-output interactions. MLP architectures enable the resolution of non-linear problems and the learning and representation of complex data structures [11].

2.4. Random Forest

Random Forest method is typically utilized for regression and classification tasks. To ensure optimal system performance during the training process, it is essential to generate a substantial number of decision trees. The class can be represented as the average prediction of each individual tree for regression tasks and the most frequent class for classification tasks. Each tree in the forest comprises a data sample, and every split in the tree evaluates a random subset of attributes, promoting diversity among trees and reducing the likelihood of overfitting. This method improves the precision and robustness of predictions relative to individual decision trees. This approach is an efficient method for managing large and complex datasets, correcting missing values, and evaluating the importance of variables. This method uses the formula presented in Equation 1 [12]. Here p_i represents the relative frequency of the class observed in the data set and c represents the number of classes.

$$Entropy = \sum_{i=1}^c - P_i * \log_2(p_i) \quad (1)$$

2.5. Linear Regression

Linear Regression (LR) is a popular regression method utilized to help explain the link between dependent and independent variables. The primary goal is to determine the ideal planar equation by examining the correlation between the independent variables in the dataset and the predicted value of the dependent variable. This method use the formula presented in Equation 2 [13]. In this equation, Y is the dependent variable and X is the independent variable, m is the estimated slope, and b is the estimated intercept.

$$Y = mX + b \quad (2)$$

2.6. Support Vector Regression

Support Vector Regression (SVR) is a known approach for addressing regression problems. The objective of the SVR algorithm is to precisely create a line that encompasses the majority of the data points under an epsilon threshold value. This algorithm seeks to identify the ideal hyperplane that maximizes the margin by focusing exclusively on points located outside the margin. SVR is particularly effective when the dataset comprises

numerous dimensions and exhibits complex, non-linear relationships among variables. To mitigate nonlinearity, it employs several kernel functions. The linear SVR formula in Equation 3 is utilized [14].

$$y(X) = \sum_1^n (a_i - a_i^*) \cdot \langle X_i, X \rangle + b \quad (3)$$

2.7. Long Short-Term Memory

Long Short-Term Memory (LSTM) networks are a specific kind of Recurrent Neural Networks (RNN) developed to tackle the issue of identifying long-term dependencies in sequential input. Traditional RNNs encounter difficulties in keeping information over long sequences, whereas LSTMs address this issue by integrating memory cells that can selectively store and control information. The memory cells are controlled by three key gates: the forget gate, which regulates the information to be discarded; the input gate, which determines the new information to be retained; and the output gate, which determines the information to be transmitted to the subsequent stage. This architecture enables LSTMs to preserve an internal state across time and more effectively capture long-term dependencies in data [15, 16].

2.8. Gated Recurrent Unit

The Gated Recurrent Unit (GRU) algorithm is a version of the RNN model designed to efficiently handle sequential input and reduce issues like vanishing gradients typically faced by conventional RNNs. It belongs to the family of LSTM network variants. The GRU algorithm demonstrates superior training speed compared to LSTMs and necessitates fewer parameters [17].

2.9. Bidirectional Long Short-Term Memory

Bidirectional Long Short-Term Memory (BiLSTM) network is an RNN variant designed to obtain contextual information from both historical and future states, in a sequential manner. LSTM models operate in a single direction. BiLSTMs are composed of two LSTM layers which one is used for processing the input data in the forward direction and the second one is for processing the data in the reverse direction. The bidirectional method, which involves comprehending the context from both perspectives, has a highly beneficial impact on the model's performance [18].

2.10. Performance Metrics

This study employs widely recognized regression metrics to assess the efficiency of the algorithms. The following metrics are summarized below.

R^2 : is utilized in regression analysis to assess the level to which the model accurately represents the data by evaluating the error rate. A robust model fit is signified by values approaching 1 [19]. Equation 4 presents the formula for the metric.

$$R^2 = correlation(actual_i, predicted_i)^2 \quad (4)$$

MAE: is the average of the absolute differences between the expected and actual values [20]. Equation 5 indicates the formula for the MAE metric.

$$MAE = \frac{\sum_{i=1}^N |predicted_i - actual_i|}{N} \quad (5)$$

MSE: denotes the average of the squared differences between the expected and actual values. It measures the magnitude of errors and maximizes the impact for significant errors [20]. Equation 6 is the formula for the MSE metric.

$$MSE = \sum_{i=1}^N (predicted_i - actual_i)^2 / N \quad (6)$$

RMSE: quantifies the magnitude of errors between actual and predicted values, calculated as the square root of MSE, as stated in Equation 7 [20, 21].

$$RMSE = \sqrt{\sum_{i=1}^N (predicted_i - actual_i)^2 / N} \quad (7)$$

2.11. The Proposed Hybrid Model

This study presents a novel hybrid deep learning model that integrates CNN and BiLSTM architectures. The CNN model is used for feature extraction, while the BiLSTM model is applied for predictions. Figure 4 illustrates the detailed presentation of the proposed model.

In Figure 4, the CNN model processes the flow data using a sliding window approach to extract features. The dataset undergoes one-dimensional convolution with 64 filters and a kernel size of 2. The feature maps from the previous phase are subjected to max pooling with a pool size of 2. Finally, the CNN model is finalized by incorporating a flatten layer, which reformats the data for input into the BiLSTM layer. Two BiLSTM layers are employed in the BiLSTM section, succeeded by two dense layers for prediction purposes. The predicted flow data has been obtained.

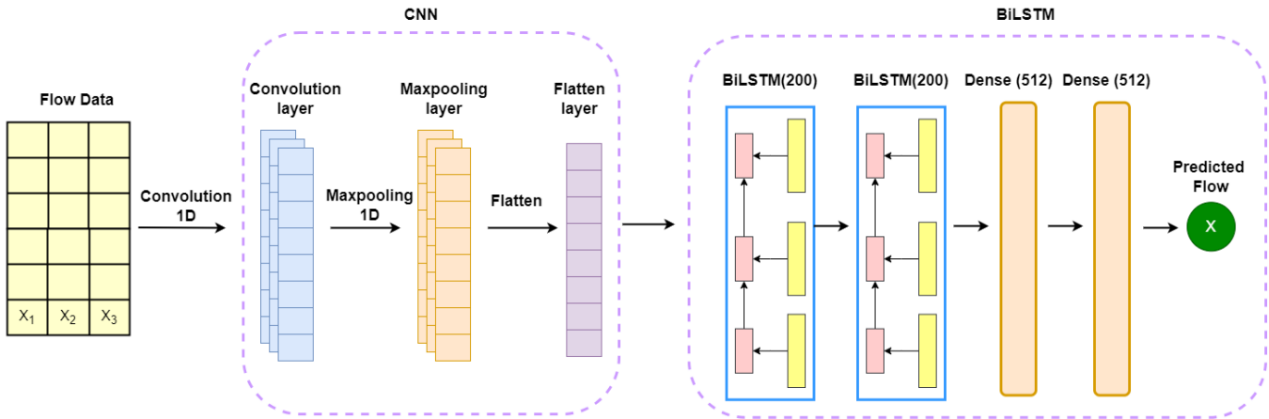


Figure 4. The proposed model

Sliding window method facilitates the transformation of time series tasks into supervised learning tasks. The time series is generally divided into short periods, aiming to predict the target value for each segment [22]. The sliding window technique, illustrated in Figure 5, converts the time series into data points including an output value and one or more input attributes. This transformation can anticipate future values by utilizing historical time series data. Figure 6 illustrates the architectural representation of the proposed model.




Figure 5. Sliding window method

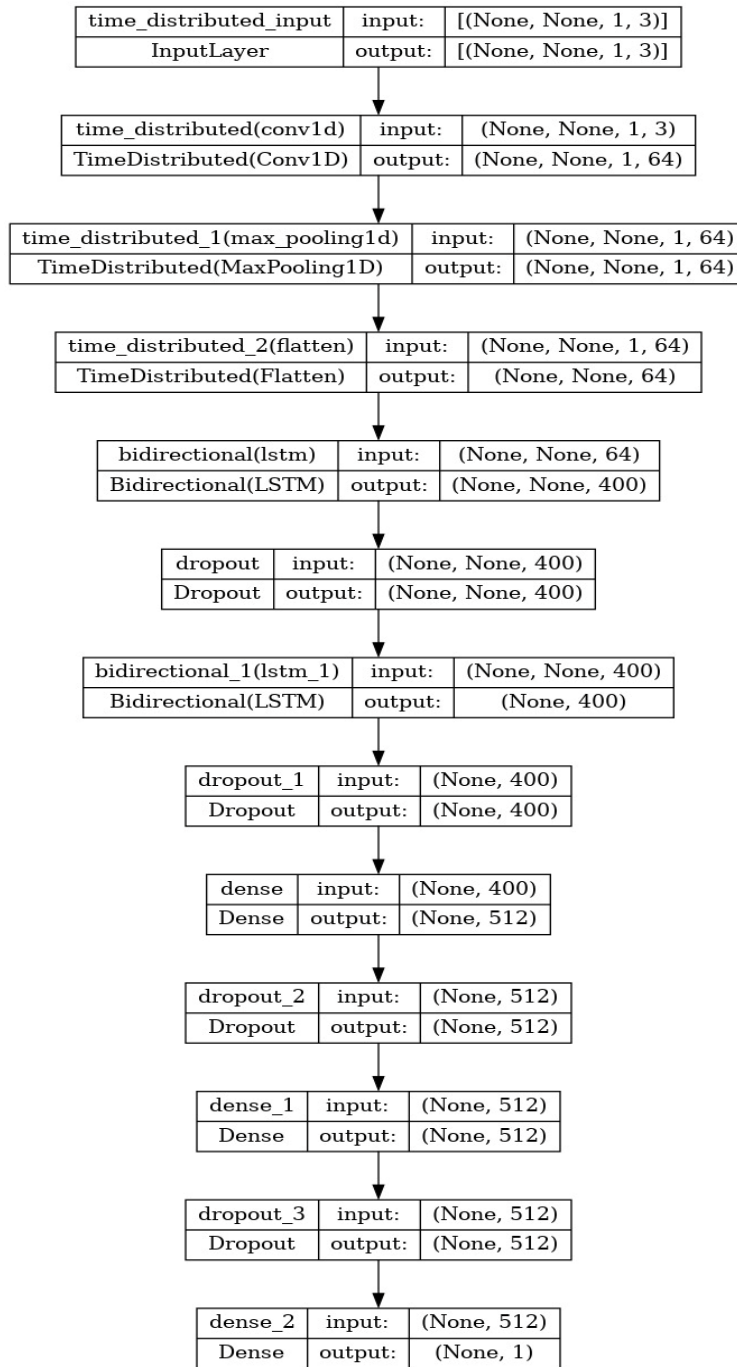


Figure 6. The architecture of the proposed model

3. RESULTS

In this study, a hybrid deep learning model for traffic flow prediction was proposed. One station was selected from a total of 170 stations in the PEMS08 data set. Experimental studies were performed on the flow variable of the chosen station utilizing 10 distinct algorithms. The dataset is partitioned into 80% for training and 20% for testing. Furthermore, 20% of the training data is utilized for validation purposes. The overall data count is 17,856, and the window size is 3.

The number of neurons in the CNNs was set to 64, with a kernel size and pool size of 2, and the activation function utilized was ReLU. The neuron count for LSTM, GRU, and BiLSTM was established at 200, with a layer count of 2. Table 1 displays the hyper parameters employed in model training.

Table 1. Hyper parameters used in model training

| Hyper parameter | Method |
|-----------------|--------|
| Loss Function | MSE |
| Optimizer | Adam |
| Learning Rate | 0.0001 |
| Epoch | 100 |
| Batch Size | 50 |

As a result of the experimental studies, the algorithms were compared with MAE, MSE, R² and RMSE performance metrics and comparison results were shown in Table 2 and presented with graphics in Figure 7.

Table 2. Experimental test results of algorithms

| Algorithm | MAE | MSE | R ² | RMSE |
|-------------------|----------|------------|----------------|-----------|
| CNN-BiLSTM | 5.183448 | 54.406092 | 0.992332 | 7.376049 |
| CNN-LSTM | 5.280843 | 55.569123 | 0.992168 | 7.454470 |
| CNN-GRU | 5.205485 | 55.322532 | 0.992202 | 7.437912 |
| BiLSTM | 5.309702 | 57.210446 | 0.991936 | 7.563759 |
| LSTM | 5.314796 | 57.698882 | 0.991868 | 7.595978 |
| GRU | 5.273546 | 56.565239 | 0.992027 | 7.520987 |
| SVR | 9.189161 | 136.057386 | 0.980823 | 11.664364 |
| LR | 5.355579 | 58.528052 | 0.991751 | 7.650363 |
| RF | 6.032785 | 66.877764 | 0.990574 | 8.177883 |
| MLP | 5.726425 | 65.254140 | 0.990803 | 8.078003 |




Figure 7. Graphical representation of the experimental results

Table 2 and Figure 7 demonstrate that the CNN-BiLSTM algorithm yields the most favorable results, with an MAE of 5.1834, MSE of 54.4060, RMSE of 7.3760, and R² value of 0.9923.

4. DISCUSSION AND CONCLUSION

The rapid increase in urbanization has weakened the quality of life for city residents and increased traffic issues. This situation has resulted in financial loss and increased environmental pollution. Efficiently controlling and reducing traffic congestion is essential for the sustainability of urban transportation systems. To attain more dependable and efficient traffic flow predicts, it is essential to utilize both historical and current traffic data. In this context, deep learning and machine learning methods provide efficient solutions to diverse issues. In recent years, these methods have been extensively utilized in the design of traffic prediction models.

This work presents a novel hybrid model based on deep learning for traffic flow prediction. A real-world dataset obtained from the Caltrans Performance Measurement System (PeMS) was utilized for performance evaluation. The efficiency of the proposed model was assessed utilizing established regression metrics and compared with various deep learning and machine learning algorithms, including BiLSTM, LSTM, GRU, SVR, LR, RF, and MLP. The evaluations are made using the metrics of MAE, MSE, RMSE, and R^2 . The CNN-BiLSTM hybrid model in our experiment demonstrated optimal performance, with an MAE of 5.1834, MSE of 54.4060, RMSE of 7.3760, and R^2 of 0.9923. These findings highlight the effectiveness of deep learning methods in the design of traffic prediction models.

In future efforts, we intend to create several hybrid versions of this model and introduce novel solutions that incorporate all stations within the dataset. The model's generalization capabilities can be further evaluated using larger datasets. Additionally, methods that integrate comprehensive evaluations of time series data and spatial characteristics can be developed. These improvements possess the capacity to enhance model performance and provide sophisticated solutions for traffic management and planning.

REFERENCES

- [1] S. A. Sayed, Y. Abdel-Hamid, and H. A. Hefny, "Artificial intelligence-based traffic flow prediction: a comprehensive review," *J. Electr. Syst. Inf. Technol.*, vol. 10, no. 1, p. 13, 2023.
- [2] N. A. M. Razali, N. Shamsaimon, K. K. Ishak, S. Ramli, M. F. M. Amran, and S. Sukardi, "Gap, techniques and evaluation: traffic flow prediction using machine learning and deep learning," *J. Big Data*, vol. 8, pp. 1–25, 2021.
- [3] Z. İ. E. Cicek and Z. K. Ozturk, "Short term traffic flow forecasting using artificial neural networks," *Sigma*, vol. 9, no. 4, pp. 405–414, 2018.
- [4] S. Goswami and A. Kumar, "Traffic Flow Prediction Using Deep Learning Techniques," in *International Conference on Computing Science, Communication and Security*, Springer, 2022, pp. 198–213.
- [5] A. Utku, "Deep Learning Based an Efficient Hybrid Model for Urban Traffic Prediction," *Bilişim Teknol. Derg.*, vol. 16, no. 2, pp. 107–117, 2023.
- [6] X. Ma, Z. Dai, Z. He, J. Ma, Y. Wang, and Y. Wang, "Learning traffic as images: A deep convolutional neural network for large-scale transportation network speed prediction," *Sensors*, vol. 19, no. 12, pp. 2801–2815, 2019.
- [7] J. Wang, R. Chen, and Z. He, "Traffic speed prediction for urban transportation network: A path based deep learning approach," *Transp. Res. Part C Emerg. Technol.*, vol. 100, pp. 372–385, 2019.
- [8] S. Guo, Y. Lin, N. Feng, C. Song, and H. Wan, "Attention based spatial-temporal graph convolutional networks for traffic flow forecasting," in *Proceedings of the AAAI conference on artificial intelligence*, 2019, pp. 922–929.
- [9] A. T. Karadeniz, Y. Çelik, and E. Başaran, "Classification of walnut varieties obtained from walnut leaf images by the recommended residual block based CNN model," *Eur. Food Res. Technol.*, pp. 1–12, 2022.
- [10] A. T. Karadeniz, E. Başaran, Y. Çelik, and "Identification of walnut variety from the leaves using deep learning algorithms," *Bitlis Eren University Journal of Science*, pp. 531–543, 2023.
- [11] J. Isabona et al., "Development of a multilayer perceptron neural network for optimal predictive modeling in urban microcellular radio environments," *Appl. Sci.*, vol. 12, no. 11, p. 5713, 2022.
- [12] G. Louppe, "Understanding random forests: From theory to practice," *arXiv Prepr. arXiv1407.7502*, 2014.
- [13] K. H. Zou, K. Tuncali, and S. G. Silverman, "Correlation and simple linear regression," *Radiology*, vol. 227, no. 3, pp. 617–628, 2003.
- [14] M. Awad, R. Khanna, M. Awad, and R. Khanna, "Support vector regression," *Effic. Learn. Mach. Theor. concepts, Appl. Eng. Syst. Des.*, pp. 67–80, 2015.
- [15] B. Yang, S. Sun, J. Li, X. Lin, and Y. Tian, "Traffic flow prediction using LSTM with feature enhancement," *Neurocomputing*, vol. 332, pp. 320–327, 2019.
- [16] Y. Kaya, Z. Yiner, M. Kaya, and F. Kuncan, "A new approach to COVID-19 detection from X-ray images using angle transformation with GoogleNet and LSTM," *Meas. Sci. Technol.*, vol. 33, no. 12, p. 124011, 2022.

- [17] R. Dey and F. M. Salem, "Gate-variants of gated recurrent unit (GRU) neural networks," in 2017 IEEE 60th international midwest symposium on circuits and systems (MWSCAS), IEEE, 2017, pp. 1597–1600.
- [18] Y. Hou et al., "Deep feature mining via the attention-based bidirectional long short term memory graph convolutional neural network for human motor imagery recognition," *Front. Bioeng. Biotechnol.*, vol. 9, p. 706229, 2022.
- [19] J. Gao, "R-Squared (R^2)–How much variation is explained?," *Res. Methods Med. Heal. Sci.*, p. 26320843231186400, 2023.
- [20] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *Peerj Comput. Sci.*, vol. 7, p. e623, 2021.
- [21] P. Canbay and H. Tas, "Prediction of Heating and Cooling Loads of Buildings by Artificial Intelligence," *Int. J. Pure Appl. Sci.*, vol. 8, no. 2, pp. 478–489, 2022.
- [22] A. Utku "Deep Learning Based an Efficient Hybrid Model for Urban Traffic Prediction," *Journal of Information Technologies*, vol. 16, no. 2, pp. 107-117, 2023.

CR3022 Antikoru ile Cihazdan Bağımsız Pratik Kağıt Tabanlı İmmünotest ile Direkt SARS CoV-2 Teşhisi

Dilek Çam Derin¹ 

*¹ İnönü Üniversitesi Fen Edebiyat Fakültesi Moleküler Biyoloji ve Genetik Bölümü, MALATYA
cam.dilek@gmail.com

(Alınış / Received: 01.11.2024, Kabul / Accepted: 25.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Anahtar Kelimeler

Dot blot assay,
viral diagnosis,
paper assay,
SARS CoV-2

Öz: Pandemi dünyada her an ortaya çıkabilir ve birçok ölümlü sonuçlanabilir. En son görülen pandemiye şiddetli akut solunum yolu sendromu koronavirüs 2 (SARS CoV-2) sebep olmuştur. SARS CoV-2 ilk kez ortaya çıktığı için hızlı tanı testlerinin yokluğu sebebiyle pandemi hızla ilerlemiş ve birçok kişinin ölümüne sebep olmuştur. Virüs tanısı için ilk olarak en güvenilir test olarak kabul edilen ters transkripsiyon polimeraz zincir reaksiyonu (RT-PZR) kullanılsa da eğitilmiş personel ihtiyacı duyması ve gelişmemiş ülkelerde bu testin uygulama zorluğu sebebiyle eksikleri vardır. Bu nedenle direkt virüs teşhisine yönelik hızlı testlerin geliştirilmesi her zaman elzemdir. Bu testler arasında kağıt tabanlı immünotestler önemlidir ve çoğunlukla dot-blot assay (noktasal test-NT) olarak bilinir. Vücut sıvılarının direkt uygulanmasına uygun olduğu için pratik ve kullanımı kolaydır. Antikor ve aptamerler tanı testlerinin en önemli bileşenleridir ve bunlardan afinitesi iyi olanlar kullanılmalıdır. Bu çalışmada antikor-aptamer sandviç testine dayalı olarak NT hazırlanmış ve viral teşhise uygun olup olmadığı bildirilmiştir.

Direct Detection of SARS CoV-2 by Practical Paper Based Immunoassay as an Instrument Free and Low Cost by CR3022

Keywords

Dot blot assay,
viral diagnosis,
paper assay,
SARS CoV-2

Abstract: Pandemia could be emerged at any time and resulted with death in the world. Severe acute respiratory syndrome coronavirus 2 (SARS CoV-2) caused the latest pandemia. Because of the absence of rapid diagnostic assays pandemia has surged in and caused the death of lots of people as SARS CoV-2 appeared at first time. Although reverse transcriptase polymerase chain reaction (RT-PCR) accepted as the most reliable test was used for the viral detection at first time, there are shortcomings including the need of educated personnel and difficulty of the usage of this test in undeveloped countries. For this reason, developing the rapid assays for direct recognition of virus is always essential. Paper based immunoassays are significant among these assays and they are known as dot-blot assay (DBA). It is practical and easy to use since they are suitable for direct application of body fluids. Antibodies and aptamers are the most important reagents of diagnostic assays and it should be used having the high affinity of them. In this work, DBA was prepared by antibody-aptamer based sandwich assay and reported the suitability of it for viral detection.

1. Giriş

İnsan sağlığı çeşitli virüs türlerinin her an ortaya çıkabilme ihtimali sebebiyle sürekli risk altındadır. Örneğin domuz gribi, kuş gribi, ebola gibi viral hastalıklar ile son zamanlarda kendini gösteren zika virüsü, koronavirüs ve maymun çiçeği virüsleri hem epidemiyem hem de pandemiye sebep olmuştur [1]. Özellikle 2019 yılının Aralık ayında,

Çin'in Wuhan kentinden dünyaya yayılan, pozitif iplikçikli bir ribonükleik asit (RNA) virüsü içeren şiddetli akut solunum sendromu virüsü koronavirüs-2 (SARS CoV-2), çok fazla sayıda ölüme sebep olmuştur [2] [3]. Bu nedenle epidemi veya pandeminin kısa sürede yayılmasının önüne geçmek ve/veya kontrol altında tutabilmek için kolay yöntemlerle hızlı sonuç verebilen testlerin doğru bir şekilde yapılması önemlidir. Bu testlerde yaygın olarak nanopartiküller kullanılmakta ve geliştirilen biyosensörler, klinik örneklerde nükleik asit ve protein gibi analitlerin tespitinin sağlanmasında avantajlı özelliklerinden dolayı önemli yer tutmaktadır [2]. SARS CoV-2 teşhisi için pandemiden günümüze kadar en güvenilir yöntem olarak Ters Transkriptaz Polimeraz Zincir reaksiyonu (RT-PCR) kullanılsa da, Enzyme Linked Immunosorbent Assay (ELISA) [4], Clustered Regularly Interspaced Short Palindromic Repeats (CRISPR), bilgisayarlı tomografi (CT) taraması, sekans analizi, lateral flow test (LFT) [5], Raman spektroskopisi [6], Loop-mediated izotermal amplifikasyon [7] gibi farklı metotlar da geliştirilmiştir. Bu metotlar pandemi sırasında çoğunlukla elde edilmesi zaman alan veya ekonomik olmayan kompleks ajanlar içermektedir. Ayrıca antijen saflaştırılması, ticari olarak ikili antikörlerin kullanılması, fonksiyonel ve çok amaçlı substrat ihtiyacı, gelişmiş ileri analiz cihazlarına ihtiyaç duyması sebebiyle dezavantajlı olabilmektedir. Bu nedenle rekombinant antikörler ve bu antikörlerin diyagnostikte kullanımı hem hızlı hem de ekonomiktir. Rekombinant antikörler arasında ise tek zincirli değişken fragment (scFv) oldukça popülerdir ve teşhis testlerinde kullanılabilir. SARS CoV-2 teşhisi için de farklı rekombinant antikörler pandemi süresince hem ticari olarak hazırlanmış hem de virüsün farklı antijenik bölgelerine özgü scFv antikörleri [8], yüzeyde zenginleştirilmiş Raman saçılması [6], ELISA [9], LFT [10] ve plazmonik temelli biyosensörlerde [11] tanıyıcı ajan olarak kullanılmıştır.

Antikörlerin yanı sıra aptamerler de hızlı tanı testleri ve genel diyagnostik testlerde kullanılan, kimyasal antikörler olarak da adlandırılan tek zincirli DNA veya RNA zincirleridir. Aptamerler, uzun raf ömrü, düşük ekonomik maliyeti, kolay erişim ve yüksek afinite özelliklerinden dolayı antikörlere göre avantajlı görülmekte ve bu nedenle hem tek başına hem de farklı antikör veya aptamerlerle bir arada kullanılarak tanı sistemlerinde önemli yer edinmiştir. SARS CoV-2 için de virüsün farklı antijenik bölgelerine özgü aptamerler geliştirilmeye devam etmektedir [12] [13]. Aptamerler antikörlerde olduğu gibi ELISA [14], LFT [15] ve farklı biyosensörlerde [16] [17] de kullanılarak SARS CoV-2 teşhisini göstermiştir. Yukarıda bahsi geçen teşhis yöntemleri arasında hızlı, kullanımı kolay ve gelişmiş cihaz kullanımına gerek kalmadan teşhis yapan testler arasında dot-blot assay (noktasal test-NT) olarak da bilinen, nokta şeklinde damlalar kullanılarak yapılan kağıt tabanlı testler hızlı tanı testleri arasında önemli bir yere sahiptir. Kağıt tabanlı biyolojik dedektörler, biyoyumlu olması, gözenekli yapıları, kolay modifiye edilmeleri, esneklikleri, çevre dostu olması, depolama ve taşınmalarının kolay olması gibi dikkat çekici özelliklerinden dolayı potansiyelleri oldukça yüksek olan testlerdir [18]. Nanopartikül tabanlı biyosensörler de, çevresel değişkenlere bağlı olarak basit, hızlı ve spesifik renk oluşturmalarından dolayı viral patojenlerin tespitinde kullanılabilir. Yeni özellikler kazandırılan altın nanopartiküller (AuNP'ler), farklı tip viral patojenlerin tespiti için oldukça doğru ve hassas biyosensörler olarak kullanılmaktadır [19] [20]. Bu anlamda nanopartikül kullanılarak geliştirilen kağıt tabanlı biyosensörlerin başında yine NT yöntemi gelmektedir. NT metodu, bir protein çözeltilisinin doğrudan nitroselüloz membran üzerine nokta olarak eklenmesini ifade eder. Bu sistemlerde protein örneğinin moleküler ağırlık bilgisi olmadığından, özellikle belirli bir antijenin farklı antikörlerle araştırılması veya bir karışımdaki belirli bir proteinin varlığının belirlenmesinde önemli yere sahiptir. Bu metod ile yalnızca antikör veya yakalayıcı ajanın özgüllüğünün biliniyor olması viral partiküllerin tespitini kolaylaştırmaktadır [21]. Pandemiye kadar SARS CoV-2 teşhisi için birkaç NT bildirilmiştir [22][23][24] fakat bu testler ya enfeksiyon sırasında hastada gelişen antikörlerin tayini [22][23] için ya da antijenik teşhiste sadece ikili antikörlerin sandviç test oluşturarak kullanılmasıyla [24][25][26] yapılmıştır. Araştırmalar hızlı, doğru ve uygun maliyetlerde yeni teknolojiler geliştirmeye yönelik devam etmektedir [27][28]. Bu bağlamda teşhis için ileri cihazların kullanımına gerek duymayan ve çıplak gözle analiz imkanı sunan kağıt tabanlı test tiplerinden biri olan NT testi hızlı ve doğru teşhis yapan testler arasındadır ve kullanım kolaylığı sunmaktadır. Ayrıca rekombinant antikör ve aptamer sandviçine dayalı NT henüz bildirilmemiştir.

Bu çalışmada SARS CoV-2'nin S proteinine özgü rekombinant antikör ve aptamer kullanılarak bu çiftin NT'de hızlı ve çıplak gözle viral teşhis için uygun olup olmadığı araştırılmıştır.

2. Materyal ve Metot

2.1. Materyal

SARS CoV-2 S proteinine özgü antikörün [29] rekombinant formu ve aptamer kullanılmıştır. Aptamer sekansı 5' ATC CAG AGT GAC GCA GCA TTT CAT CGG GTC CAA AAG GGG CTG CTC GGG ATT GCG GAT ATG GAC ACG T - 3' [30] şeklindedir ve thiol modifiyeli olarak Integrated DNA Technologies (IDT)'den satın alınmıştır. NT için nitroselüloz membran kullanılmıştır ve analit olarak ticari sentetik S proteini reseptör bağlayıcı domain (sRBD) satın alınmıştır. HAuCl₄.xH₂O, sodyum sitrat (Alpha Easer), fosfat tampon çözeltisi (PBS), TCEP Tris(2-carboxyethyl)phosphine hydrochloride ve gümüş geliştirme solüsyonu (Sigma) kullanılmıştır. Deney süresince

tüm solüsyonlar ultra saf su ile hazırlanmıştır. AuNP'lar ve NP'lerin aptamer ile konjuge halleri UV-Visible spektrofotometre ile analiz edilmiştir.

2.2. AuNP sentezi ve NT için hazırlanması

AuNP'lerin (13-14 nm) hazırlanması daha önceki çalışmamızda belirttiğimiz gibi yapıldı [5]. Kısaca 1mM HAuCl₄.xH₂O çözeltisi hazırlanarak kaynatıldı ve üzerine %1'lik sitrat çözeltisi eklendi [31]. Renk kırmızıya dönüşünce oda sıcaklığında soğumaya bırakıldı. NP'ler 30 dakika santrifüj edilerek 2 kat (2X) veya 4 kat (4X) konsantrasyon haline getirildi ve konjugasyonda kullanılmak üzere 4°C'de muhafaza edildi. Modifiye aptamerler önce TCEP ile 1 saat inkübe edildi ve konsantrasyon AuNP'lar ile karıştırılarak inkübe edildi. Konjugasyonun stabil kalması için oda sıcaklığında tuzla yaşlandırma işlemi yapıldı ve inkübasyon sonrası 12000 rpm de santrifüj edildi. Süpernatant atılarak buzağı serum albümin (BSA) ve sükröz içeren fosfat tamponu ile 2 kez yıkanarak aynı çözeltide yeniden süspanse edilerek 4°C'de saklandı.


2.3. NT'lerin hazırlanması

NT'ler en az ikili olarak hazırlanmıştır. Sandviç testi yapmak üzere antikor stoğundan 0.1, 0.2 ve 3 µg/mL konsantrasyonlarından 1 µL alınarak pipet ile membranın 1. noktasına (üst) ayrı ayrı nokta şeklinde immobilize edildi ve kurumaya bırakıldı. Daha sonra BSA ile 5 dakika bloklama yapıp kurutulduktan sonra sentetik analit 0.4 µg/mL sRBD'den 1 µL alınarak eklendi ve negatif kontrol olarak 2. noktaya (alt) PBS eklendi. Daha sonra kurutma yapılarak 3 kez PBST ile yıkama yapılmış ve 37°C'de tekrar kurutulmuştur. Takiben, aptamer/AuNP konjugasyonundan 1 µL alınarak membranın hem 1. hem de 2. noktasına eklendi ve 37°C'de kurutuldu. Tween-20 ile yıkama yapılarak 1 saat kurumanın ardından membrana bağlanan AuNP'lerin görünürlüğünü geliştirmek/arttırmak için her iki noktaya gümüş geliştirme solüsyonu olan A ve B solüsyonları 1:1 oranında katılarak 1'er µL damlatıldı ve 5-8 dakika süreyle karanlıkta bekletildi [32]. Daha sonra sodyum tiyosulfat çözeltisinden 1'er µL alınarak noktaların üzerine eklendi ve 2 dakika boyunca karanlıkta bekletildi. Son olarak PBST ile 3 kez yıkama yapıldı ve 1 saat kurumanın ardından sonuçlar gözlemlendi.

3. Bulgular

3.1. AuNP sentezi ve aptamer konjugasyonu

Sentezlenen AuNP'ların UV-Visible spektrofotometre ile ölçümünde maximum absorpsiyon değeri (λ_{max}) beklenildiği üzere 522 nm olarak ölçülmüştür (Şekil 1A). Konjugasyon sonrası λ_{max} değeri yine beklenildiği üzere 526 nm'ye kaymıştır (Şekil 1B) ve konjugasyonun başarılı olduğunu göstermiştir.



Şekil 1. AuNP'lerin konjuge edilmemiş (A) ve aptamer ile konjuge edildikten (B) sonra ölçülen λ_{max} değeri.


3.2. Sentetik analitin NT ile Tespiti

Viral sRBD proteini hedef olarak hazırlanan NT'lere uygulanmıştır ve NT'lerin çalışma prensibi Şekil 2'de şematik olarak gösterilmiştir. Gümüş zenginleştirme solüsyonu eklenmeden önce de AuNP'lar sayesinde noktalar tespit edilse de (Şekil 2, A1-A2) gümüş görünürlüğü iyileştirdiği için NT'lere eklenmiştir (Şekil 2, A3-A4, B-D). Farklı konsantrasyonlardaki AuNP'lar, antikor ve analit miktarına göre teşhis sonuçları da farklı olmuştur. Örneğin 4X AuNP kullanılan NT'lerde (Şekil 2, A-B) test noktaları 2X AuNP'lara (Şekil 2, C-D) göre kısmen daha belirgin olmuştur fakat non spesifik bağlanmaları da kuvvetlendirme ihtimaline karşın 2X AuNP'lar ile devam edilmiştir. Antikor/aptamer sandviç çiftinin NT'de etkinliğini kıyaslayabilmek adına aptamer/aptamer sandviç çifti ile de NT

hazırlanmıştır. Pozitif ile negatif test noktalarındaki nokta rengi yoğunlukları arasındaki fark aptamer çifti (Şekil 2, A3-A4) kullanıldığında net oluşmazken bu durum antikor/aptamer çifti kullanılan NT'lerde daha belirgin olmuştur (Şekil 2, B-D).

0.2 µg/mL antikor analiti yakalamada başarılı olsa da bloklanmamış (Şekil 2, C1-C2) ve bloklı membranlarda (Şekil 2, C3-C4), pozitif ve negatif test noktalarındaki ayırım net olarak görülmemiştir. Fakat yıkama pipetle yapıldığında pozitif ve negatif noktaların farkı daha belirgin olmuştur (Şekil 2, C7-C9). Özellikle C9 NT'de negatif test noktasında hiç arka plan sinyali oluşmamıştır ve pozitif test noktası belirgin şekilde görülmüştür. Noktaların oluşumu analit direkt NT'ye yüklendiğinde (Şekil 2, C5) konjugat ile karıştırıldıktan sonra yüklenmesine (Şekil 2, C6) oranla kısmen daha iyi olmuştur ve analit diğer bütün NT'lere direkt olarak yüklenmiştir.

Antikor miktarı biraz düşürüldüğünde bloklanmış membranlarda (Şekil 2, D1-D3) pozitif ve negatif test noktaları arasındaki fark bloklanmamış membrana göre daha belirgin olmuştur (Şekil 2, D4-D5) ve negatif test noktalarında arka plan sinyalleri diğer NT'lerle karşılaştırıldığında oldukça düşüktür.



Şekil 2. SARS CoV-2 S proteininin aptamer çifti (A) ve antikor/aptamer çifti (B-D) ile NT'de tespiti ve testin çalışma prensibi. Analit +: 1. noktaya (üst) analit eklenmesini, Analit - : 2. Noktaya (alt) negatif kontrol olarak PBS eklenmesini gösterir. A-B: 4X AuNP ve C-D: 2X AuNP konjugatı içerir. C) 0.2 µg/mL antikor kullanılmıştır. D) 0.1 µg/mL antikor kullanılmıştır. C3-C5, C7-C9 ve D1-D3 bloklı, C1-C2, C6 ve D4-D5 bloksuz membranlardır.

4. Tartışma ve Sonuç

Tasarlanan NT yönteminin yerinde ve cihaz kullanımına gerek kalmadan SARS CoV-2'nin teşhisine uygunluğu denenmiştir. Testin bu şekilde tasarımı literatür bilgilerine göre ve mevcut bildirilen NT'lerle [24][33] kıyaslandığında tarafımızca ilk kez yapılmıştır ve başarılı şekilde teşhis yaptığı gösterilmiştir. Ayrıca hazırlanan NT'ler direkt virüs teşhisine yönelik olduğu için, enfeksiyon sırasında yaklaşık 7-10 gün içerisinde gelişen antikorların teşhisini yapan ve tanının gecikmesine sebep olan NT'den [22][23] avantajlı görünmektedir. İlaven, NT'ler pozitif veya negatif test noktalarını net şekilde göstermiştir ve arka plan sinyalleri yüksek antikor konsantrasyonlarıyla hazırlanan NT'ler hariç, bazı araştırmalarda olduğu gibi yüksek [25] çıkmamıştır ve floresans işaretlemeye UV görüntülemeye [24] ihtiyaç duymaksızın çıplak gözle sonuç izlenmiştir. Bulgularda pozitif test noktalarının kısmen zayıf oluşmasının nedeni ticari olarak satılan ve farklı tedarikçilerden elde edilen analit-antikor-aptamer uyumunun ve afinitesinin tam olarak bildirilmemesi ve affinite zayıflığı olabilmektedir ve çalışmamızda da temel sebebin bu olduğu düşünülmektedir. Bulgulara genel olarak bakıldığında kullanılan AuNP'lar yoğunluk olarak teste uygun görünmüştür. Çünkü pozitif test noktalarından da anlaşılacağı üzere çıplak gözle analizde 2X AuNP'lardan daha az kullanılması yeterli renk değişimini sağlayabilir. PBS negatif kontrol olarak alındığında geliştirilen NT'ler net şekilde pozitif viral teşhisi yapmıştır ve negatif test noktalarında arka plan sinyalleri beklenildiği üzere düşük çıkmıştır. 0.1 µg/mL antikor kullanılan NT'lerin teşhis profilinde 0.2 µg/mL antikor kullanımına göre bloksuz membranlarda önemli ölçüde değişiklik olmazken bloklanan membranda noktaların renk yoğunluğu azalsa da pozitif teşhis başarılı şekilde gözlenmiştir ve negatif kontrol beklenildiği üzere görülmemiştir. Böylece çok az miktarda dahi antikor ile NT'de viral tespiti çıplak gözle yapılacağı bu araştırmada gösterilmiştir. Bu nedenle bir sonraki adım olarak bu şekilde hazırlanacak NT'ler ile ilgili

optimizasyonlar yapılarak klinik örneklerin kullanılması ve böylece nazo/orofarinjeal sürüntü örneklerinden direkt SARS CoV-2 teşhisi için ön çalışmalar başlatılmıştır. Çünkü tasarlanan NT'lerin hem araştırma hem de klinik validasyon çalışmaları açısından uygun olduğu ve geliştirilmesi gerektiği düşünülmüştür. Böylece olası viral salgınlarda yeni ortaya çıkan virüslerin teşhisi için alternatif hızlı tanı testlerinin geliştirilmesine de katkıda bulunacaktır.

Teşekkür

Çalışmada yardımları dokunan Dr. Irmak İÇEN TAŞKIN ve Eray TATLICI'ya teşekkür ederim.

Kaynakça

- [1] Alafeef, M., Dighe, K., Moitra, P., Pan, D. 2020. Rapid, ultrasensitive, and quantitative detection of SARS-CoV-2 using antisense oligonucleotides directed electrochemical biosensor chip. *ACS nano*, 14:17028-17045.
- [2] Ibrahim, N., Jamaluddin, N. D., Tan, L. L., Mohd Yusof, N. Y. 2021. A review on the development of gold and silver nanoparticles-based biosensor as a detection strategy of emerging and pathogenic RNA virus. *Sensors*, 21(15):5114.
- [3] Daniel, S. K., Pai, P. S., Sabbella, H. R., Singh, K., Rangaiah, A., Basawarajappa, S. G., Thakur, C. S. 2022. Handheld, low-cost, aptamer-based sensing device for rapid SARS-CoV-2 RNA detection using novel synthesized gold nanoparticles. *IEEE Sensors Journal*, 22(19): 18437-18445.
- [4] Amanat, F., Stadlbauer, D., Strohmeier, S., Nguyen, T. H. O., Chromikova, V., McMahon, M., Jiang, K., Arunkumar, G. A., Jurczyszak, D., Polanco, J., Bermudez-Gonzalez, M., Kleiner, G., Aydillo, T., Miorin, L., Fierer, D. S., Lugo, L. A., Kojic, E. M., Stoeber, J., Liu, S. T. H., Cunningham-Rundles, C., Krammer, F. 2020. A serological assay to detect SARS-CoV-2 seroconversion in humans. *Nature medicine*, 26(7):1033-1036.
- [5] Çam Derin, D., Gültekin, E., Gündüz, E., Otlu, B. 2024. Comparison of Six Aptamer-Aptamer Pairs on Rapid Detection of SARS-CoV-2 by Lateral Flow Assay. *Journal of AOAC International*, 107(3):464-470.211.
- [6] Antoine, D., Mohammadi, M., Vitt, M., Dickie, J. M., Jyoti, S. S., Tilbury, M. A., Johnson, P. A., Wawrousek, K. E., Wall, J. G. 2022. Rapid, Point-of-Care scFv-SERS Assay for Femtogram Level Detection of SARS-CoV-2. *ACS sensors*, 7(3):866-873.13.
- [7] Thippornchai, N., Pengpanich, S., Jaroenram, W., Kosoltanapiwat, N., Sukphopetch, P., Kiatpathomchai, W., Leaungwutiwong, P. 2024. A colorimetric reverse-transcription loop-mediated isothermal amplification method targeting the L452R mutation to detect the Delta variant of SARS-CoV-2. *Scientific reports*, 14(1):21961.
- [8] Lisi, S., Malerba, F., Quaranta, P., Florio, R., Vitaloni, O., Monaca, E., Bruni Ercole, B., Bitonti, A. R., Del Perugia, O., Mignanelli, M., Perrera, P., Sabbatella, R., Raimondi, F., Piazza, C. R., Moles, A., Alfano, C., Pistello, M., Cattaneo, A. 2024. Selection and characterization of human scFvs targeting the SARS-CoV-2 nucleocapsid protein isolated from antibody libraries of COVID-19 patients. *Scientific reports*, 14(1):15864.
- [9] Ge, S., Wu, R., Zhou, T., Liu, X., Zhu, J., Zhang, X. 2022. Specific anti-SARS-CoV-2 S1 IgY-scFv is a promising tool for recognition of the virus. *AMB Express*, 12(1):18.
- [10] Kim, H. Y., Lee, J. H., Kim, M. J., Park, S. C., Choi, M., Lee, W., Ku, K. B., Kim, B. T., Changkyun Park, E., Kim, H. G., Kim, S. I. 2021. Development of a SARS-CoV-2-specific biosensor for antigen detection using scFv-Fc fusion proteins. *Biosensors & bioelectronics*, 175:112868.
- [11] Tohari, T. R., Anshori, I., Baroroh, U., Nugroho, A. E., Gumilar, G., Kusumawardani, S., Syahrini, S., Yulianto, B., Arnafia, W., Faizal, I., Hartati, Y. W., Subroto, T., Yusuf, M. 2022. Development of a Single-Chain Variable Fragment of CR3022 for a Plasmonic-Based Biosensor Targeting the SARS-CoV-2 Spike Protein. *Biosensors*, 12(12):1133.
- [12] Kim, W., Song, E. S., Lee, S. H., Yang, S. H., Cho, J., Kim, S. J. 2024. A new DNA aptamer which binds to SARS-CoV-2 spike protein and reduces pro-inflammatory response. *Scientific reports*, 14(1):7516.
- [13] Yang, M., Li, C., Ye, G., Shen, C., Shi, H., Zhong, L., Tian, Y., Zhao, M., Wu, P., Hussain, A., Zhang, T., Yang, H., Yang, J., Weng, Y., Liu, X., Wang, Z., Gan, L., Zhang, Q., Liu, Y., Yang, G., Zhao, Y. 2024. Aptamers targeting SARS-CoV-2 nucleocapsid protein exhibit potential anti pan-coronavirus activity. *Signal transduction and targeted therapy*, 9(1):40.

- [14] Chen, Z., Wu, Q., Chen, J., Ni, X., Dai, J. 2020. A DNA Aptamer Based Method for Detection of SARS-CoV-2 Nucleocapsid Protein. *Virologica Sinica*, 35(3):351–354.20.
- [15] Yang, L. F., Kacherovsky, N., Panpradist, N., Wan, R., Liang, J., Zhang, B., Salipante, S. J., Lutz, B. R., Pun, S. H. 2022. Aptamer Sandwich Lateral Flow Assay (AptaFlow) for Antibody-Free SARS-CoV-2 Detection. *Analytical chemistry*, 94(20):7278–7285.
- [16] Erdem, A., Senturk, H., Yildiz, E., Maral, M. 2024. Optimized aptamer-based next generation biosensor for the ultra-sensitive determination of SARS-CoV-2 S1 protein in saliva samples. *International journal of biological macromolecules*, 281(Pt 1):136233.
- [17] Khan, R., Deshpande, A. S., Proteasa, G., Andreescu, S. 2024. Aptamer-based electrochemical biosensor with S protein binding affinity for COVID-19 detection: Integrating computational design with experimental validation of S protein binding affinity. *Sensors and Actuators B: Chemical*, 399:134775.
- [18] Kim, S., Lee, J. H. 2022. Current advances in paper-based biosensor technologies for rapid COVID-19 diagnosis. *Biochip journal*, 16(4):376-396.
- [19] Derin, D. C., Gültekin, E., Taşkın, I. İ., Yakupoğulları, Y. 2023. Development of nucleic acid based lateral flow assays for SARS-CoV-2 detection. *Journal of bioscience and bioengineering*, 135(2):87-92.
- [20] Najafabad, M. B., Rastin, S. J., Taghvaei, F., Khiyavi, A. A. 2022. A review on applications of gold nanoparticles-based biosensor for pathogen detection. *Advances in Natural Sciences: Nanoscience and Nanotechnology*, 13(3):033002.
- [21] Diamandis, E. P., Christopoulos, T. K. 1996. *Immunoassay*. Academic Press.
- [22] Apú, N., Madrigal-Redondo, G., Vega, M. H., Corrales-Aguilar, E., Segura-Ulate, I. 2023. Development of an instrument-free and low-cost ELISA dot-blot test to detect antibodies against SARS-CoV-2. *Open life sciences*, 18(1):20220577.
- [23] Norouzi, M., Truong, T., Jaenes, K., Warner, B. M., Vendramelli, R., Tierney, K., Kobasa, D., Tailor, N., Plant, P., Dos Santos, C., Babiuk, S., Ambagala, A., Pardee, K. 2023. Cell-Free Dot Blot: an Ultra-Low-Cost and Practical Immunoassay Platform for Detection of Anti-SARS-CoV-2 Antibodies in Human and Animal Sera. *Microbiology spectrum*, 11(2):e0245722. Advance online publication.215.
- [24] Celiker, T., Ghorbanizamani, F., Moulahoum, H., Guler Celik, E., Tok, K., Zihnioglu, F., Cicek, C., Serto, R., Arda, B., Goksel, T., Turhan, K., Timur, S., Yagci, Y. 2022. Fluorescent bioassay for SARS-CoV-2 detection using polypyrene-g-poly(ϵ -caprolactone) prepared by simultaneous photoinduced step-growth and ring-opening polymerizations. *Mikrochimica acta*, 189(5):202.
- [25] Connelly, G. G., Kirkland, O. O., Bohannon, S., Lim, D. C., Wilson, R. M., Richards, E. J., Tay, D. M., Jee, H., Hellinger, R. D., Hoang, N. K., Hao, L., Chhabra, A., Martin-Alonso, C., Tan, E. K. W., Koehler, A. N., Yaffe, M. B., London, W. B., Lee, P. Y., Krammer, F., Bohannon, R. C., Li, H. 2022. Direct capture of neutralized RBD enables rapid point-of-care assessment of SARS-CoV-2 neutralizing antibody titer. *Cell reports methods*, 2(8):100273.
- [26] Lee, J. H., Choi, M., Jung, Y., Lee, S. K., Lee, C. S., Kim, J., Kim, J., Kim, N. H., Kim, B. T., Kim, H. G. (2021). A novel rapid detection for SARS-CoV-2 spike 1 antigens using human angiotensin converting enzyme 2 (ACE2). *Biosensors & bioelectronics*, 171:112715.
- [27] Singh, B., Datta, B., Ashish, A., Dutta, G. 2021. A comprehensive review on current COVID-19 detection methods: From lab care to point of care diagnosis. *Sensors International*, 2:100119.
- [28] Wang, J., Drelich, A. J., Hopkins, C. M., Mecozzi, S., Li, L., Kwon, G., Hong, S. 2022. Gold nanoparticles in virus detection: Recent advances and potential considerations for SARS-CoV-2 testing development. *Wiley Interdisciplinary Reviews: Nanomedicine and Nanobiotechnology*, 14(1):e1754.
- [29] Tian, X., Li, C., Huang, A., Xia, S., Lu, S., Shi, Z., Lu, L., Jiang, S., Yang, Z., Wu, Y., Ying, T. 2020. Potent binding of 2019 novel coronavirus spike protein by a SARS coronavirus-specific human monoclonal antibody. *Emerg. Microbes Infect*, 9:382–385.
- [30] Song, Y., Song, J., Wei, X., Huang, M., Sun, M., Zhu, L., Lin, B., Shen, H., Zhu, Z., Yang, C. 2020. Discovery of Aptamers Targeting the Receptor-Binding Domain of the SARS-CoV-2 Spike Glycoprotein. *Analytical chemistry*, 92(14):9895–9900.
- [31] Huo, T. M., Peng, C. F., Xu, C. L., Liu, L. Q. 2006. Development of colloidal-gold-based immunochromatographic assay for the rapid detection of medroxyprogesterone acetate residues. *Food and Agricultural Immunology*, 17:183-190.

- [32] Liu, R., Zhang, Y., Zhang, S., Qiu, W., Gao, Y. 2014. Silver enhancement of gold nanoparticles for biosensing: from qualitative to quantitative. *Applied Spectroscopy Reviews*, 49(2):121-138.
- [33] Li, J., Zhang, Z., Gu, J., Stacey, H. D., Ang, J. C., Capretta, A., Filipe, C. D. M., Mossman, K. L., Balion, C., Salena, B. J., Yamamura, D., Soleymani, L., Miller, M. S., Brennan, J. D., Li, Y. 2021. Diverse high-affinity DNA aptamers for wild-type and B.1.1.7 SARS-CoV-2 spike proteins from a pre-structured DNA library. *Nucleic acids research*, 49(13):7267–7279.

Panoramik Radyograflarda Anatomik Yer İşaretlerinin Yapay Zeka Destekli Otomatik Tespiti

Tayyip Özcan^{*1}, Rümeysa Karayılan¹, Serkan Yılmaz²

^{*1}Erciyes Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği, KAYSERİ

²Ömer Halisdemir Üniversitesi Diş Hekimliği Fakültesi
Ağız Diş ve Çene Radyolojisi ABD, NİĞDE

(Alınış / Received: 18.11.2024, Kabul / Accepted: 25.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Anahtar Kelimeler

Tıbbi Görüntü Analizi,
Evrişimsel Sinir Ağları,
Panoramik Radyografi,
Anatomik Yer İşaretleri,
YOLO

Öz: Bilişim çağı ve yapay zekayla beraber bilgisayar bilimi diğer bilim dalları ile bir arada yürütülmeye başlamıştır ve ihtiyaç doğrultusunda bu çalışmalar artmaktadır. Radyolojik inceleme alanında da bilgisayar bilimi önemini gün geçtikçe arttırmaktadır. Panoramik radyografi de bu anlamda önemli alanlardan birisidir. Genç hekimlerin ve hekim adaylarının herhangi bir teşhis koyarken klinik tecrübe yetersizliğinin olması gibi olumsuz durumlardan dolayı panoramik radyograflar için bir karar destek programı oluşturulması amaçlanmıştır. Bu çalışmada, farklı YOLO (You Only Look Once) modelleri kullanılarak panoramik radyografi üzerindeki anatomik yer işaretlerinin tespiti otomatik olarak gerçekleştirildi ve karşılaştırmalar sonucunda en iyi tespit sağlayan modele karar verilmesi sağlanmıştır. Çeşitli internet sitelerinden elde edilen panoramik radyografi görüntülerinden oluşan veri setlerinin birleşimi kullanılmıştır. Toplam 14 anatomik yer işaretinin otomatik tespiti yapılmıştır. Sonuçta kullanılan performans metriğine göre YOLOv5 için 0.790, YOLOv8 için 0.802, YOLOv11 için 0.810 değerlerine ulaşılmıştır. Modellerin performans değerleri karşılaştırıldığında, anatomik yer işaretlerinin otomatik tespiti için en uygun modelin YOLOv11 olduğu sonucuna varılmıştır.

Artificial Intelligence-Assisted Automatic Detection of Anatomical Landmarks in Panoramic Radiographers

Keywords

Medical Image Analysis,
Convolutional Neural
Networks,
Panoramic Radiography,
Anatomical Landmarks,
YOLO

Abstract: In the era of information technology and artificial intelligence, computer science is increasingly being integrated with other scientific disciplines to meet growing demands. Its significance in the field of radiological examinations is becoming more pronounced with each passing day. Panoramic radiography stands out as a key area in this regard. To address challenges such as the lack of clinical experience among young physicians and medical students, this thesis aims to develop a decision support system for panoramic radiographs. In this study, different YOLO (You Only Look Once) models were used to automatically detect anatomical landmarks on panoramic radiography and to decide on the model that provides the best detection as a result of comparisons. A combination of datasets consisting of panoramic radiography images obtained from various websites was used. A total of 14 anatomical points were automatically detected. As a result, values of 0.790 for YOLOv5, 0.802 for YOLOv8, and 0.810 for YOLOv11 were achieved based on the performance metric. When the performance values of the models were compared, it was concluded that YOLOv11 was the most suitable model for automatic detection of anatomical landmarks.

1. Giriş

Teknolojinin ilerlemesiyle birlikte diş görüntüleme yöntemleri çeşitlenmiştir. Panoramik radyografi gibi modern görüntüleme teknikleri, diş sorunlarının daha hızlı ve etkili bir şekilde teşhis edilmesini sağlamış, bu da ortodontik tedavilerde başarıyı artırmıştır. Panoramik radyografi, tüm ağız ve çene-yüz bölgesinin kapsamlı bir şekilde görüntülenmesini sağlayan ve bu nedenle vazgeçilmez bir araç olarak kabul edilen bir tekniktir. Bu yöntem, geniş bir anatomik alanı tek bir film üzerinde inceleme fırsatı sunar. Müdahaleci olmayan yapısı ve tek bir çekimde ayrıntılı bilgi sağlama kapasitesi, panoramik radyografiyi çağdaş diş hekimliğinde önemli bir araç yapmaktadır [1].

Günümüzde yapay zekâ, tıp alanında ilerlemesini her geçen yıl hızla arttırmasıyla beraber radyografik görüntülerin okunması ve analiz edilmesi konusunda da doktorların işini oldukça kolaylaştıracak bir yer almayı başarmıştır. Panoramik radyografide yapay zekâ yöntemlerinin uygulanması da gitgide artmaktadır. Yapılan çalışmaların anatomik yer işaretlerinden çok panoramik radyografilerde eksik dişi veya çürümüş olan dişi bulmak üzere olduğu görülmektedir.

Literatür taramasında bu alanda araştırmacıların yoğun bir şekilde çalıştığı görülmektedir. İncelenen bazı çalışmalarda tıbbi görüntülerde yapay zekanın yerine bakıldığında: Michael Tran Duong ve arkadaşları, radyoloji kursiyerlerine daha iyi öğretim sağlayabilmek için yapay zekanın nasıl geliştirilebileceğine odaklanmayı amaçlamışlardır. Radyoloji eğitimini arttırmak için yapay zeka ile entegre bir çerçeve vurgulamışlardır. Yalnızca "Yapay Zekâ ile Arttırılmış Radyoloji" konusuyla kalmayıp "Hassas Tıp Eğitimi" olarak bilinen eğitimin de yapay zekâ ile şekillendirilebileceğini savunmuşlardır. Ayrıca "Yapay Zekâ Destekli Hassas Tıp Eğitimi" konusunun kursiyer ve eğitmenlere öğretim etkileşimlerinin yanı sıra genel iş akışı verimliliği ve teşhis doğruluğunu geliştirmeyi öğretmek daha iyi hasta sonuçlarına yol açacağı görüşündedirler [2]. Selma Güzel ve arkadaşları, panoramik diş röntgenlerine dayalı bir otomatik diş algılama ve etiketleme sistemi sunmuşlardır. Diş tespiti ve diş etiketleme aşamalarıyla nihai amaçları postmortem (ölüm sonrası) ve antemortem (ölüm öncesi) diş radyografilerinin karşılaştırılarak ölülere belirlemek olmuştur. Sistemde önce diş bölgeleri belirlenip algılama modülü her bölge için ayrı ayrı çalışmaktadır. SVM (destek vektör makinesi) tarafından sınıflandırılan modeller en uygun atlas tabanlı modele göre etiketlenir. Maliyet fonksiyonuna göre optimum model seçimi yapılmaktadır. Sonuç olarak uygulanan algoritmanın panoramik radyografik görüntülerde dişleri tespit etme ve etiketleme konusunda umut verici olduğu anlaşılmaktadır [3]. Li ve arkadaşları, Görüntü yer işareti tespiti alandaki başarılarına rağmen, anatomik işaretler arasındaki örtülü veya açık ilişkileri yakalamak için yüksek dereceli yapısal modellemelerin yeterince kullanılmadığını öngörmüşler ve çalışmalarında doğru anatomik yüz ve tıbbi (örneğin el, pelvis) yer işareti tespiti için topolojiye uyum sağlayan yeni bir derin grafik öğrenme yaklaşımı olan Derin Uyarlanabilir Grafik (Deep Adaptive Graph - DAG) sunmuşlardır. Önerdikleri yöntem, hem yerel görüntü özelliklerinden hem de küresel şekil özelliklerinden yararlanarak grafik sinyalleri oluşturmaktadır. İncelenen tüm veri kümelerinde önceki son teknoloji yaklaşımlarla karşılaştırdıkları niceliksel sonuçlar, hem sağlık hem de doğruluk açısından üstün performans göstermiştir [4]. İki boyutlu görüntülerde manuel yer işareti tespiti tıbbi uzmanlığa bağlıdır ve süreç zaman almaktadır. Bu nedenle Shoaleh Shahidi ve arkadaşları, görüntü kaydına dayalı olarak konik ışınli bilgisayarlı tomografi görüntüleri üzerindeki kraniofasiyal yer işaretlerinin (kafatası noktaları - landmarklar) otomatik lokalizasyonunu yapabilen bir yazılım üretmek ve doğruluğunu değerlendirmek için bir çalışma yapmışlardır. Manuel(gözlemci) ve otomatik algılama yöntemleri arasındaki her görüntüdeki her bir dönüm noktasının koordinat mesafelerindeki farkları hesaplamışlar ve ortalama hatalar olarak rapor etmişlerdir. Sistemin güvenilirlik katsayısı 0,89 iken gözlemcilerin güvenilirlik katsayısı 0,87 olarak belirlenmiştir ve bu çalışmanın doğruluğunun kabul edilebilir olduğunu göstermektedir [5].

Radyografi alanında YOLO ile yapılan bazı çalışmalara bakıldığında ise: Ayyıldız ve arkadaşları, YOLOv5'in periapikal radyografilerde dişleri tespit etmek ve numaralandırmak üzere eğitilebileceği hipotezini doğrulamak için çalışmalarda bulunmuşlardır. Yaptıkları çalışma sonucunda modeli eğitip precision (kesinlik), recall (duyarlılık) ve F1 skorlarını sırasıyla 0,9548, 0,9882 ve 0,9712 şeklinde bulmuşlar ve bu da periapikal radyografilerdeki dişlerin tespitinde YOLOv5 ile son derece iyi sonuçlar elde edildiğini göstermiştir. Diş hekimlerinin radyografik muayene süresini hızlandırabileceği ve deneyimsiz diş hekimlerinin YOLOv5 kullanarak hata oranını azaltabileceği sonucuna varılmıştır [6]. Raşî c arkadaşlarıyla birlikte gelişmiş YOLOv8 kullanarak alt çenedeki radyolüsent lezyonları otonom bir şekilde tespit edip segmentlere ayırabilen derin öğrenme modeli geliştirmek için çalışmalar yapmıştır. Veri tabanını geliştirmek için radyografik görüntüler üzerinde çeviri, ölçekleme, döndürme, yatay çevirme ve mozaik efektleri gibi tekniklerle artırma işlemleri uygulamışlardır. Artırma yapılmadan elde edilen precision, recall, mAP@50 (Mean Average Precision) ve mAP@50-95 değerleri sırasıyla %76, %75,5, %75,1 ve %48,3 olarak kaydedilirken, artırma teknikleriyle bu değerler sırasıyla %100, %94,5, %96,6 ve %72,2'ye yükselmiştir. Sonuçlara bakıldığında, sürekli evrimi ve çeşitli tıbbi alanlara entegrasyonu ile derin öğrenme modelinin, hasta bakımında devrim yaratma potansiyeline sahip olduğunu belirtmişlerdir [7]. Widiyasri ve arkadaşları, dental implant planlamasını basitleştirebilecek ve hızlandırabilecek 2

boyutlu ve gri tonlamalı konik ışınli bilgisayarlı tomografi görüntülerine dayalı alveolar kemik ve mandibular kanal tespiti için otomatik ve eş zamanlı bir sistem önermişlerdir. Bu sistemde YOLOv4'ün etkili bir versiyonu olan Dental-YOLO'yu, düşük ve yüksek ölçeklerde iki ölçekli özellik haritalarıyla tanıtmışlardır. Sistem performansı ortalama %99,46 hassasiyete ulaşmıştır. Sonuçlar, Dental YOLO tespit sisteminin dental implant cerrahisi ve cerrahi öncesi tedavi planlaması için yararlı olabileceğini düşündürmüştür [8]. Zeren, ekibiyle beraber çalışmasında, proksimal femoral kırıkların tespiti için veri artırma teknikleri kullanılarak 820'ye çıkardığı 410 X-ışını görüntüsünü kullanarak YOLOv4 algoritması ile eğitim gerçekleştirmiştir. Modelin eğitimi sonucunda %90,33 doğruluk oranıyla çok tatmin edici sonuçlar elde edilmiştir. Model, üç kat daha hızlı, ortalama 1,4 saniyelik bir tespit süresiyle hız açısından doktorları geride bırakmıştır. Yapay sinir ağlarının proksimal femoral kırıkları doğru bir şekilde belirleyebileceği gösterilmiştir [9]. Almufareh ve arkadaşları, MRI'da (Manyetik Rezonans Görüntüleme) beyin kanserlerini sınıflandırmak ve tespit etmek için en son derin öğrenme mimarilerinden yararlanan iki önemli nesne tanımlama çerçevesi olan YOLOv5 ve YOLOv7'nin kapsamlı bir analizini ele almışlardır. Beyin tümörü veri seti, menenjiyomlar, gliyomlar ve hipofiz tümörleri dahil olmak üzere üç ayrı sınıflı kapsamaktadır. Tüm kategoriler için duyarlılık (recall) puanları sürekli olarak 0,78 eşiğini aşmıştır. Bu bulgular, YOLO modellerinin beyin tümörlerini hassas bir şekilde tespit etme potansiyelini doğrulamıştır [10]. Lu, arkadaşlarıyla gerçekleştirdiği çalışmada, fetal ultrason görüntülerinde kardiyak anatomik yapı konumu ve segmentasyonu için YOLOX tabanlı derin örnek segmentasyon sinir ağı önermişlerdir. Dört odacıklı görünümün 13 tip anatomik yapısı için önerilen modelin ilk örnek segmentasyon yöntemi olduğunu söylemişlerdir. Çalışma sonucunda ortalama 0,835 doğruluk elde etmişlerdir. Uyguladıkları yöntem tahmin hızı açısından en iyi performansı elde etmiştir [11].

Anatomik yer işaretleri, incelenen bölgenin anatomik oluşumlarının neler olduğunu gösteren yer işaretleridir. Panoramik radyografide anatomik yer işaretlerinin tespit edilmesi, teşhis, tedavi planlaması ve izleme dâhil olmak üzere çeşitli tıbbi uygulamalar için çok önemlidir. Bu çalışmada da panoramik radyografilerdeki anatomik yer işaretlerinin yapay zekanın bir alt dalı olan derin öğrenme yönteminin modellerinden YOLO versiyonlarının kullanılarak belirlenmesi, elde edilen sonuçlara göre en iyi modele karar verilerek diş hekimleri için hem doğru ve optimum bilginin sağlanması hem de zamandan tasarruf edilmesi planlanmıştır.

Bu çalışmanın ana katkıları şu şekilde sunulabilir:

- Arama motorları yardımı ile panoramik radyografi görüntülerinden yeni bir veri seti oluşturulmuştur.
- Oluşturulan veri setinde, en kritik 14 anatomik yer işareti, bu alanda uzman diş hekimi tarafından etiketlenmiş ve model eğitime hazır hale getirilmiştir.
- Görüntü çoğullama yöntemlerinin performans etkisi incelenmiştir.
- Görüntü çoğullama ve YOLOv11 derin öğrenme modeli destekli önerilen yöntem ile en başarılı sonuç elde edilmiştir.

Çalışma bilgilerine daha ayrıntılı bir şekilde yer verilmesi için ikinci bölümde, kullanılan yöntemler ve materyaller kapsamlı bir şekilde açıklanmış, tercih edilme nedenleri ve önemleri belirtilmiştir. Üçüncü bölüm, yapılan araştırmalar sonucunda elde edilen bulguları detaylandırmaktadır. Dördüncü ve son bölümde ise bu bulguların sonuçları ve tartışmaları üzerinde durulmuştur.

2. Materyal ve Metot

Bu çalışmanın yöntem ve metot bölümü esasen iki ana aşamadan oluşmaktadır. İlk aşama, veri setinin hazırlanmasıyla ilgili süreçleri kapsamaktadır. İkinci aşamada ise, panoramik radyografilerdeki anatomik yer işaretlerinin otomatik olarak tespitini sağlamak amacıyla uygun derin öğrenme yönteminin seçilmesi ve yapılandırılması gerçekleştirilmiştir.

2.1. Veri Seti Oluşturma

Veri seti oluşturmak, bir derin öğrenme projesinin temel adımlarından biridir ve başarılı sonuçlar elde etmek için önemlidir. Veri seti oluştururken, projenin hedeflerine uygun ve güvenilir verileri toplamak ve düzenlemek kritiktir. İlk adım, projenin amacına uygun verileri tanımlamak ve kaynaklarını belirlemektir. Daha sonra, belirlenen kaynaklardan veri toplanmalı ve gerekli ön işleme adımları uygulanmalıdır. Bu ön işleme adımları, veri temizleme, eksik değerlerin doldurulması ve veri formatlarının standartlaştırılması gibi işlemler olabilmektedir.

Çalışma için çeşitli internet sitelerinden elde edilen panoramik radyografi görüntülerinden oluşan veri setlerinin birleşimi kullanılmıştır. Proje için gerekli olan panoramik radyograf görüntülerinin paylaşılması konusunda etik problemler yaşanabildiğinden isim olarak paylaşılan veriler de anonim olarak değiştirilmiştir.

2.1.1. Etiketleme Yöntemleri

Veri etiketleme bilindiği üzere, bir veri setindeki örneklerin doğru bir şekilde sınıflandırılması veya kategorize edilmesi işlemdir. Etiketleme yöntemlerini şu şekilde sıralamak mümkündür:

Manuel Etiketleme: İnsanların müdahalesini gerektirir ve genellikle el ile veya otomatik etiketleme algoritmalarıyla gerçekleştirilir. El ile etiketleme, insanların veri örneklerine bireysel olarak etiket eklemesiyle gerçekleşir ve bu yöntem yüksek kaliteli, hassas etiketler elde etmek için yaygın olarak kullanılır ama bu yöntem daha fazla zaman gerektirir.

Otomatik Etiketleme: Genellikle makine öğrenimi veya yapay zekâ algoritmaları kullanılarak gerçekleştirilir ve büyük miktarda veriyi hızlı şekilde işlemesine karşın, el ile etiketlemeye göre daha düşük doğruluk oranlarına sahip olabilmektedir.

Yarı Otomatik Etiketleme: Manuel ve otomatik etiketleme yöntemlerinin bir kombinasyonudur. Otomatik etiketlemeye göre daha yüksek doğruluk sağlarken, manuel etiketlemeye göre daha az zaman kaybına neden olur.

Kitle Kaynaklı Etiketleme: Birden fazla insan etiketleyicinin, genellikle çevrimiçi platformlar aracılığıyla veri etiketleme görevini tamamlamasıdır. Geniş veri setleri için etiketleme sürecini hızlandırır. Dikkatli bir değerlendirme ve doğrulama gerektirir.


Anatomik yer işaretlerinin bir uzman tarafından belirlenmesi ve gösterilmesi gerektiğinden etiketleme aşamasında uzmanlardan yardım alınmıştır. Etiketleme aracı olarak MakeSense kullanılmıştır. MakeSense, bir manuel etiketleme aracıdır ve insan doğruluğu, hassasiyeti gerektiren görevlerde mükemmel sonuçlar vermektedir. Aynı zamanda görüntü anotasyon projelerinde esneklik ve kontrol sunmaktadır. Bu nedenle, detaylı ve doğru etiketleme gerektiren bu projede MakeSense tercih edilmiştir.

2.1.2. Veri Ön İşleme ve Arttırma

İşlenecek veri seti üzerinde veri setinin çeşitliliğini ve kapsamını genişleterek modelin daha etkili şekilde öğrenmesini sağlayan veri boyutlandırma ve veri arttırma işlemleri gerçekleştirilmiştir.

Yeniden Boyutlandırma

Veri arttırma işlemi yapılmadan önce, görsellerin boyutları küçültülmüştür. Orijinal veri setlerinde yer alan görsellerin çözünürlüğü 2976 x 1536 pikseldir. Ancak, bu görseller 640 x 640 piksellik boyutlara indirilmiştir. Örnek bir yeniden boyutlandırma işlemi Şekil 1 ile sunulmuştur.




Şekil 1. Orijinal görsel ve boyutlandırılmış hali

Veri Arttırma

640 x 640 piksellik panoramik görüntülerin eğitim veri seti üzerinde Roboflow ile veri arttırma işlemleri gerçekleştirilmiştir. Bu işlemler flip (çevirme / tam aşağı döndürme), 90° rotate (90° çevirme) ve saturation %25 (%25 doygunluk ayarı)dır. Veri arttırma işlemlerinin ardından toplamda 767 yeni görüntü oluşturulmuştur.

Etiketlenen Anatomik Yer İşaretleri


Etiketleme işlemi için 767 adet görüntü kullanılmıştır. Eğitim için 706, validation (doğrulama) için 40 ve test için 21 görüntü bulunmaktadır. Veri kümesinden her bir gözlem bir panoramik görüntü ve birbirinin simetriği 7 bölgeden oluşan 14 yer işareti konumlarından oluşmaktadır.



- | | | |
|---|---|----------------------------------|
| 1. Pterigomaksiller fissür | 11. Nazal kavitenin tabanı | 22. Koronoid proses |
| 2. Maksillanın posterior sınırı | 12. Anterior nazal spina | 23. Ramusun posterior sınırı |
| 3. Tüber maksilla | 13. İnsiziv foramen | 24. Angulus mandibula |
| 4. Maksiller sinüs | 14. Sert damak / nazal kavitenin tabanı | 25. Hiyoid kemik |
| 5. Maksiller sinüsün tabanı | 15. Maksillanın zigomatik prosesi | 26. Mandibulanın inferior sınırı |
| 6. Maksiller sinüsün medial sınırı / nazal kavitenin lateral sınırı | 16. Zigomatik ark | 27. Mental foramen |
| 7. Orbita tabanı | 17. Artiküler eminens | 28. Mandibular kanal |
| 8. İnfraorbital kanal | 18. Dış kulak yolu | 29. Servikal vertebralar |
| 9. Nazal kavite | 19. Stiloid proses | 30. Epiglot |
| 10. Nazal septum | 20. Mandibula Kondili | |
| | 21. Sigmoid çentik | |

Şekil 2. Anatomik yer işaretlerinin bölgesel ayrımı

Projede tespit etmek için kullanılan 7 yer işareti ve simetrikleri aşağıda örnek görsel üzerinde gösterilmiştir.



Şekil 3. Etiketlenen yer işaretlerinin örnek görüntü üzerinde gösterimi

Şekil 3 ile gösterilen yer işaretlerinin isimleri sırasıyla aşağıdaki gibidir:

- Üst Sarı Bölge: Mandibula kondili
- Mor Bölge: Koronoid proses
- Mavi Bölge: Tüber maksilla
- Yeşil Bölge: Mandibular kanal
- Turuncu Bölge: Mental foramen
- Kırmızı Bölge: Angulus mandibula
- Alt Sarı Bölge: Hiyoid kemik

Görsellerin etiketlenmesi uzun zaman aldığından anatomik yer işaretlerinin hepsinin etiketlenmesi yerine seçilen, 7 yer işareti simetriği olmak üzere, 14 yer işareti kullanılacak modellerle tespit edilmek üzere ele alınmıştır.

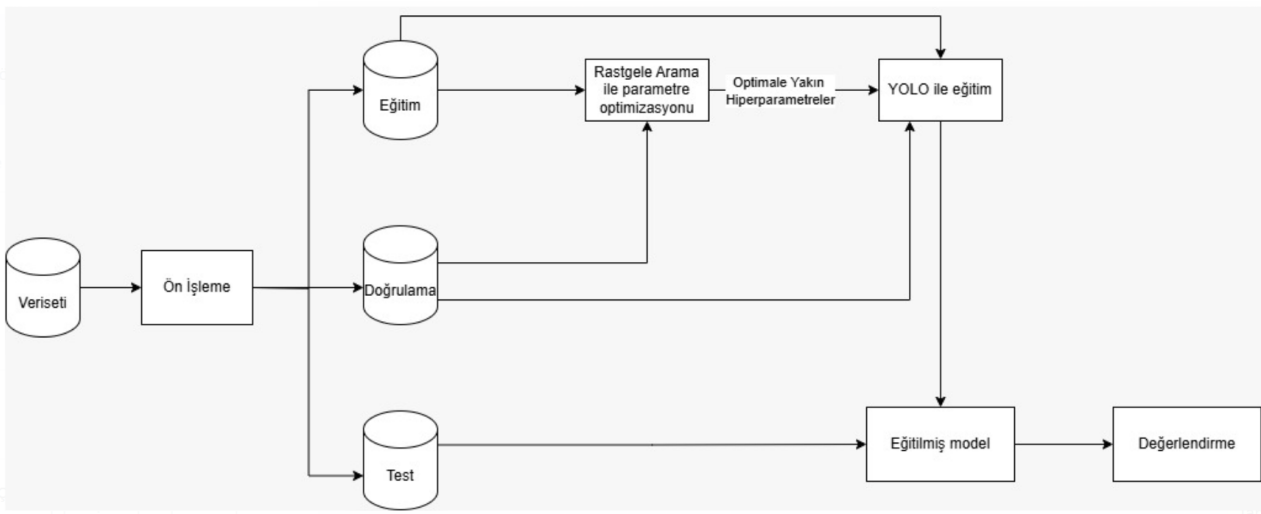
2.2. Önerilen Yöntem

Çalışma için kullanılacak YOLO modellerinin optimale yakın parametrelerle eğitilip en iyi sonuçların alınması için genel bir yöntem önerilmiştir. Rastgele Arama Yöntemi ile random (rastgele) bir şekilde farklı

hiperparametrelerin denenmesi ve optimale yakın parametrelerin model için uygulanması önerilen yöntemin temelini oluşturmaktadır. Yöntem şema halinde Şekil 4 ile daha net anlaşılmaktadır.

Derin öğrenme, doğal dil işleme, konuşma tanıma, nesne tanıma gibi çeşitli alanlarda kullanılan, çok katmanlı yapay sinir ağlarını temel alan bir yapay zekâ yöntemidir ve makine öğrenmesinin bir alt dalıdır. Geleneksel makine öğrenmesi yöntemlerinden farklı olarak, derin öğrenme sistemleri verileri (resimler, videolar, sesler ve metinler) doğrudan kodlanmış kurallar olmadan otomatik olarak analiz edebilir, bu verilerden öğrenebilirler [58]. Derin öğrenmede model seçimi, problemin çözüm sürecinde kritik bir rol oynar. Problemin özelliklerine uygun olarak seçilen model, çözümün etkinliğini artırabilir.

Bu çalışmada, otomatik panoramik radyograf analizi için yenilikçi bir yaklaşım önerilmiştir. Bu yaklaşım, çeşitli YOLO modellerinin (YOLOv5, YOLOv8, YOLOv11) tıbbi görseller üzerindeki instance segmentation (örnek segmentasyonu) başarısının kıyaslanması ve en uygun modele karar verilmesidir. Model, tek kanallı gri tonlu görüntüleri giriş olarak kullanılmaktadır. Eğitim süreçlerini hızlandırmak amacıyla, tüm modeller 640 x 640 piksel boyutundaki görüntülerle eğitilmiştir. Uzmanlar tarafından manuel olarak belirlenen 30 panoramik anatomik yer işaretinden, 14'ü bu model aracılığıyla otomatik olarak elde edilmiştir.

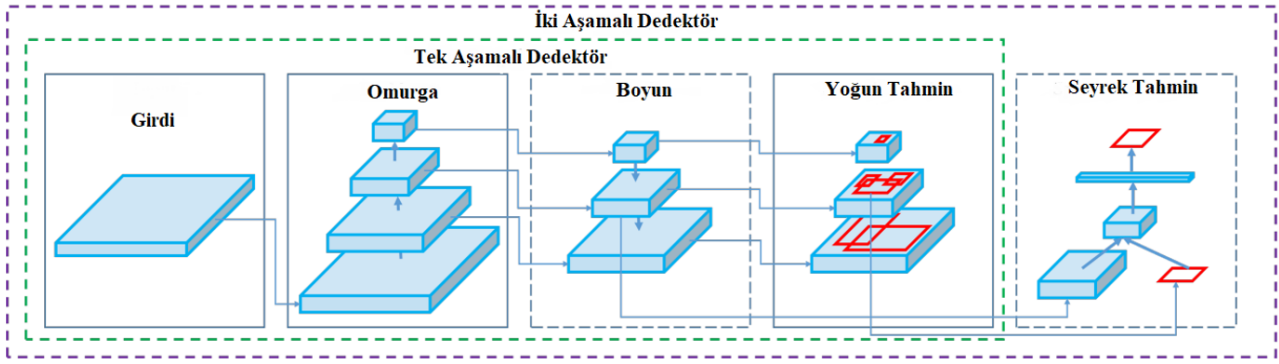


Şekil 4. Önerilen yöntemin şematik gösterimi

2.2.1. YOLO (You Only Look Once) Modeli

YOLO (You Only Look Once), ESA tarafından öğrenilen özellikleri kullanarak videolarda, canlı yayınlarda veya görüntülerde belirli nesnelere hızlı ve verimli bir şekilde tanımlayan, özellikle nesne tespiti (object detection) için kullanılan gerçek zamanlı bir nesne algılama algoritmasıdır. YOLO'nun temel çalışma prensiplerinden biri, görüntü üzerinde "sadece bir kez" işlem yaparak hem nesne sınıflandırması hem de nesne konumlandırması yapabilmesidir. Model, Evrimsel Sinir Ağları (Convolutional Neural Networks- CNN) temel alınarak geliştirilmiştir ve nesne tespitini, görüntüyü tek bir işlemde analiz ederek yapar. Normalde, derin sinir ağlarında tahminler yapmak için tam bağlı (fully connected) katmanlar kullanılır. Ancak, YOLO bu katmanlar yerine 1x1 evrimselleri verimli bir şekilde kullanarak, özellik haritasındaki bilgileri sıkıştırır ve daha az karmaşıklıkla tespitler yapar. Bu sayede, gerçek zamanlı uygulamalarda yüksek performans sunar. YOLO, tam da bu nedenden "sadece bir kez bakıyorsunuz" anlamına gelir.

Geleneksel nesne tespiti yöntemlerinden farklı olarak, YOLO görüntüyü gridlere böler ve her grid hücresi için potansiyel nesne tespiti yapar. Model, her grid hücresinde bir nesne olup olmadığını, nesnenin sınıfını ve sınır kutusu (bounding box) koordinatlarını tahmin eder. Bu model, hız ve doğruluğun bir arada gerektiği uygulamalar için oldukça uygundur. Nesnelere tespit etmek için tek bir CNN kullanarak görüntüdeki tüm nesnelere eşzamanlı olarak analiz etmesi, modeli diğer iki aşamalı modellerden (örneğin R-CNN) daha hızlı hale getirir. Bu nedenle, YOLO hem bilgisayarla görme (computer vision) hem de derin öğrenme uygulamaları için popüler ve etkili bir tekniktir [12]. YOLO'nun tüm versiyonları açık kaynaklıdır ve bu da onu araştırmacılar ve geliştirici topluluğu için erişilebilir hale getirir. Bu açık yapı, iş birliğini, iyileştirmeyi ve çeşitli uygulamaların geliştirilmesini teşvik etmektedir [13].



Şekil 5. YOLO model mimarisi [12]

2.2.2. Rastgele Arama Yöntemi (Random Search) ile Hiperparametre Optimizasyonu

Rastgele arama yöntemi, hiperparametre ayarlama süreçlerinde kullanılan bir optimizasyon tekniğidir. Bu yöntem, bir modelin performansını optimize etmek için hiperparametrelerin rastgele kombinasyonlarını belirli bir aralıkta veya kümede deneyerek en iyi sonuç veren kombinasyonu bulmaya çalışmaktadır. Hiperparametrelerin her biri için bir aralık veya olası değerler kümesi tanımlanır. Parametreler bu aralık veya kümeden rastgele seçilir. Her deneme için hiperparametre kombinasyonları bağımsız olarak oluşturulur. Rastgele seçilen hiperparametrelerle model eğitilir. Performans metrikleri (örneğin doğruluk, F1 skoru) ölçülerek en iyi kombinasyon belirlenir.

Yöntem kolayca uygulanabilir olduğundan ve hiperparametre alanında daha az deneme yaparak iyi sonuçlara ulaşabildiğinden avantajlıdır. Diğer taraftan, yöntemin rastgele doğası gereği, bazı önemli hiperparametre kombinasyonları denenemeyebilir. Her zaman en iyi kombinasyonu bulamayabilir.

Eğitim sonucunda en iyi değerlerin alınması için öncelikle bazı hiperparametreler Rastgele Arama Yöntemi ile düzenli aralıklarla değiştirilip alınan sonuçlar karşılaştırılmış ve buna göre en iyi sonuçların alındığı hiperparametre değerlerine karar verilmiştir. Bu değerler belirlenirken alt ve üst sınır olarak genelde kullanılan optimum aralık baz alınmıştır. Epoch için [40,70] aralığı, batch size için [16,64] aralığı, learning rate için [0.001,0.1] aralığı belirlenmiştir. Denemeler yapılarak en uygun epoch değeri 60, en uygun batch değeri 32, learning rate oranı 0.01 olarak seçilmiştir.

2.2.3. Çalışma İçin Kullanılan Değerlendirme Metrikleri

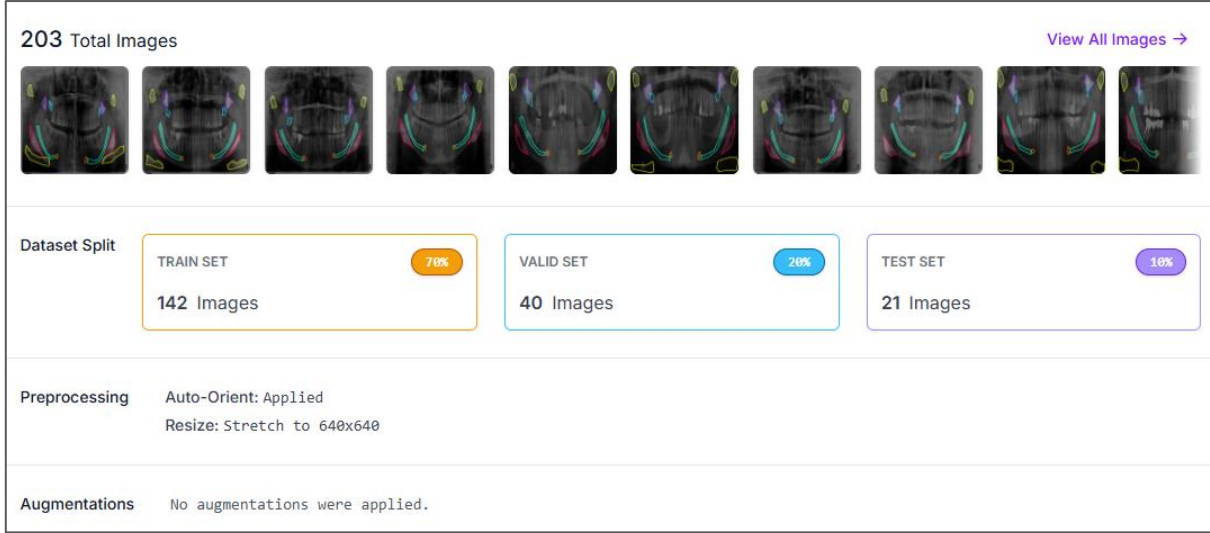
Çalışma YOLO modelleri ile anatomik yer işaretleri üzerinde instance segmentation (örnek segmentasyonu) olduğu için elde edilen sonuçlarda hem nesneyi içine alan box (kutu) değerlendirme metrikleri hem de mask (maske) değerlendirme metrikleri göz önünde bulundurulmuş ve iki ele alış şekline göre değerlendirmeler yapılmıştır. Box (kutu) hesaplamaları yalnızca nesnenin sınırlarını belirleyen kutuları hesaba katarken, mask (maske) hesaplamaları nesnenin tam şeklini yakalamaya çalışmaktadır. Bu nedenle, kutu ve maske tespiti için doğruluk oranları ve metrikler farklı olabilmektedir.

Genelde, maske tespiti için daha düşük değerler görülebilir çünkü maske tespiti daha karmaşık bir görevdir. Kutu doğru yerleştirilse bile, nesnenin şeklini doğru tahmin etmek, özellikle karmaşık nesnelere çalışırken, daha zor olmaktadır. İyi bir kutu (box) başarı tespit oranı, doğru konumlandırılmış nesnelerin olduğu ve bu nesnelerin şekil (mask) doğruluğunu da olumlu yönde etkileyeceğini göstermektedir. Ancak bazen şekil tespiti doğru olmasına rağmen, kutular yanlış yerleştirilebilmektedir. Bu nedenle box ve mask başarı tespit sonuçlarını beraber değerlendirmekte fayda vardır. Ayrıca iki konuyu aynı anda ele almak modelin hangi yönlerinin güçlü, hangi yönlerinin zayıf olduğunu belirlemekte yardımcı olabilmektedir.

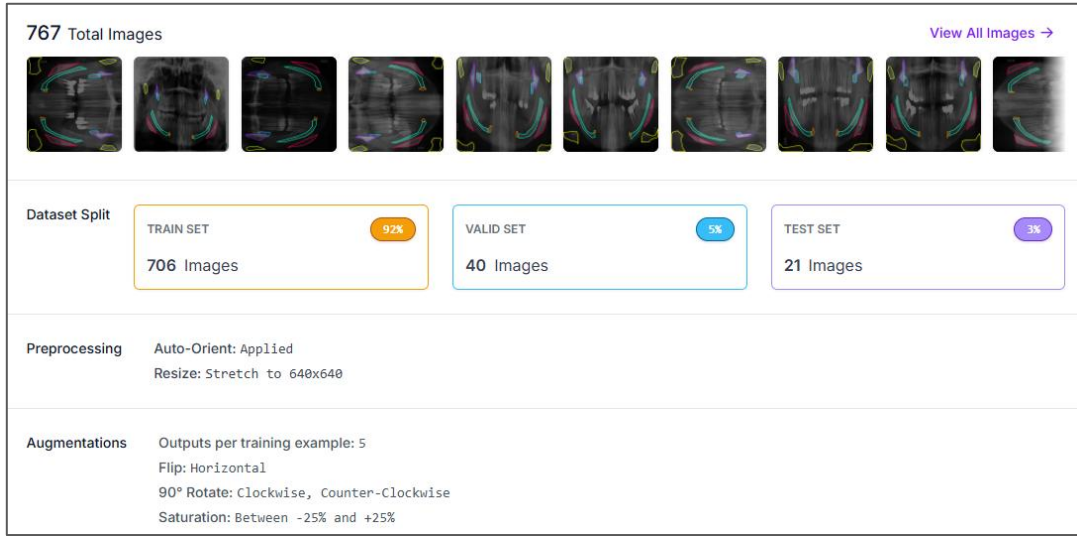
Tüm bu faktörler göz önünde bulundurulduğunda proje kapsamında analiz edilmesi gereken değerlendirme metrikleri box precision (BP - kutu kesinlik), box recall (BR- kutu duyarlılık), box mAP50 (BmAP50), box mAP50-95 (BmAP50-95), mask precision (MP - maske kesinlik), mask recall (MR - maske duyarlılık), mask mAP50 (MmAP50), mask mAP50-95 (MmAP50-95), box F1 (BF1), mask F1 (MF1), speed (çıkarma hızı) olarak ele alınmıştır.

3. Bulgular

Bu bölümde önerilen 3 modelin (YOLOv5, YOLOv8, YOLOv11) panoramik radyografi görselleri üzerinde anatomik yer işareti tespiti konusunda elde ettikleri başarı değerleri ve kayıplar değerlendirilip karşılaştırılmaktadır.



Şekil 6. 203 görüntünün ön işleme adımları



Şekil 7. Arttırma işlemleriyle oluşan 767 görüntü

Şekil 6.da gösterildiği gibi 203 görüntüden oluşan ve Şekil 7.de gösterildiği gibi çeşitli augmentation (arttırma) işlemlerinin yapılmasıyla oluşturulan 767 görüntüden oluşan 2 farklı veri seti üzerinde karar verilen hiperparametreler ile 2 farklı modelleme işlemleri yapılmış ve elde edilen değerler en sonda karşılaştırılarak gerekli değerlendirmeler yapılmıştır.

3.1. YOLOv5 ile Segmentasyon Sonuçları

YOLOv5, bilgisayarla görü uygulamalarında güçlü nesne tespiti ve segmentasyon performansı ile bilinen bir modeldir. Bu bölümde, YOLOv5 için elde edilen performans metriklerini ve eğitim sırasında kaydedilen önemli sonuçları incelenmektedir. Modelin tespit doğruluğu, mask (maske) ve box (kutu) açısından doğruluk değerleri, farklı kayıplar açısından analizi detaylı olarak tablolar ve grafikler halinde sunulmaktadır.

203 Görüntü ile Elde Edilen Değerler

Tablo 1. YOLOv5 203 Görüntü kutu için elde edilen değerler

| Sınıflar | P | R | mAP50 | mAP50-95 | F1 |
|-------------------|-------|-------|-------|----------|-------|
| Tümü | 0.649 | 0.642 | 0.622 | 0.236 | 0.644 |
| Coronoid | 0.683 | 0.575 | 0.594 | 0.134 | 0.622 |
| Foramenmentale | 1.000 | 0.000 | 0.006 | 0.001 | 0.000 |
| Hyoidbone | 0.488 | 0.889 | 0.779 | 0.265 | 0.628 |
| Mandibularangle | 0.578 | 1.000 | 0.989 | 0.409 | 0.732 |
| Mandibularcanal | 0.953 | 1.000 | 0.995 | 0.586 | 0.974 |
| Mandibularcondyle | 0.458 | 0.825 | 0.690 | 0.189 | 0.586 |
| Tubermaxilla | 0.381 | 0.208 | 0.306 | 0.068 | 0.268 |

Tablo 1 ile görüldüğü üzere box (kutu) tespiti açısından modelin tüm sınıflarına bakıldığında istenen değerler alınamamıştır. Sınıf bazında bakıldığında yalnızca Mandibularcanal sınıfının kesinlik ve duyarlılık değerleri istenen seviyededir. Diğer sınıflara bakıldığında modelin doğru pozitif değerleri bulamadığı (Hyoidbone), güvenilirliğinin artırılması (Mandibularcondyle) ve doğruluğunun iyileştirilmesi gerektiği (Mandibularangle), yeterli etiketleme olmadığı ve sınıf dengesizliğinin olduğu (Foramenmentale) anlaşılmaktadır.

Tablo 2. YOLOv5 203 Görüntü maske için elde edilen değerler

| Sınıflar | P | R | mAP50 | mAP50-95 | F1 |
|-------------------|-------|-------|-------|----------|-------|
| Tümü | 0.587 | 0.533 | 0.490 | 0.141 | 0.556 |
| Coronoid | 0.300 | 0.200 | 0.143 | 0.028 | 0.240 |
| Foramenmentale | 1.000 | 0.000 | 0.045 | 0.006 | 0.000 |
| Hyoidbone | 0.449 | 0.796 | 0.674 | 0.218 | 0.572 |
| Mandibularangle | 0.605 | 0.950 | 0.918 | 0.286 | 0.738 |
| Mandibularcanal | 0.769 | 0.800 | 0.684 | 0.164 | 0.382 |
| Mandibularcondyle | 0.472 | 0.812 | 0.689 | 0.211 | 0.596 |
| Tubermaxilla | 0.515 | 0.175 | 0.278 | 0.071 | 0.260 |

Tablo 2 ile mask (şekil) için elde edilen sonuçlara bakıldığında kutu tespiti bazında yapılan modellemelerden farklı olmadığı hatta değerlerin daha da düşük olduğu görülmektedir. Özellikle mAP50 ve mAP50-95 değerlerinin düşük olması modelin güvenilirliğinin az olduğunu göstermektedir ki bu durum da şekillerin istenen seviyede tespit edilememesinden kaynaklanmaktadır.

203 görüntü ile eğitim süresi 0.058 ölçülürken 767 görüntü ile 0.575 ölçülmüştür. Genel olarak eğitim süresiyle beraber hem box hem mask tespitleri açısından model incelendiğinde, veri setinin yeteri kadar büyük olmamasından kaynaklı, düşük başarı oranları elde edildiğinden aradaki eğitim süresi farkı göz ardı edilmiştir. Bunun neticesinde veri artırımı işlemleri yapılarak modellerin eğitilmesine karar verilmiştir.

Arttırma İşlemi Sonrası Oluşan 767 Görüntü ile Elde Edilen Değerler

Mevcut 203 görüntüden oluşan veri seti üzerinde 3 farklı augmentation işlemleri yapıp sonuçta 767 veri elde edilmiştir. Veri setinin büyüklüğü arttıkça model başarısının da doğru orantılı bir şekilde artacağı göz önünde bulundurulduğundan YOLOv5 modeli başta olmak üzere YOLOv8 ve YOLOv11 modellerinin eğitimlerinde de artırma işlemi sonrası 767 görüntüden oluşan veri seti kullanılmıştır.

Tablo 3. YOLOv5 767 Görüntü kutu için elde edilen değerler

| Sınıflar | P | R | mAP50 | mAP50-95 | F1 |
|-------------------|-------|-------|-------|----------|-------|
| Tümü | 0.847 | 0.853 | 0.832 | 0.390 | 0.848 |
| Coronoid | 0.826 | 0.838 | 0.783 | 0.241 | 0.830 |
| Foramenmentale | 0.532 | 0.525 | 0.442 | 0.120 | 0.526 |
| Hyoidbone | 0.841 | 0.870 | 0.857 | 0.401 | 0.854 |
| Mandibularangle | 0.980 | 0.988 | 0.986 | 0.506 | 0.982 |
| Mandibularcanal | 0.995 | 1.000 | 0.995 | 0.696 | 0.996 |
| Mandibularcondyle | 0.968 | 0.975 | 0.970 | 0.530 | 0.970 |
| Tubermaxilla | 0.785 | 0.775 | 0.788 | 0.236 | 0.778 |

Tablo 3 ile tahmin edilen kutu için elde edilen sonuçlara bakıldığında Mandibularange, Mandibularcanal ve Mandibularcondyle yer işareti bölgelerinin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin oldukça yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Bu da modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini göstermektedir. Foramenmentale ise precision ve recall açısından en düşük değere sahip anatomik yer işareti bölgesi olmuştur. Bu da modelin bu bölgeyi tespit ederken zorlandığını göstermektedir.

Tüm bölgeler açısından bakıldığında genel olarak F1 skoru iyi sonuç vermiştir ancak, mAP50-95 değerlerine bakıldığında modelin genel tespit hassasiyetinin iyileştirilmesi gerektiği görülmektedir.


Tablo 4. YOLOv5 767 Görüntü maske için elde edilen değerler

| Sınıflar | P | R | mAP50 | mAP50-95 | F1 |
|-------------------|-------|-------|-------|----------|-------|
| Tümü | 0.787 | 0.795 | 0.760 | 0.289 | 0.790 |
| Coronoid | 0.705 | 0.717 | 0.658 | 0.153 | 0.710 |
| Foramenmentale | 0.450 | 0.450 | 0.372 | 0.096 | 0.448 |
| Hyoidbone | 0.821 | 0.852 | 0.817 | 0.346 | 0.834 |
| Mandibularangle | 0.943 | 0.950 | 0.920 | 0.381 | 0.944 |
| Mandibularcanal | 0.870 | 0.875 | 0.858 | 0.260 | 0.872 |
| Mandibularcondyle | 0.988 | 0.996 | 0.994 | 0.576 | 0.990 |
| Tubermaxilla | 0.734 | 0.725 | 0.702 | 0.211 | 0.728 |


Tablo 4' teki gibi mask için elde edilen sonuçlarda da yine sınıflara göre bakıldığında Mandibularange, Mandibularcanal ve Mandibularcondyle yer işareti bölgelerinin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin nispeten en yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini gösterir demek mümkündür. Yine Foramenmentale, precision ve recall açısından en düşük değere sahip anatomik yer işareti bölgesi olmuştur. Bu da modelin bu bölgeyi tespit ederken zorlandığını göstermektedir.

Genel karşılaştırma yapıldığında modelin box yaklaşımında daha iyi bir sonuç verdiği açıktır. Bunun sebebi mask (şekil) tahmininin box (şekil etrafında bir kutu) tahmininden çok daha hassas detaylara sahip olması ve tahmin edilirliliğinin bu sebeple zor olmasıdır. Ayrıca, bu durum modelin konumlandırma konusunda başarılı olduğunu, ancak şekil segmentasyonu konusunda geliştirilmesi gerektiğini ortaya koymaktadır.

Sonuçlardan Elde Edilen Grafikler



Şekil 8. YOLOv5 kutu tespiti için elde edilen metrikler arası ilişkiler



Şekil 9. YOLOv5 maske tespiti için elde edilen metrikler arası ilişkiler


Şekil 8' de Box tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Mavi kalın çizgiyle gösterilen değer tüm sınıfların ortalamasını belirtmektedir.

Grafiklere bakıldığında mavi çizginin genel olarak başarılı sonuçlar elde ettiği ama turuncu çizgiyle belirtilen Foramenmentale sınıfının istenen sonuçları alamadığı gözlemlenmektedir.


Özellikle F1 - Confidence (F1 -Güven) grafiğine bakıldığında Foramenmentale değeri göz ardı edildiğinde sonuçların gayet başarılı olduğu söylenebilmektedir. Precision - Confidence (Kesinlik - Güven) grafiğine bakıldığında yine Foramenmentale sınıfı göz ardı edildiğinde diğer sınıfların oldukça yüksek performans sergilediği ve hatta kırmızı, mor ve kahverengi ile gösterilen Mandibularange, Mandibularcanal ve Mandibularcondyle sınıflarının 1'e yakın değerlerde ilerlediği görülmektedir. Aynı durum Recall - Confidence (Duyarlılık - Güven) grafiği için de geçerliliğini korumaktadır.

Mandibularcondyle sınıflarının 1'e yakın değerlerde ilerlediği görülmektedir. Aynı durum Recall - Confidence (Duyarlılık - Güven) grafiği için de geçerliliğini korumaktadır.

Şekil 9' da Mask tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Grafikselleştirilmiş olarak box tespiti sonuçlarına benzer sonuçlar elde edildiği görülse de ayrıntılı bakıldığında tüm grafiklerde daha az başarı oranı olduğu açıkça gösterilmektedir.



Şekil 10. YOLOv5 kayıp değerleri



Şekil 11. YOLOv5 karmaşıklık matrisi

Şekil 10' da modelin box kayıp (box_loss), segmentasyon (mask) kayıp (seg_loss), object detection (nesne tespiti) kayıp (obj_loss) ve sınıf tespitindeki kayıp (cls_loss) değerlerinin eğitim sırasındaki skorları gösterilmektedir. Kayıp değerlerinin zamanla azalması ve ortalama olarak düşük değerler alması model açısından olumlu yorumlanmaktadır. Şekil 11' de ise YOLOv5 için Confusion (karışıklık) matrisi ile her bir sınıfın True (gerçek) değerleri olma oranları gösterilmiş ve doğruluk 1'e yaklaştıkça renk koyulaşmıştır. Confusion matrixe göre bakıldığında en iyi değeri alan sınıf yine Mandibularcanal'dır.

3.2. YOLOv8 ile Segmentasyon Sonuçları

YOLOv8, nesne tespiti ve segmentasyon görevlerinde geliştirilmiş bir model yapısı sunarak, daha yüksek hassasiyet ve hız hedeflemektedir. Bu bölümde, YOLOv8 ile yapılan deneylerin sonuçları karşılaştırmalı olarak analiz edilmektedir. Yine modelin kutu ve maske açısından doğruluğu, F1 skorları ve mAP değerleri üzerinde durulmaktadır. Sonuçlar tablo ve grafikler halinde gösterilmektedir. Eğitim sonucunda en iyi değerlerin alınması için öncelikle bazı hiperparametreler Rastgele Arama Yöntemi ile düzenli aralıklarla değiştirilip alınan sonuçlar karşılaştırılmış ve buna göre en iyi değerlerin alındığı hiperparametre değerlerine YOLOv8 modeli için karar verilmiştir. Epoch için [40,70] aralığı, batch size için [16,64] aralığı, learning rate için [0.001,0.1] aralığı belirlenmiştir. Denemeler yapılarak en uygun epoch değeri 70, en uygun batch değeri 32, learning rate oranı 0.01 olarak seçilmiştir.

Arttırma İşlemi Sonrası Oluşan 767 Görüntü ile Elde Edilen Değerler

Tablo 5. YOLOv8 kutu için elde edilen değerler

| Sınıflar | P | R | mAP50 | mAP50-95 | F1 |
|-------------------|-------|-------|-------|----------|-------|
| Tümü | 0.844 | 0.860 | 0.840 | 0.423 | 0.850 |
| Coronoid | 0.798 | 0.793 | 0.781 | 0.246 | 0.794 |
| Foramenmentale | 0.543 | 0.562 | 0.492 | 0.112 | 0.552 |
| Hyoidbone | 0.821 | 0.889 | 0.856 | 0.478 | 0.852 |
| Mandibularangle | 0.983 | 1.000 | 0.995 | 0.504 | 0.990 |
| Mandibularcanal | 0.981 | 0.988 | 0.987 | 0.776 | 0.984 |
| Mandibularcondyle | 0.990 | 1.000 | 0.995 | 0.605 | 0.994 |
| Tubermaxilla | 0.794 | 0.787 | 0.774 | 0.241 | 0.788 |

Tablo 5' te tahmin edilen kutu için elde edilen sonuçlara bakıldığında yine Mandibularangle, Mandibularcanal ve Mandibularcondyle yer işareti bölgelerinin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin oldukça yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Bu da modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini göstermektedir. Foramenmentale ise precision ve recall açısından en düşük değere sahip anatomik yer işareti bölgesi olmuştur. Tüm bölgeler açısından bakıldığında genel olarak F1 skoru iyi sonuç vermiştir ancak, mAP50-95 değerlerine bakıldığında yine modelin genel tespit hassasiyetinin iyileştirilmesi gerektiği görülmektedir.

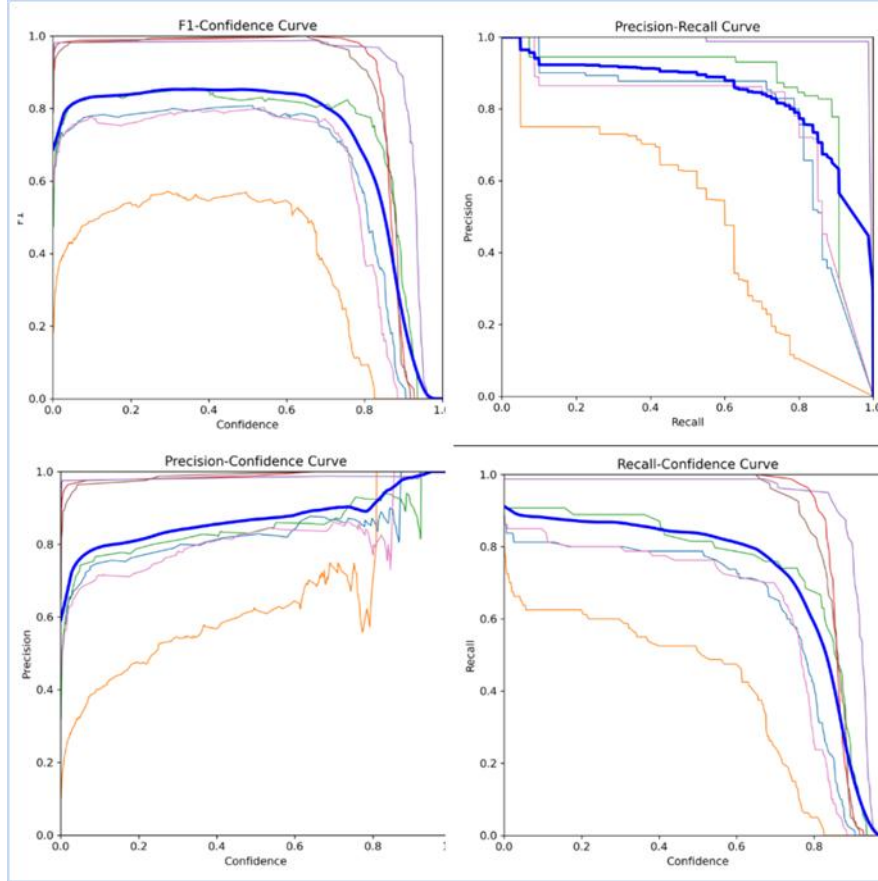
Tablo 6. YOLOv8 maske için elde edilen değerler

| Sınıflar | P | R | mAP50 | mAP50-95 | F1 |
|-------------------|-------|-------|-------|----------|-------|
| Tümü | 0.818 | 0.792 | 0.786 | 0.327 | 0.802 |
| Coronoid | 0.669 | 0.637 | 0.596 | 0.147 | 0.652 |
| Foramenmentale | 0.572 | 0.487 | 0.431 | 0.111 | 0.524 |
| Hyoidbone | 0.814 | 0.796 | 0.853 | 0.385 | 0.802 |
| Mandibularangle | 0.975 | 0.988 | 0.989 | 0.443 | 0.980 |
| Mandibularcanal | 0.909 | 0.912 | 0.924 | 0.372 | 0.910 |
| Mandibularcondyle | 0.995 | 1.000 | 0.995 | 0.619 | 0.996 |
| Tubermaxilla | 0.791 | 0.725 | 0.716 | 0.216 | 0.754 |

Tablo 6 ile görüldüğü üzere mask için elde edilen sonuçlarda da yine sınıflara göre bakıldığında Mandibularange, Mandibularcanal ve Mandibularcondyle yer işareti bölgelerinin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin nispeten en yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini gösterir demek mümkündür.

Genel karşılaştırma yapıldığında modelin box yaklaşımında daha iyi bir sonuç verdiği açıktır. Bunun sebebi mask (şekil) tahmininin box (şekil etrafında bir kutu) tahmininden çok daha hassas detaylara sahip olması ve tahmin edilirliliğinin bu sebeple zor olmasıdır. Ancak, YOLOv8 segmentasyon konusunda daha başarılı olduğu için şekil değerleri YOLOv5'e göre daha iyi sonuç vermiştir. Ama mAP50-95 değerlerine bakıldığında tespit hassasiyetinin artırılması gerektiği görülmektedir.

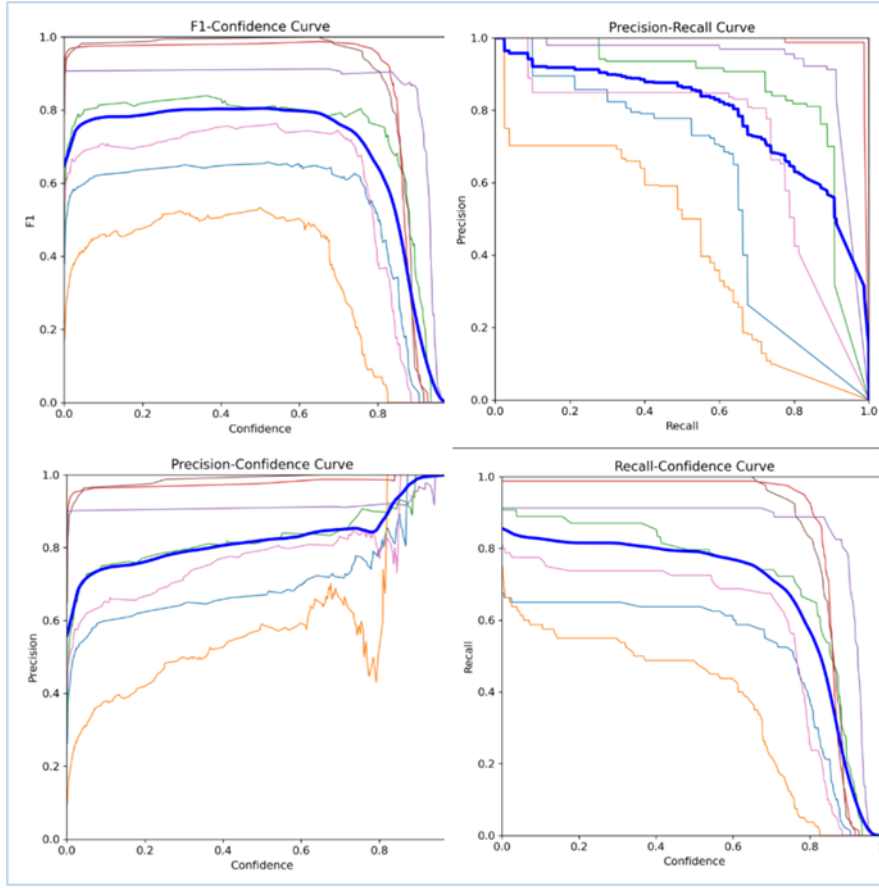
Sonuçlardan Elde Edilen Grafikler



Şekil 12. YOLOv8 kutu tespiti için elde edilen metrikler arası ilişkilere

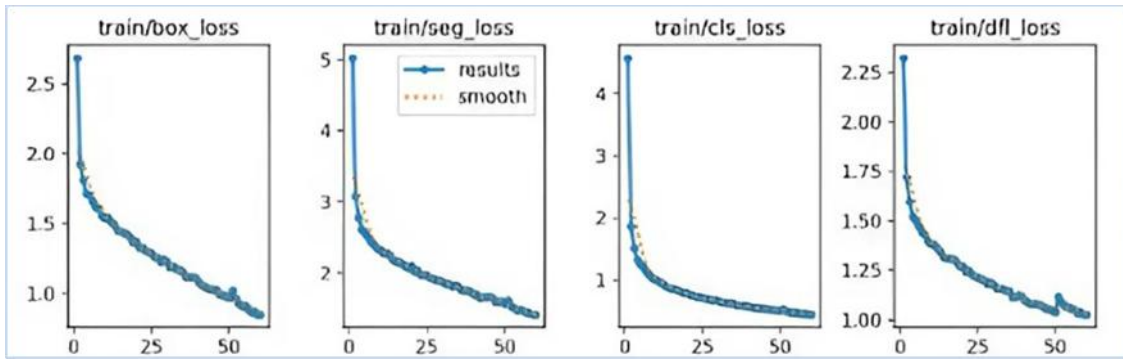
Şekil 12' de Box tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Mavi kalın çizgiyle gösterilen değer tüm sınıfların ortalamasını belirtmektedir. Grafiklere bakıldığında mavi çizginin genel olarak başarılı sonuçlar elde ettiği ama turuncu çizgiyle belirtilen Foramenmentale sınıfının istenen sonuçları alamadığı gözlemlenmektedir.

Özellikle F1 - Confidence (F1 -Güven) grafiğine bakıldığında Foramenmentale değeri göz ardı edildiğinde sonuçların gayet başarılı olduğu söylenebilmektedir. Hatta optimum seviyenin uzun bir süre korunduğu da gözlemlenmektedir. Precision - Confidence (Kesinlik - Güven) grafiğine bakıldığında yine Foramenmentale sınıfı göz ardı edildiğinde diğer sınıfların oldukça yüksek performans sergilediği ve hatta kırmızı, mor ve kahverengi ile gösterilen Mandibularange, Mandibularcanal ve Mandibularcondyle sınıflarının YOLOv5 sonuçlarına göre 1'e daha yakın değerlerde ilerlediği görülmektedir.




Şekil 13. YOLOv8 maske tespiti için elde edilen metrikler arası ilişkiler

Şekil 13 ile maske tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Grafikselleştirilerek box tespiti sonuçlarına benzer sonuçlar elde edildiği görülmektedir. Ancak mask için ayrıntılı bakıldığında tüm grafiklerde biraz az başarı oranı olduğu açıkça gösterilmektedir. Ancak başarılı tespiti seviyesini uzun süre korumasının mask için de sağlanabildiği gözlemlenmektedir. Bu durum YOLOv8 modelinin segmentasyon için oldukça güçlü bir model olduğunun kanıtı niteliğinde sayılmaktadır.



Şekil 14. YOLOv8 kayıp tespiti

Şekil 14 ile modelin kaybının hızlı bir şekilde azaldığı, bounding box tahminlerinin hızla geliştirildiği gösterilmektedir. Segmentasyon kaybının hızla düşüp, yavaşlayarak dengelendiği, modelin segmentasyon maskelerini öğrenmeye başladığı, süreç boyunca daha hassas hale geldiği görülmektedir. Sınıf tespitindeki kayıp hızla azalıp sabit bir noktaya yaklaşmakta, modelin sınıf tahminlerinde giderek daha az hata yaptığını göstermektedir. Bounding box koordinatları (dfl_loss - mesafe alan kaybı) ise modelin bounding box'larının konumunu daha hassas şekilde tahmin etmeye başladığını göstermektedir.



Şekil 15. YOLOv8 karmaşıklık matrisi

Şekil 15' te YOLOv8 için Confusion (karmaşıklık) matrisi ile her bir sınıfın True (gerçek) değerleri olma oranları gösterilmiş ve doğruluk 1'e yaklaştıkça renk koyulaşmıştır. Confusion matrisine göre bakıldığında en iyi değeri alan sınıflar Mandibularcanal, Mandibularangle ve Mandibularcondyle' dir.

3.3. YOLOv11 ile Örnek Segmentasyon Sonuçları

YOLOv11, daha yeni optimizasyon teknikleri ve model iyileştirmeleri içeren gelişmiş bir model sürümüdür. Bu bölümde, YOLOv11'in genel performansını detaylandırılmakta ve modelin yer işaretlerinin tespiti senaryolarındaki başarımı değerlendirilmektedir.

Önceki modellerde olduğu gibi aynı hiperparametreler Rastgele Arama Yöntemi değiştirilip sonuçlar karşılaştırılmış en iyi değerlerin alındığı hiperparametre değerlerine YOLOv11 modeli için karar verilmiştir. En uygun epoch değeri 60, batch değeri 32, learning rate oranı 0.01 olarak seçilmiştir.

Arttırma İşlemi Sonrası Oluşan 767 Görüntü ile Elde Edilen Değerler

Tablo 7. YOLOv11 kutu için elde edilen değerler

| Sınıflar | P | R | mAP50 | mAP50-95 | F1 |
|-------------------|-------|-------|-------|----------|-------|
| Tümü | 0.855 | 0.839 | 0.832 | 0.433 | 0.846 |
| Coronoid | 0.817 | 0.800 | 0.830 | 0.287 | 0.806 |
| Foramenmentale | 0.689 | 0.500 | 0.493 | 0.143 | 0.578 |
| Hyoidbone | 0.826 | 0.889 | 0.857 | 0.464 | 0.854 |
| Mandibularangle | 0.949 | 0.975 | 0.966 | 0.505 | 0.960 |
| Mandibularcanal | 0.983 | 0.988 | 0.980 | 0.779 | 0.984 |
| Mandibularcondyle | 0.980 | 0.988 | 0.987 | 0.589 | 0.982 |
| Tubermaxilla | 0.739 | 0.738 | 0.709 | 0.263 | 0.736 |

Tablo 7 incelendiğinde tahmin edilen kutu için elde edilen sonuçlara bakıldığında yine Mandibularange, Mandibularcanal ve Mandibularcondyle yer işareti bölgelerinin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin oldukça yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Bu modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini göstermektedir. Foramenmentale ise precision ve recall açısından en düşük değere sahip anatomik yer işareti bölgesi olmuştur yani model bu bölgeyi tespit ederken zorlanmıştır.

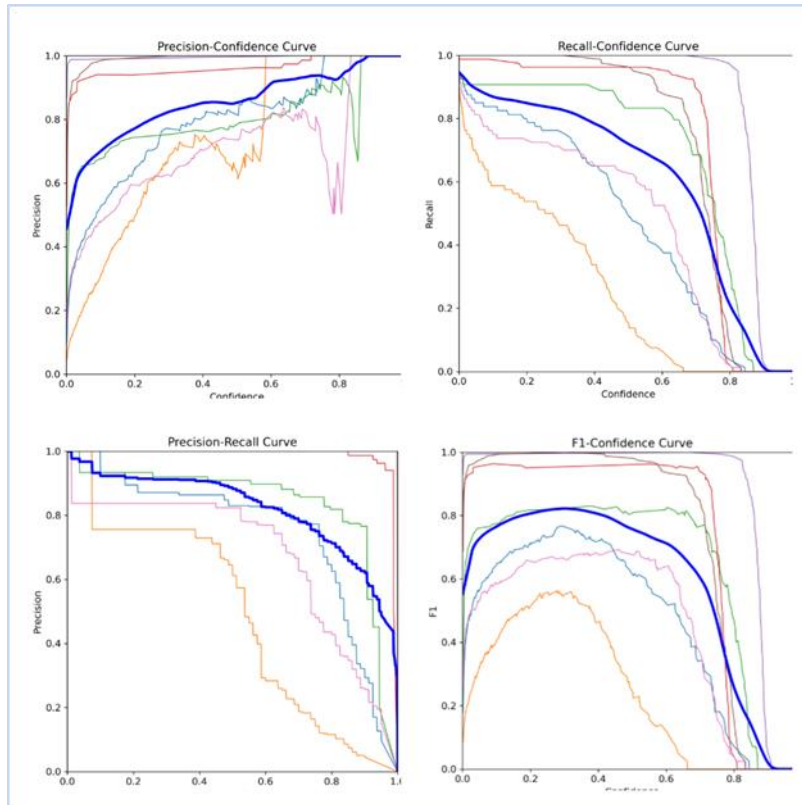
Tüm bölgeler açısından bakıldığında genel olarak F1 skoru iyi sonuç vermiştir, mAP50-95 değerlerine bakıldığında diğer modellere göre daha yüksektir ama modelin zorlayıcı eşik değerlerinde hala geride kaldığı söylenebilmektedir.

Tablo 8. YOLOv11 maske için elde edilen değerler

| Sınıflar | P | R | mAP50 | mAP50-95 | F1 |
|-------------------|-------|-------|-------|----------|-------|
| Tümü | 0.823 | 0.800 | 0.795 | 0.330 | 0.810 |
| Coronoid | 0.683 | 0.662 | 0.650 | 0.169 | 0.672 |
| Foramenmentale | 0.681 | 0.450 | 0.462 | 0.124 | 0.270 |
| Hyoidbone | 0.793 | 0.852 | 0.786 | 0.359 | 0.820 |
| Mandibularangle | 0.963 | 0.988 | 0.980 | 0.439 | 0.974 |
| Mandibularcanal | 0.921 | 0.925 | 0.941 | 0.375 | 0.920 |
| Mandibularcondyle | 0.981 | 0.988 | 0.987 | 0.598 | 0.984 |
| Tubermaxilla | 0.740 | 0.738 | 0.759 | 0.248 | 0.738 |

Tablo 8 incelendiğinde modelin box yaklaşımında daha iyi bir sonuç verdiği açıktır. Bunun sebebi mask (şekil) tahmininin box (şekil etrafında bir kutu) tahmininden çok daha hassas detaylara sahip olması ve tahmin edilirliliğinin bu sebeple zor olmasıdır. Ancak, segmentasyon konusunda YOLOv8'e göre biraz daha iyi sonuç vermiştir. Ama mAP50-95 değerlerine bakıldığında tespit hassasiyetinin hala artırılması gerektiği görülmektedir.

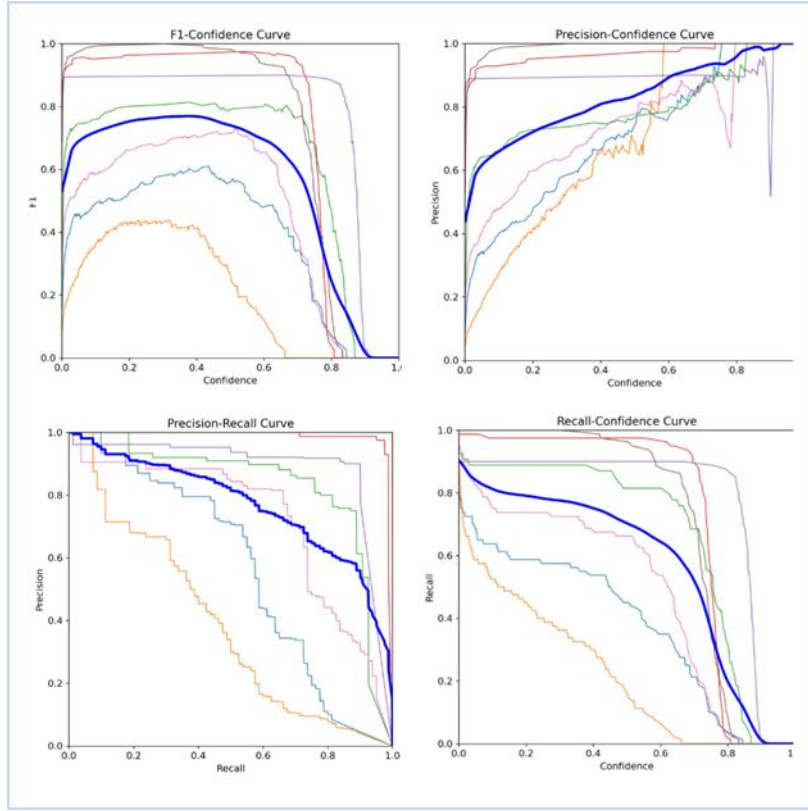
Sonuçlardan Elde Edilen Grafikler



Şekil 16. YOLOv11 kutu tespiti için elde edilen metrikler arası ilişkiler

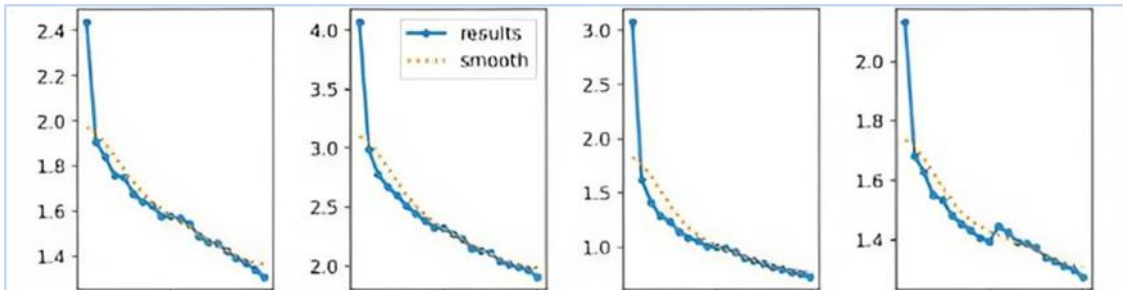
Şekil 16' da Box tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Mavi kalın çizgiyle gösterilen değer tüm sınıfların ortalamasını belirtmektedir. Grafiklere bakıldığında mavi çizginin genel olarak başarılı sonuçlar elde ettiği ama turuncu çizgiyle belirtilen Foramenmentale sınıfının istenen sonuçları alamadığı gözlemlenmektedir. Aynı zamanda önceki model grafikleriyle kıyaslandığında grafiklerdeki ortalamayı gösteren mavi çizginin YOLOv8deki gibi başarılı değerde uzun süre kaldığı söylenememektedir.

F1 - Confidence (F1 -Güven) grafiğine bakıldığında Foramenmentale değeri göz ardı edildiğinde sonuçların genel olarak başarılı olduğu söylenebilmektedir. Precision - Confidence (Kesinlik - Güven) grafiğine bakıldığında kırmızı, mor ve kahverengi ile gösterilen Mandibularange, Mandibularcanal ve Mandibularcondyle sınıflarının oldukça yüksek değerler aldığı ama diğer sınıflar için aynı şeyin söylenemeyeceği açıktır. Aynı durum Recall - Confidence (Duyarlılık - Güven) grafiği için de geçerliliğini korumaktadır.



Şekil 17. YOLOv11 maske tespiti için elde edilen metrikler arası ilişkiler


Şekil 17' de Mask tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Grafikselsel olarak box tespiti sonuçlarına benzer sonuçlar elde edildiği görülse de mask için ayrıntılı bakıldığında tüm grafiklerde daha az başarı oranı olduğu açıktır.



Şekil 18. YOLOv11 Loss (kayıp) değerleri

Şekil 18' deki grafik değerlerinde modelin (box_loss) kaybının azaldığı, bounding box tahminlerinin geliştirildiğini gösterilmektedir. Segmentasyon kaybının (seg_loss) belirgin şekilde iyileştiği, ancak bu kaybın hâlâ nispeten yüksek olduğu söylenebilmektedir. Sınıf tespitindeki kayıp (cls_loss) nesnelere doğru sınıflandırmada sürekli bir

ilerleme kaydetmiştir. Bounding box koordinatları (df_l loss – mesafe alan kaybı) ise modelin bounding box sınırlarını giderek daha iyi öğrendiği görülmektedir.



Şekil 19. YOLOv11 Confusion Matrix

Şekil 3.19’ da YOLOv11 için Confusion (karmaşıklık) matrisi ile her bir sınıfın True (gerçek) değerleri olma oranları gösterilmiş ve doğruluk 1’e yaklaştıkça renk koyulaşmıştır. Confusion matrisine göre bakıldığında en iyi değeri alan sınıflar Mandibularcanal, Mandibularange ve Mandibularcondyle’ dir.

3.4. Eğitilen Modellerin Karşılaştırılması

Bu bölümde YOLOv5, YOLOv8 ve YOLOv11 modellerinin sonuçları farklı değerlendirme metrikleri açısından karşılaştırılmaktadır. Her modelin doğruluk, hız ve işlem kapasitesi gibi önemli faktörler dikkate alınarak performans analizi yapılmıştır. Ayrıca, segmentasyon ve nesne tespiti görevlerinde elde edilen metrikler üzerinden modellerin güçlü ve zayıf yönleri incelenmiştir. Bu karşılaştırma, her modelin belirli veri kümesi ve uygulama senaryoları için ne kadar uygun olduğunun daha net anlaşılması için yapılmıştır.

Tablolar Bazında Modellerin Karşılaştırılması

Tablo 9. Tüm modellerin kutu tespiti için F1, mAP50, mAP50-95 değerleri

| Model | F1 | mAP50 | mAP50-95 | Eğitim Süresi |
|---------|-------|-------|----------|---------------|
| YOLOv5 | 0.848 | 0.832 | 0.390 | 0.705 |
| YOLOv8 | 0.850 | 0.840 | 0.423 | 0.625 |
| YOLOv11 | 0.846 | 0.832 | 0.433 | 0.528 |

Tablo 9 değerlerine bakıldığında box tespiti için F1 metriğinde en başarılı skora YOLOv8’in sahip olduğu görülmektedir. Bu YOLOv8’in daha dengeli bir performans sunduğunu göstermekteyken öte yandan YOLOv5 ve YOLOv11 de oldukça yakın performans sergilemişlerdir. Aynı zamanda mAP50 değerinde de yine YOLOv8 diğerlerinden daha yüksek performans göstermiştir. mAP50-95 değerinde YOLOv11 öne çıkmakta ve bu sonuca göre YOLOv11’in daha karmaşık senaryolardaki kutu tespiti için performans sunduğu söylenebilmektedir. Sonuç olarak, YOLOv8 genelde ön plana çıkarken YOLOv11 eğitim süresinin diğerlerinden düşük olması ve mAP50-95

değerinden dolayı tercih edilebilir seviyede görünmektedir. YOLOv5 dengeli bir performans sergilediği halde diğer modellerden geri kalmaktadır.


Tablo 10. Tüm modellerin maske tespiti için F1, mAP50, mAP50-95 değerleri

| Model | F1 | mAP50 | mAP50-95 | Eğitim Süresi |
|---------|-------|-------|----------|---------------|
| YOLOv5 | 0.790 | 0.760 | 0.289 | 0.705 |
| YOLOv8 | 0.802 | 0.786 | 0.327 | 0.625 |
| YOLOv11 | 0.810 | 0.795 | 0.330 | 0.528 |


Tablo 10 değerlerine bakıldığında mask tespitinde F1 metriklerinde en başarılı skora sahip olan model YOLOv11 olduğu görülmektedirken YOLOv8 az farkla onu takip etmektedir. mAP50 metriği için en iyi performansı sergileyen YOLOv11, mAP50-95 metriğinde de öne çıktığı gözlemlenmektedir. Az farkla YOLOv8 de onu takip etmektedir. Eğitim süresi olarak da yine YOLOv11 avantajlı görünmektedir. Sonuçta mask tespiti için YOLOv11 modelinin daha başarılı olduğu ve tercih edilebilir olduğu gözlemlenmektedir.

Grafiksel Olarak Modellerin Karşılaştırılması


Bu kısımda YOLOv5, YOLOv8 ve YOLOv11 modellerine ait değerlendirme metrikleri grafikler şeklinde karşılaştırılmış ve en iyi model ortaya konulmuştur. Şekil 20, Şekil 21, Şekil 22 ve Şekil 23'te karşılaştırılan grafikler bakıldığında YOLOv8'in genel olarak tüm değerlerde stabil ve başarılı değerler aldığını göstermektedir. YOLOv11'in de yine yüksek değerlere ulaştığı ama bazı sınıflarda fazla dalgalanmalar yaşandığı görülmektedir. Bu durum dalgalanma olan sınıflarda daha az güvenli tahminler yapıldığını göstermektedir. Diğer yandan YOLOv8 eğrisinin daha pürüzsüz ve az dalgalı olması modelin daha tutarlı olduğunu göstermektedir. YOLOv11 ise bu tutarlılığa sahip olmadığı görülmektedir.




Şekil 20. Kesinlik değerlerine göre model grafikleri



Şekil 21. Duyarlılık değerlerine göre model grafikleri



Şekil 22. Kesinlik - Duyarlılık değerlerine göre model grafikleri



Şekil 23. F1 değerlerine göre model grafikleri


Örnek Görüntü Etiketlemeleri ile Modellerin Karşılaştırılması

Bu bölümde her bir model için örnek görüntü üzerinde segmentasyon işleminin her sınıf üzerindeki başarımları karşılaştırılmaktadır.




Şekil 24. YOLOv5 örnek görüntü üzerinde etiketlenen bölgelerin gösterimi

Şekil 24' te YOLOv5 için örnek bir görüntü üzerinde anatomik yer işaretlerinin tespitindeki başarımları gösterilmektedir. Bu görüntüye bakıldığında Mandibularcondyle 0.69, Coronoid 0.58, Tubermaxilla 0.30 ve 0.36, Mandibularcanal 0.77, Mandibularangle 0.56 ve 0.60, Hyoidbone 0.74 ve 0.67 değerlerini almış, Foramenmentale ise tespit edilememiştir.



Şekil 25. YOLOv8 örnek görüntü üzerinde etiketlenen bölgelerin gösterimi

Şekil 25' te YOLOv8 için örnek bir görüntü üzerinde anatomik yer işaretlerinin tespitindeki başarımları gösterilmektedir. Bu görüntüye bakıldığında Mandibularcondyle 0.90 ve 0.86, Coronoid 0.77 ve 0.69, Tubermaxilla 0.82 ve 0.83, Mandibularcanal 0.87 ve 0.91, Mandibularangle 0.73, Hyoidbone 0.80 değerlerini almış, Foramenmentale ise yine tespit edilememiştir.



Şekil 26. YOLOv11 örnek görüntü üzerinde etiketlenen bölgelerin gösterimi

Şekil 26' da YOLOv11 için örnek bir görüntü üzerinde anatomik yer işaretlerinin tespitindeki başarımları gösterilmektedir. Bu görüntüye bakıldığında Mandibularcondyle 0.64 ve 0.76, Coronoid 0.39 ve 0.57, Tubermaxilla 0.57 ve 0.69, Mandibularcanal 0.84 ve 0.83, Mandibularangle 0.74 ve 0.74, Hyoidbone 0.73 ve 0.79, Foramenmentale 0.31 ve 0.27 değerlerini almıştır.

Modellerin hepsi bir arada değerlendirildiğinde YOLOv8'in tespit değerlerinin yüksek olduğu gözlemlenmektedir. Diğer taraftan YOLOv11 görsel üzerinde daha fazla tespitte bulunabilmiş ve Foramenmentale diğer modellerde bulunamazken YOLOv11 ile tespit edilebilmiştir. Fakat bu görseller yüzlerce görüntü arasından yalnızca birini ifade ettiğinden modeller hakkında net bilgi, elde edilen tablolar ve grafikler tarafından sağlanmaktadır.

Nihai Sonuç

Grafikler, modelin eğitim sürecini, loss (hata) değerlerindeki düşüşü ve optimizasyon davranışını anlamak için önemliyken tablolar, eğitim süreci tamamlandıktan sonra, modelin gerçek performansını ölçen nihai metriklere odaklanmaktadır.

Grafiklere bakıldığında, YOLOv8 daha avantajlı görünmektedir. Bu, modelin daha hızlı ve kararlı bir şekilde loss değerlerini azaltarak optimize olduğunu ve eğitim sırasında daha iyi bir öğrenme kapasitesine sahip olduğunu göstermektedir. Tablolara bakıldığında ise, YOLOv11'in özellikle mAP50-95 gibi farklı eşiklerde daha yüksek doğruluk göstermesi ve mask tespitindeki üstünlüğü, modelin farklı görevlerde daha iyi genelleştirdiğini ve özellikle mask tespiti gibi detaylı analizlerde daha başarılı olduğunu ortaya koymaktadır.

Hem metriklere hem de grafiklere bakarak tutarlılık ve genel performans istenirse, YOLOv8 biraz daha dengeli bir model olarak değerlendirilmektedir. En yüksek doğruluk metrikleri ve kısa eğitim süresiyle üstün olan model ise YOLOv11'dir.

4. Tartışma ve Değerlendirme

Panoramik radyografi, dişler, çeneler, göz çukurunun üst kısmı, maksiller sinüsler, mandibula ve temporomandibuler eklem gibi geniş bir bölgeyi kapsayarak tüm bu yapıların birlikte görüntülenmesini sağlar. Bu nedenle, medikal görüntüleme açısından önemli bir klinik ve araştırma aracıdır [14]. Ancak, anatomik işaretlerin tanımlanması genellikle zor ve zaman alıcı bir süreçtir, bu yüzden otomatik yöntemlerin geliştirilmesi büyük önem taşır. Farklı radyografi türleri üzerinde otomatik anatomik işaret tespiti ile ilgili çalışmalar yapılmış olsa da panoramik radyografi görüntüleri üzerindeki araştırmalar daha sınırlıdır.

Bu çalışmanın amacı, panoramik anatomik yer işaretlerini otomatik olarak doğru ve güvenilir bir şekilde tespit etmektir. YOLOv5, YOLOv8 ve YOLOv11 modelleri kullanılarak çeşitli internet sitelerinden elde edilen panoramik radyografi görüntülerinden oluşan veri setlerinin birleşimi kullanılmıştır. Eğitim için görüntüler, daha hızlı ve etkili deneyler sağlamak amacıyla 2976 x 1536 boyutundan 640 x 640'a küçültülmüştür. Toplamda 14 anatomik noktanın otomatik olarak tespit edildiği çalışmada, ortalama F1 performans değerleri sırasıyla şu şekilde elde edilmiştir: YOLOv5 modeli için 0.790, YOLOv8 modeli için 0.802, YOLOv11 modeli için 0.810. Uygulanan 3 farklı modelin eğitimi sonucunda elde edilen değerlerin kıyaslaması ve başarı oranlarının göz önünde bulundurulması sonucunda Panoramik Radyografi görüntülerinde anatomik yer işareti tespitinin derin öğrenme ile otomatik yapılması için en uygun modelin YOLOv11 olacağı kararına varılmıştır.

Önerilen yaklaşım, doktor adaylarının panoramik radyografiler üzerindeki anatomik yer işaretlerini daha doğru bir şekilde tespit etmelerini ve uzman doktorların yorgunluk ve yoğunluk gibi faktörlerden kaynaklanabilecek hataları minimuma indirmeyi hedeflemektedir. Olabildiğince optimum sonuna ulaşabilmek adına çalışmalar gerçekleştirilmiştir. Sonuç olarak, yeterince yüksek başarı oranlarına ulaşılmış olsa da daha fazla veri kullanılarak çok daha iyi sonuçların elde edilmesinin, mevcut değerlere bakıldığında kaçınılmaz olduğu görülmektedir. Aynı zamanda yapılan çalışmada anatomik yer işaretlerinin bir kısmı kullanıldığından, ilerleyen çalışmalarda tüm yer işaretleri ile modellerin eğitilmesi tavsiye edilmektedir.

Kaynakça

- [1] Pişiren A., 2020. Panoramik radyografi. (Web Sayfası: <https://akinpisiren.com/panoramik-radyografi>), (Erişim tarihi: Aralık 2023).
- [2] Duong, M. T., Rauschecker, A. M., Rudie, J. D., Chen, P. -H., Cook, T. S., Bryan, R. N., Mohan, S., 2019. "Artificial Intelligence for Precision Education in Radiology", The British Journal of Radiology, 92, 20190389.
- [3] Diyva, V. K., Jatti, A., Meheraj S.P., Joshi, R., 2016, "Image Processing and Parameter Extraction of Digital Panoramic Dental X-rays with ImageJ", International Conference on Computational Systems and Information Systems for Sustainable Solutions, 450-454.
- [4] Li W., Lu Y., Zheng K., Liao H., Lin C., Luo J., Cheng C., Xiao J., Lu L., Kuo C., Miao S., 2020. Structured landmark detection via topology-adapting deep graph learning. Department of Computer Science, University of Rochester, Rochester, NY, USA, 2004.08190v6.

- [5] Shahidi S, Bahrampour E, Soltanimehr E, Zamani A, Oshagh M, Moattari M, et al. The accuracy of a designed software for automated localization of craniofacial landmarks on CBCT images. *BMC Med Imaging* 2014;14:32.
- [6] Ayyıldız, H., Orhan, M., & Bilgir, E. (2024). Tooth numbering with polygonal segmentation on periapical radiographs: An artificial intelligence study. *Clinical Oral Investigations*, 28, 610. <http://doi.org/10.1007/s00784-024-05999-3>
- [7] Rašić, M., Tropčić, M., Karlović, P., Gabrić, D., Subašić, M., & Knežević, P. (2023). Detection and segmentation of radiolucent lesions in the lower jaw on panoramic radiographs using deep neural networks.
- [8] Widiyasri, M., Suciati, N., Arifin, A. Z., Faticah, C., Astuti, E. R., Indraswari, R., Putra, R. H., & Choiruzain. (2022). Dental-YOLO: Alveolar bone and mandibular canal detection on cone beam computed tomography Images for dental implant planning.
- [9] Zeren, M., Arslankaya, S., Altuntaş, Y., Cam, N., Kirelli, Y., Özdemir, M., (2023). doctors versus YOLO: comparison between YOLO algorithm, orthopedic and traumatology resident doctors and general practitioners on detection of proximal femoral fractures on X-ray images with multi methods. *International Journal of Artificial Intelligence Tools*, 1-24. <http://dx.doi.org/10.1142/S0218213023500562>
- [10] Almufareh, M. F., Khan, A., Imran, M., Humayun, M., & Asim, M. (2023). Automated Brain Tumor Segmentation and Classification in MRI Using YOLO-Based Deep Learning. *Jouf University, Saudi Arabia*.
- [11] Lu, Y., Li, K., Pu, B., Tan, Y., Zhu, N., (2024). A YOLOX-based deep instance segmentation neural network for cardiac anatomical structures in fetal ultrasound images. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 21 (4), 1007-1018.
- [12] Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. <https://arxiv.org/abs/2004.10934>
- [13] Meel, A., 2021. Guide to the model & its controversy. (<https://viso.ai/computer-vision/yolov5-controversy/>), (Kasım 2024).
- [14] Çağıl, H., 2009. Serbest Çalışan Diş Hekimlerinin Kullandıkları Radyografik Teknik ve Ekipmanları bitirme tezi. İzmir: Ege Üniversitesi Diş Hekimliği Fakültesi Oral Diagnoz ve Radyoloji Anabilim Dalı.

Farklı Geometriye Sahip Savaklarda Nümerik Modeller ile Elde Edilen Debi Katsayılarının İncelenmesi

Şeyma Özdin¹, Mücella İlkentapar^{*2}, Serhat Akşit³, Ahmet Alper Öner⁴

¹ Erciyes Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği, KAYSERİ

² Erciyes Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği, KAYSERİ

³ Abdullah Gül Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği, KAYSERİ

⁴ Erciyes Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği, KAYSERİ

(Alınış / Received: 27.08.2024, Kabul / Accepted: 25.11.2024, Online Yayınlanma / Published Online: 30.12.2024)

Anahtar Kelimeler

Debi Katsayısı,
HAD,
Açık Kanal,
Savak,
FLOW-3D

Öz: Farklı tipleri bulunan savaklar, geometrik şekillerine göre geniş başlıklı, keskin kenarlı ve uzun başlıklı olarak sınıflandırılabilirler. Bu çalışmada, geniş başlıklı savak akımına ait deney verileri, sonlu hacimler metoduna dayanan FLOW-3D paket programı kullanılarak modellenmiştir. Çalışma kapsamında farklı ağ yapıları test edilmiş ve türbülans viskozitesinin hesaplanmasında Standart $k-\varepsilon$ ve RNG $k-\varepsilon$ türbülans kapatma modelleri uygulanmıştır. Yapılan çalışmalardan elde edilen uygun ağ yapısı ile savak geometrileri çoğaltılarak; keskin kenarlı, geniş ve uzun başlıklı savaklar için su yüzü profilleri elde edilmiştir. Üç farklı geometriye sahip savaklarda Microsoft Excel ile Q_{tahmin} ve $C_{dtahmin}$ değerleri hesaplanarak yeni c_d debi katsayısı formülleri önerilerek literatürde bulunan formüller ile karşılaştırılmıştır. Çalışma sonucunda debi katsayısı hesabında kullanılacak genel formüller de üretilmiştir. Keskin kenarlı ve geniş başlıklı savaklarda, Standart $k-\varepsilon$ ve RNG $k-\varepsilon$ türbülans kapatma modelleri kullanılarak elde edilen yeni formüllerin; literatürde bulunan formüllere nazaran deney sonuçlarına daha yakın değerler verdiği belirlenmiştir.

Investigation of Discharge Coefficients Obtained by Numerical Models in Weirs With Different Geometries

Keywords

Discharge Coefficient,
CFD,
Open Channel,
Weir,
FLOW-3D

Abstract: Weirs, which are available in various types, can be classified according to their geometric shapes as broad-crested, sharp-crested, and long-crested. In this study, experimental data for flow over broad-crested weirs were modeled using the FLOW-3D software, which is based on the finite volume method. Various mesh configurations were tested, and the Standard $k-\varepsilon$ and RNG $k-\varepsilon$ turbulence models were employed for calculating turbulence viscosity. Following the determination of the optimal mesh configuration, weir geometries were replicated to generate water surface profiles for sharp-crested, broad-crested, and long-crested weirs. Discharge ($Q_{estimate}$) and discharge coefficient ($c_{d,estimate}$) values for the weirs with three distinct geometries were calculated using Microsoft Excel. Subsequently, new discharge coefficient (c_d) formulas were proposed and compared with existing formulas in the literature. As a result, generalized formulas for calculating discharge coefficients were developed. It was determined that the new formulas obtained for sharp-crested and broad-crested weirs using the Standard $k-\varepsilon$ and RNG $k-\varepsilon$ turbulence models provided values that aligned more closely with experimental results compared to the formulas available in the literature.

1. Giriş

Hidrolik mühendisleri tarafından akışı kontrol etmek, suyun debisini ölçmek, su seviyelerini düzenlemek ve istenmeyen taşkınları önlemek amacıyla kullanılan kritik yapı elemanları savak olarak isimlendirilmektedir. Kanal eksenine dik olarak yerleştirilen bir ölçüm savağının yaklaşım kanalında ölçülen derinlik ile debi arasında belirlenen ilişki yardımıyla akım tespit edilebilir. Savaklar, farklı geometrik şekillerde uygulanabilir ve keskin kenarlı, geniş başlıklı ve uzun başlıklı savaklar olarak sınıflandırılabilir. [1]. Keskin kenarlı savaklar ince bir düşey levha olup su napı savak üzerinden serbest bir şekilde dökülür. Geniş başlıklı savaklar, akım yönünde yeterli uzunlukta düz bir yüksekliğe sahip olup, bu savaklarda su geniş bir yüzey üzerinde akar. Uzun başlıklı savaklar ise geniş başlıklı savakların uzun bir türüdür ve bu savaklarda su daha uzun bir yüzey üzerinden akar. Her bir savak geometrisinin kendine özgü avantajları bulunmaktadır ve kullanım amacına göre uygun olan geometri seçilerek tasarım yapılmaktadır.

Savaklar üzerindeki akım; serbest yüzey akışı, türbülans ve enerji kayıpları gibi birçok karmaşık faktörü içerir. Uygun tasarım modelini oluşturabilmek için akış profili, hız profili ve basınç alanının hassas bir şekilde öngörülmesi gerekmektedir. Savaklarda akımların analizi fiziksel deneyler ile gerçekleştirilebilmektedir. Ancak deneysel çalışmalar maliyetli ve zaman alıcı olabilmektedir. Günümüzde Hesaplamalı Akışkanlar Dinamiği, HAD, (Computational Fluid Dynamics - CFD) yöntemlerindeki gelişmeler ile savakların modellenmesi kolaylaşmış zamandan ve maliyetten tasarruf edilmesini sağlamıştır. HAD ile yapılan analizler, c_d debi katsayısı gibi önemli hidrolik parametrelerinde hassas bir şekilde hesaplanmasına olanak tanımaktadır. Ayrıca HAD modelleri, savak geometrisinin değiştirilmesi gibi farklı parametrelerin etkisini kolayca analiz etme imkânı tanımaktadır.

Günümüze kadar, savak ve c_d debi katsayısı ile ilgili çok sayıda deneysel ve nümerik çalışma yapılmıştır. Azimi ve Rajaratnam [1], farklı savak modellerinde literatürden elde ettikleri deneysel verileri sayısal olarak analiz etmişlerdir. Geniş başlıklı savak için c_d debi katsayısını geniş başlıklı savak uzunluğuna göre incelemişlerdir. Debi katsayısının, savak genişliği ve memba bölgesindeki kret uzunluğuna bağlı olarak değiştiğini ifade etmişlerdir.

Savak şekillerine göre c_d debi katsayısı formüllerini aşağıdaki gibi bulmuşlardır.

Keskin Kenarlı Savaklarda C_d formülü;

$$C_d = 0.767 + 0.215 \left(\frac{h}{L} \right) \quad (1.1)$$

Uzun Başlıklı Savaklarda C_d formülü;

$$C_d = 1.02 [h/(h + p)]^{0.12} \quad (1.2)$$

Formüllerdeki h memba kısmındaki akım yüksekliğini, L savağın uzunluğunu, p ise savak yüksekliğini ifade göstermektedir.

Govinda Rao ve Muralidhar [2], Sonlu tepe genişliğine sahip savakların debi özelliklerini ayrıntılı bir şekilde analiz etmişlerdir. Bu analizde, önceki deney sonuçları kullanılarak savaklar keskin kenarlı, uzun ve geniş başlıklı olarak kategorize edilmiştir. Geniş başlıklı savak için debi katsayısı formülünü aşağıdaki gibi bulmuşlardır. Geniş Başlıklı savaklarda C_d formülü;

$$C_d = 0.913 + 0.049 \left(\frac{h}{L} \right) \quad (1.3)$$

Formüllerdeki h , savağın memba kısmındaki akım yüksekliğini, L ise savağın uzunluğunu ifade etmektedir.

Ramamurthy ve ark. [3], keskin kenarlı savak akımını deneysel olarak incelemişlerdir. Çalışmalarında kret bölgesine yakın olan bölgede hız ve basınç dağılımlarını incelemişlerdir. Çalışmalarında, c_d debi katsayısının h/P oranına göre değiştiğini belirtmişlerdir. Yaptıkları çalışmada, h savağın membaındaki akım yüksekliğini, P ise savağın yüksekliğini belirtmektedir.

El-Alfy [4], c_d debi katsayısının değişimini deneysel olarak incelemiştir. Dört farklı savak için farklı akım şartlarında 254 adet deney gerçekleştirmişlerdir. Çalışmalarında, debi katsayısı c_d 'nin H/Y oranına bağlı olarak değiştiğini tespit etmişlerdir. Geliştirdiği formüllerdeki debi katsayısının literatürde bulunan katsayılar ile uyumlu olduğunu belirtmiştir. Keskin kenarlı savaklar ve geniş başlıklı savaklar için aşağıdaki formülleri bulmuştur.

Keskin kenarlı savaklarda 0.375 ile 1.47 arasındaki H/Y oranı için C_d formülü;

$$C_d = 0.6184 + 0.1078H/Y \quad (1.4)$$

Geniş başlıklı savaklarda, H/Y oranı 0.3 ile 1.5 arasında ve H/w oranı 0.18 ile 0.33 arasında olduğunda C_d formülü;

$$C_d = 0.5819 + 0.1677H/Y \quad (1.5)$$

Formüllerde, H savak üstü su yüksekliği, Y kret yüksekliği ve w kret kalınlığı olarak ifade edilmektedir.

Doğan [5], deneysel olarak yaptığı çalışmasında kret şeklinin c_d debi katsayısına etkisini incelemiştir. Çalışmasında; 1/4 yuvarlatılmış savak, 1/2 yuvarlatılmış savak, düz savak ve keskin kenarlı savak olmak üzere

dört farklı savak şeklini kullanmıştır. Yapmış olduğu deneyler sonucunda savak kret şeklinin c_d debi katsayısı değişimi için önemli bir faktör olduğunu ve savağın yüksekliğinin artmasıyla debi katsayısında azalma olduğunu belirtmiştir. Bilhan ve ark. [6], keskin kenarlı dikdörtgen yan savaklarda 843 deneysel veri kullanarak yapay sinir ağlarıyla debi katsayılarını tahmin etmişlerdir. İki farklı sinir ağı tekniğini kullanarak elde ettikleri sonuçları karşılaştırmışlardır. Çalışmalarında, FFNN modelinin debi katsayısını tahmin etmede RBNN modelinden daha iyi performans sergilediğini vurgulamışlardır. Salması ve ark. [7], geniş başlıklı savaklarda c_d debi katsayısını belirlemek için yapay sinir ağları ve genetik programlama yöntemlerini kullanmışlardır. Yaptıkları çalışmada 15 farklı savak geometrisinde elde edilen deneysel verileri kullanmış ve genetik programlama ile yaptıkları hesaplamaların yapay sinir ağlarına göre deneysel verilerle daha uyumlu olduğunu belirtmişlerdir. Al-Khatip ve ark. [8], geniş başlıklı savaklarda c_d debi katsayısı ve c_v hız katsayısının nelere bağlı olarak değiştiğini belirlemek amacıyla deneysel çalışma gerçekleştirmişlerdir. Genel denklemlerden elde edilen c_v hız katsayısı ve c_d debi katsayısı değerlerini, deneylerde elde ettikleri veriler ile karşılaştırdıklarında hata oranının %5' ten küçük olduğunu belirtmişlerdir. Hoseini ve ark. [9], geniş başlıklı savaklarda 2 farklı genişlik ve 15 farklı debi kullanarak deneysel çalışma yapmışlardır. Çalışmalarında debi katsayısını etkileyen parametrelerin savak genişliği, kret üzerindeki toplam enerji yükü ve savak uzunluğu olduğunu belirtmişlerdir. Literatürde bulunan denklemlerle sayısal olarak elde edilen debi katsayılarının ve deneyde elde edilen debi katsayılarına yakın sonuçlar verdiğini ifade etmişlerdir.

Bu çalışmada; İlkentapar [10]' ın Erciyes Üniversitesi Hidrolik Laboratuvarında bulunan 0.6x0.6x9.5 m ölçülerindeki açık kanal sisteminde deneysel olarak elde ettiği su yüzü profilleri ile FLOW-3D paket programında gerçekleştirilen analizlerden elde edilen su yüzü profilleri karşılaştırılarak uygun ağ yapısı belirlenmiştir. Belirlenen uygun ağ yapısında Standart k- ϵ ve RNG k- ϵ türbülans kapatma modelleri kullanılarak farklı geometrik boyutlarda ve farklı debilerde analizler gerçekleştirilerek veriler çoğaltılmıştır. Geniş başlıklı, uzun başlıklı ve keskin kenarlı olarak sınıflandırılabilir savaklarda Microsoft Excel ile Q_{tahmin} ve $c_{d\text{ tahmin}}$ değerleri hesaplanmış ve yeni c_d debi katsayısı formülleri elde edilmiştir. Elde edilen formüllerden hesaplanan sonuçlar ile literatürde bulunan formüllerden elde edilen sonuçlar ile karşılaştırılmıştır. Çalışmada geliştirilen c_d debi katsayısı formüllerinin doğruluğu, MARE, MSE, MAE, NSE, R^2 ve RMSE gibi farklı performans değerlendirme kriterleriyle test edilmiştir. Burada MARE ortalama mutlak bağıl hatayı, MSE ortalama karesel hatayı, MAE ortalama mutlak hatayı, NSE Nash-Sutcliffe verimlilik katsayısını, RMSE kök ortalama karesel hatayı, R^2 ise belirleme katsayısını ifade etmektedir.

2. Materyal ve Metot

2.1 Deneysel Veriler

Çalışmada kullanılan deney verileri; İlkentapar [10]'ın Erciyes Üniversitesi İnşaat Mühendisliği bünyesindeki Hidrolik Laboratuvarında bulunan 0.6x0.6x9.5 m boyutlarındaki açık kanal düzeneğinde (Şekil 1) gerçekleştirdiği çalışmadan alınmıştır. Deneylerde 0.6x0.6x0.10 m, 0.6x0.3x0.10 m, 0.6x0.2x0.10 m, 0.6x0.15x0.10 m ölçülerine sahip 4 farklı yüksekliğe sahip geniş başlıklı savak kullanılmıştır. Deneylerde her savak geometrisi için 5 farklı debi ile çalışılmış ve su yüzü ölçümü yapılmıştır.



Şekil 1 ERÜ Mühendislik Fakültesi İnşaat Müh. Böl. Hidrolik Laboratuvarı Açık Kanal Düzeneği

2.2 FLOW-3D

Çalışma kapsamında sayısal çözümler FLOW-3D programı ile gerçekleştirilmiştir. FLOW-3D serbest yüzey akışlarını modellemek için geliştirilen akışkan hacmi (VOF Volume of Fluid) yöntemini kullanarak analiz yapmaktadır. Hesaplamalar, dikdörtgen hücrelerden oluşan üniform olmayan bir çözüm ağı üzerinde yapılmaktadır. Akışkana ait viskozite, yoğunluk, basınç gibi skaler büyüklükler kontrol hacminin (hücre) merkezinde yer alırken sadece hızlar (u, v, w) kontrol hacminin yüzeyinde hesaba katılmaktadır. VOF yöntemi ile serbest yüzeyin izlenmesi üç kısımdan oluşur. İlk olarak serbest yüzeyin yeri bulunur. Daha sonra bu yüzey, hava ve su arasında keskin bir arakesit olarak belirlenir. Son olarak bu arakesite sınır şartları uygulanır. Arakesit üzerinde sabit basınç sınır koşulları ve sıfır kayma gerilmesi uygulanmaktadır. Akışkan hacmi fonksiyonu F' nin değişimi diferansiyel olarak ifade edilmektedir. Standart k-ε, RNG k-ε, LES (Large Eddy Simulation) gibi çeşitli türbülans modelleri içeren programda analizler Standart k-ε ve RNG k-ε türbülans kapatma modelleri kullanılarak yapılmıştır.

2.2.1 Standart k-ε Türbülans Kapatma Modeli

Standart k-ε türbülans modeli, özellikle yüksek Reynolds sayılı akışlarda daha iyi performans göstermekte ve sınır tabakası dışındaki bölgelerde geçerli olmaktadır. Standart k-ε türbülans kapatma modelinde kinetik enerji k ve kinetik enerji kayıp oranı ε için ayrı taşınım denklemleri yazılır. Standart k-ε modelinde, Reynolds gerilmesini hesaplayan türbülans viskozitesi formül 2.1 kullanılarak bulunur.

$$\mu_t = \frac{\rho C_\mu k^2}{\varepsilon} \quad (2.1)$$

Bu denklemde C_μ türbülans modeli sabitini ifade etmektedir. Türbülans kinetik enerjisi ile enerji kayıp oranını tanımlayan türbülans denklemleri, denklem 2.2 ve 2.3 ile tanımlanır. Bu denklemlerde, G türbülans kinetik enerjisi üretim miktarını ifade eder. Difüzyon terimleri ise denklem 2.4' te belirtilmiştir

$$\frac{\partial}{\partial t}(\rho k) + \frac{\partial}{\partial x_i}(\rho k u_i) = \frac{\partial}{\partial x_j} \left(\Gamma_k \frac{\partial k}{\partial x_j} \right) + G_k - \rho \varepsilon \quad (2.2)$$

$$\frac{\partial}{\partial t}(\rho \varepsilon) + \frac{\partial}{\partial x_i}(\rho \varepsilon u_i) = \frac{\partial}{\partial x_j} \left(\Gamma_\varepsilon \frac{\partial \varepsilon}{\partial x_j} \right) + C_{1\varepsilon} \frac{\varepsilon}{k} G_k - C_{2\varepsilon} \rho \frac{\varepsilon^2}{k} - R \quad (2.3)$$

$$\Gamma_\varepsilon = \mu + \frac{\mu_t}{\sigma_\varepsilon}, \Gamma_k = \mu + \frac{\mu_t}{\sigma_k} \quad (2.4)$$

2.2.2 RNG k-ε Türbülans Kapatma Modeli

RNG k-ε türbülans kapatma modeli, Standart k-ε türbülans kapatma modeli gibi, türbülans kinetik enerjisi k ve kinetik enerji kayıp oranı ε için iki ayrı kısmi diferansiyel taşıma denkleminin kullanılmasını gerektirir. Taşıma denklemlerinin şekli Standart k-ε türbülans kapatma modeline benzerdir. RNG k-ε türbülans kapatma modeli ile Standart k-ε türbülans kapatma modeli arasındaki temel farklar, kullanılan sabitlerin değerleri ve eklenen ilave terimlerdir. RNG (Renormalization Group) yöntemi, türbülans viskozitesinin daha geniş bir türbülans aralığında hesaplanmasını sağlamak amacıyla türetilmiştir ve bu nedenle Standart k-ε modeline kıyasla daha hassas sonuçlar verebilmektedir. Özellikle RNG modeli, düşük Reynolds sayılarında ve dönel akışlarda daha iyi performans göstermektedir. Modeldeki ilave terimlerden biri, türbülans viskozitesinin hesaplanmasında yer alan geri dönüşüm (reynolds-stress) etkilerini temsil eden bir düzeltme terimidir. Bu düzeltme, türbülans kinetik enerjinin hızla dağıldığı bölgelerde modelin doğruluğunu artırır. Ayrıca, RNG modeli, türbülans kinetik enerji ve dağılım oranları için farklı bir eşitlik seti içerir. Bu farklılık, özellikle girdap çözünürlüğünün önemli olduğu akışlarda, daha gerçekçi sonuçlar elde edilmesine olanak tanır. Standart k-ε modeli ise daha basitleştirilmiş sabit değerler kullanarak genel mühendislik uygulamalarında kabul edilebilir doğruluk sağlamayı hedefler. RNG k-ε türbülans kapatma modelinde 2.2 ve 2.3 eşitliklerinde bulunan difüzyon terimleri 2.5'teki gibi olur.

$$\Gamma_\varepsilon = \alpha_\varepsilon \mu_e, \Gamma_k = \alpha_k \mu_e \quad (2.5)$$

Akışkanın viskozitesi (μ) ile türbülans viskozite (μ_t)' nin toplamı, efektif viskozite (μ_e) değerini verir. RNG k-ε türbülans kapatma modeli, Standart k-ε türbülans kapatma modeli ile karşılaştırıldığında aralarındaki en büyük fark, ε denkleminde ilave olarak gelen R terimidir. Bu fark ile formül, 2.6'teki gibi olmaktadır.

$$\frac{\partial}{\partial t}(\rho\varepsilon) + \frac{\partial}{\partial x_i}(\rho\varepsilon u_i) = \frac{\partial}{\partial x_j}\left(\Gamma_\varepsilon \frac{\partial \varepsilon}{\partial x_j}\right) + C_{1\varepsilon} \frac{\varepsilon}{k} G_k - C_{2\varepsilon}^* \rho \frac{\varepsilon^2}{k} \quad (2.6)$$

$$C_{2\varepsilon}^* = C_{2\varepsilon} + \frac{C_{\mu}\eta^3(1-\eta/\eta_0)}{1+\beta\eta^3} \quad (2.7)$$

Burada η , türbülans kinetik enerjisinin üretim ve kayıp oranlarına dayanan bir fonksiyon olarak tanımlanır.

$$\eta = S \frac{k}{\varepsilon} \quad (2.8)$$

S_{ij} ; şekil değiştirme hızı tansörüdür.

$$S = \sqrt{S_{ij}S_{ij}} \quad (2.9)$$

$$S_{ij} = \frac{1}{2}\left(\frac{\partial u_j}{\partial x_i} + \frac{\partial u_i}{\partial x_j}\right) \quad (2.10)$$


2.3 Performans Değerlendirme Kriterleri

Bu çalışmada kapsamında üretilen c_d debi katsayısı formüllerinin doğruluğu MSE, MARE, MAE, R^2 , NSE, RMSE performans değerlendirme ölçütlerine göre hesaplanmıştır. MSE, MARE değerlerinin en küçük olması durumu ve R^2 değerinin 1'e en yakın olması, tahminlerin son derece doğru ve güvenilir olduğunu işaret eder. Literatürde, NSE değerinin 0.3 ile 0.5 arasında olması düşük tahmin başarısını, 0.5 ile 0.7 arasında olması kabul edilebilir bir başarıyı, 0.7 ile 0.9 arasında olması yüksek tahmin başarısını ve 0.91'in üzerinde olması ise mükemmel tahmin başarısını ifade etmektedir [11]. RMSE değerinin sıfıra yakın olması durumu tahminin en iyi olduğunu belirtmektedir.

2.4 Hesaplama Ağının Tasarımı

Sayısal hesaplamalarda, tüm çözüm bölgesinde tek tip ağ sıklığı kullanılmıştır. Analiz üzerindeki ağ aralığının etkisini incelemek amacıyla, 2 cm, 1 cm, 0.5 cm ve 0.25 cm olmak üzere dört farklı ağ aralığı ile çözümler gerçekleştirilmiştir. Bu farklı ağ yoğunlukları ile elde edilen su yüzeyleri, deneysel olarak ölçülen su yüzeyleriyle karşılaştırılmış ve ortalama karesel hatalar (OKH) denklem (2.11) aracılığıyla hesaplanmıştır. Sonuç olarak, OKH değerleri 2 cm'lik ağ aralığı için 0.00148, 1 cm'lik ağ aralığı için 0.000639, 0.5 cm'lik ağ aralığı için 0.000145 ve 0.25 cm'lik ağ aralığı için 0.000035 olarak bulunmuştur. İncelenen OKH değerlerine göre, en uygun ağ aralığının 0.5 cm olduğu belirlenmiştir. Ayrıca, 0.5 cm'lik ağ aralığı için çözüm süresi 0.25 cm'lik aralığa göre önemli ölçüde daha kısa olduğundan, tüm debiler için 0.5 cm ağ aralığı tercih edilerek çözümler yapılmıştır. Oluşturulan ağ yapısı Şekil 2' de gösterilmiştir.

$$OKH = \sum_{i=1}^n \frac{(H_{iölçüm} - H_{iFLOW-3D})^2}{n} \quad (2.11)$$



Şekil 2 Ağ (Mesh) Aralığı Çalışması

2.5 Sınır Şartlarının Tanımlanması

Analiz bölgesinin fiziksel ve geometrik özelliklerini doğru bir şekilde temsil etmek için Xmin: Volume of Rate (debi), Xmax: Out-Flow (su çıkışı), Zmin: Wall (duvar), Zmax: Symmetry, Ymin: Symmetry, Ymax: Symmetry olarak yapılandırılmıştır. Çalışma kapsamında FLOW-3D programında modellemeler 2 boyutlu olarak yapılmıştır. Debi, kanal genişliğine bölünerek $\text{cm}^3/\text{sn}/\text{cm}$ olacak şekilde birim genişlikten geçen debi değeri girilmiştir. Programda, Output sekmesindeki Hydraulic Data seçeneği üzerinden Restart Data Interval parametresi 0,1 olarak belirlenmiştir. Bu ayar sayesinde, 10 saniyelik toplam çözüm süresi boyunca, her 0,1 saniyede bir veri kaydedilerek analiz için gerekli sonuçların zamana bağlı olarak detaylı bir şekilde elde edilmesi sağlanmıştır.

2.6 Debi Katsayısı Hesabında Kullanılan Savak Geometrileri

Çalışma kapsamında mevcut deney verileri kullanılarak uygun ağ yapısı belirlendikten sonra farklı geometrilere sahip savaklarda debi katsayısı hesabı yapabilmek amacıyla yeni savak boyutları belirlenmiştir. Bu amaçla, savak genişliği 0.6 m olarak sabit tutulmuştur ve savak uzunlukları için 0.15, 0.20, 0.25, 0.50, 0.55, 0.60 ve 0.70 m seçilmiştir. Savak yüksekliği, farklı savak uzunluklarına göre şu şekilde belirlenmiştir: 0.15 m uzunluğundaki savak için 0.1, 0.2, 0.25 ve 0.3 m; 0.20, 0.25 ve 0.50 m uzunluğundaki savaklar için 0.1 m; 0.55 m uzunluğundaki savak için 0.1 ve 0.15 m; 0.60 m uzunluğundaki savak için 0.1 ve 0.15 m; ve 0.70 m uzunluğundaki savak için 0.05 ve 0.1 m yükseklik değerleri kullanılmıştır.

2.7 Debi Katsayılarının Hesaplanması

Debi katsayılarının hesaplanması için deneylerden elde edilen su yüzü ölçümleri ve yeni oluşturulmuş savak geometrilerin FLOW-3D programında çözülmesi ile elde edilen su yüzü sonuçları kullanılmıştır. Mevcut su yüzü profillerinden elde edilen su yükseklikleri kullanılarak c_d debi katsayıları hesaplanmıştır. Debi katsayılarının hesaplanmasında formül 1.1, 1.2, 1.3 ve 2.11 kullanılmıştır. Formül 1.1 ve 1.2 Azimi ve Rajaratnam [1], formül 1.3 Govinda Rao ve Muralidhar [2] tarafından önerilen formüller iken, formül 2.12 savaklar için önerilen genel debi katsayısı formülüdür. Burada b savak genişliğini, H ise memba kısmındaki toplam enerji yükünü ifade etmektedir.

$$C_d = Q / (b \sqrt{8/27} \sqrt{g} H^{3/2}) \quad (2.12)$$

3. Bulgular

3.1 Debi Katsayısının Hesaplanması için Formül Üretilmesi

Çalışma kapsamında debi katsayısı c_d ' nin hesaplanmasında yeni formül oluşturma işleminde savak geometrileri dikkate alınmıştır. Savak geometrileri h/L oranına göre sınıflandırılmış olup; h akımın kararlı hale geldiği durumda memba su seviyesini, L savak uzunluğunu temsil etmektedir. Buna göre, h/L oranı 0 ile 0.1 arasında olduğunda savaklar uzun başlıklı, 0.1 ile 0.4 arasında olduğunda geniş başlıklı ve 0.4 ile 2 arasında olduğunda ise keskin kenarlı olarak tanımlanmıştır. Elde edilen bütün su yüzü profillerinden belirlenen su yükseklikleri ve savak geometrileri kullanılarak Q_{tahmin} ve $C_{d\text{tahmin}}$ değerleri hesaplanmıştır. Yapılan hesaplamalardan elde edilen sonuçlar performans değerlendirme kriterleri değerlendirilerek yeni c_d debi katsayısı formülleri önerilmiştir. FLOW-3D' de analiz yapılırken türbülans kapatma modeli olarak Standart k- ϵ ve RNG k- ϵ modelleri kullanıldığından her iki analizden de elde edilen sonuçlara göre farklı c_d katsayıları hesaplanmıştır. Debi katsayısı hesabı için üretilen yeni formüller 3.1-3.8 de verilmiştir. Formüllerdeki h akımın kararlı hale geldiği durumda memba su yüksekliğini, p savak yüksekliğini ve L savak uzunluğunu gösterir.

Standart k- ϵ türbülans kapatma modeline göre keskin kenarlı savakta;

$$C_d = 1.025366 + 0.062949 \left(\frac{h}{L} \right) \quad (3.1)$$

Keskin kenarlı savakta RNG k- ϵ türbülans kapatma modeline göre;

$$C_d = 0.994254 + 0.90271 \left(\frac{h}{L} \right) \quad (3.2)$$

Geniş başlıklı savakta Standart k-ε türbülans kapatma modeline göre;

$$C_d = 1.011418 + 0.33974 \left(\frac{h}{L}\right) \quad (3.3)$$

Geniş başlıklı savakta RNG k-ε türbülans kapatma modeline göre;

$$C_d = 1.01118 + 0.237 \left(\frac{h}{L}\right) \quad (3.4)$$

Uzun başlıklı savakta Standart k-ε türbülans kapatma modeline göre;

$$C_d = 1.101133[h/(h + p)]^{-0.01007} \quad (3.5)$$

Uzun başlıklı savakta RNG k-ε türbülans kapatma modeline göre;

$$C_d = 0.817777[h/(h + p)]^{-0.20539} \quad (3.6)$$

Genel savak formülü Standart k-ε türbülans kapatma modeline göre;

$$C_d = 1.026838 + 0.43728 \left(\frac{h}{L}\right) \quad (3.7)$$

Genel savak formülü RNG k-ε türbülans kapatma modeline göre;

$$C_d = 1.009405 + 0.057083 \left(\frac{h}{L}\right) \quad (3.8)$$

Standart k-ε türbülans kapatma modeli için üretilen formül 3.1, 3.3, 3.5 ve 3.7 ve savak tipine uygun olarak literatürde bulunan 1.1, 1.2 ve 2.12 formülleri kullanılarak hesaplanan c_d katsayıları ve performans kriterleri Tablo 1'de verilmiştir.

Tablo 1 Standart k-ε türbülans kapatma modeline c_d katsayıları ve performans kriterleri

| | C_d | MSE | RMSE | MARE | MAE | R ² | NSE |
|--|-------|------------|----------|-----------|----------|----------------|----------|
| Keskin Kenarlı Savak Literatür Formülü | 0.76 | 0.00004700 | 0.006890 | 13.916584 | 0.006591 | 0.838933 | 0.381964 |
| Keskin Kenarlı Savak Üretilen Yeni Formül | 1.02 | 0.00001100 | 0.003382 | 4.359829 | 0.002011 | 0.853303 | 0.851141 |
| Geniş Başlıklı Savak Literatür Formülü | 0.91 | 0.00002500 | 0.005019 | 13.998362 | 0.003715 | 0.668544 | 0.592410 |
| Geniş Başlıklı Savak Üretilen Yeni Formül | 1.01 | 0.00003200 | 0.005654 | 8.356126 | 0.002110 | 0.667354 | 0.482734 |
| Uzun Başlıklı Literatür Formülü | 1.02 | 0.00000300 | 0.001717 | 23.668904 | 0.001682 | 0.995660 | 0.528580 |
| Uzun Başlıklı Savak Üretilen Yeni Formül | 1.10 | 0.00000007 | 0.000272 | 3.081310 | 0.000205 | 0.992972 | 0.988150 |
| Genel Savak Literatür Formülü | 0.91 | 0.00002400 | 0.004926 | 14.622950 | 0.003885 | 0.944796 | 0.918369 |
| Genel Savak Üretilen Yeni Formül | 1.02 | 0.00001800 | 0.004199 | 7.515684 | 0.001823 | 0.943603 | 0.940689 |

RNG k-ε türbülans kapatma modeli için üretilen formül 3.2, 3.4, 3.6 ve 3.8 ve savak tipine uygun olarak literatürde bulunan 1.1, 1.2 ve 2.12 formülleri kullanılarak hesaplanan c_d katsayıları ve performans kriterleri Tablo 2'de verilmiştir.

Tablo 2 RNG k-ε türbülans kapatma modeline c_d katsayıları ve performans kriterleri

| | C_d | MSE | RMSE | MARE | MAE | R^2 | NSE |
|--|-------|------------|----------|-----------|----------|----------|----------|
| Keskin Kenarlı Savak Literatür Formülü | 0.76 | 0.00004100 | 0.006398 | 12.998343 | 0.006151 | 0.965634 | 0.467150 |
| Keskin Kenarlı Savak Üretilen Yeni Formül | 0.99 | 0.00000200 | 0.001527 | 2.3187750 | 0.001159 | 0.973720 | 0.969650 |
| Geniş Başlıklı Savak Literatür Formülü | 0.91 | 0.00002000 | 0.004434 | 12.654777 | 0.003398 | 0.740685 | 0.681896 |
| Geniş Başlıklı Savak Üretilen Yeni Formül | 1.01 | 0.00002400 | 0.004914 | 6.8922480 | 0.001767 | 0.739024 | 0.609242 |
| Uzun Başlıklı Literatür Formülü | 1.02 | 0.00000400 | 0.002097 | 25.805592 | 0.001899 | 0.709089 | 0.296667 |
| Uzun Başlıklı Savak Üretilen Yeni Formül | 0.81 | 0.00000200 | 0.001287 | 6.8491190 | 0.000603 | 0.835297 | 0.735016 |
| Genel Savak Literatür Formülü | 0.91 | 0.00002000 | 0.004497 | 14.158922 | 0.003635 | 0.961831 | 0.931951 |
| Genel Savak Üretilen Yeni Formül | 1.00 | 0.00001100 | 0.003375 | 7.2559760 | 0.001433 | 0.962127 | 0.961671 |

Keskin kenarlı savakta Standart k-ε türbülans kapatma modeline göre oluşturulan modellemelerde, NSE değeri 0.85, R^2 değeri 0.85' tir. R^2 değerinin 1'e yakın olması ve NSE değerinin 0.7 ile 0.9 arasında olması, yüksek bir tahmin başarısına işaret etmektedir. RNG k-ε türbülans kapatma yaklaşım modeline göre oluşturulan modellemelerde, NSE değeri 0.96, R^2 değeri 0.97' dir. R^2 değerinin 1'e yakın olması ve NSE değerinin 0.91'in üzerinde olması, tahmin başarısının mükemmel olduğunu göstermektedir.


Geniş başlıklı savakta Standart k-ε türbülans kapatma modeline göre oluşturulan modellemelerde, NSE değeri 0.48, R^2 değeri 0.66' dır. R^2 değerinin 1'den biraz uzaklaşması ve NSE değerinin 0.3- 0.5 arasında olması düşük tahmin başarısı olarak yorumlanmıştır. RNG k-ε türbülans kapatma modeline göre oluşturulan modellemelerde, NSE değeri 0.60, R^2 değeri 0.73' tür. R^2 değerinin 1'e yakın olması ve NSE değerinin 0.7 ile 0.9 arasında bulunması, modelin yüksek tahmin başarısına sahip olduğunu göstermiştir.

Uzun başlıklı savakta Standart k-ε türbülans kapatma modeline göre oluşturulan modellemelerde, NSE değeri 0.98, R^2 değeri 0.99' dur. R^2 değerinin 1'e çok yakın olması ve NSE değerinin 0.91' den büyük olmasından dolayı tahmin başarısının mükemmel olduğu anlaşılmıştır. RNG k-ε türbülans kapatma modeline göre oluşturulan modellemelerde, NSE değeri 0.73, R^2 değeri 0.83' tür. R^2 değerinin 1'e yaklaşması ve NSE değerinin 0.7 ile 0.9 arasında olması, tahmin başarısının yüksek olduğunu ortaya koymuştur.


Savak geometrisi göz önüne alınmaksızın, Standart k-ε türbülans kapatma modeli kullanılarak elde edilen genel formül incelendiğinde, NSE değeri 0.94 ve R^2 değeri 0.94 olarak bulunmuştur. R^2 değerinin 1'e çok yakın olması ve NSE değerinin 0.91'in üzerinde olması, modelin tahmin başarısının mükemmel olduğunu göstermektedir. Benzer şekilde, RNG k-ε türbülans kapatma modeli ile elde edilen genel formül incelendiğinde, NSE değeri 0.96 ve R^2 değeri 0.96'dır. R^2 değerinin 1'e oldukça yakın olması ve NSE değerinin 0.91'in üzerinde olması, tahmin başarısının mükemmel olduğu şeklinde değerlendirilmiştir.

3.2 Hesaplanan Debi Katsayılarının Karşılaştırılması

Kenarlı savakta deney verileri kullanılarak Standart k-ε ve RNG k-ε türbülans kapatma modeline göre formül 2.12 ile hesaplanan debi katsayıları, Azimi ve Rajaratnam [1] formülü ile hesaplanan debi katsayıları ve çalışma kapsamında elde edilen yeni formülle hesaplanan debi katsayıları Şekil 3 (a) ve (b)'de gösterilmiştir.


**Şekil 3** Keskin Kenarlı Savaklarda c_d Katsayılarının Karşılaştırılması

Geniş başlıklı savakta deney verileri kullanılarak Standart k- ϵ ve RNG k- ϵ türbülans kapatma modeline göre formül 2.12 ile hesaplanan debi katsayıları, Govinda Rao ve Muralidhar [2] formülü ile hesaplanan debi katsayıları ve çalışma kapsamında elde edilen yeni formülle hesaplanan debi katsayıları Şekil 4 (a) ve (b)'de gösterilmiştir.



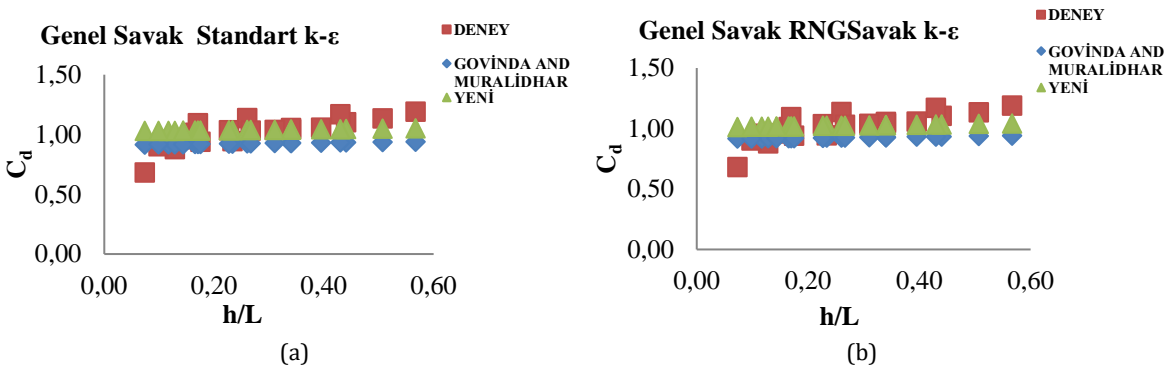
Şekil 4 Geniş Başlıklı Savaklarda C_d Katsayılarının Karşılaştırılması

Uzun başlıklı savakta deney verileri kullanılarak Standart k- ϵ ve RNG k- ϵ türbülans kapatma modeline göre formül 2.12 ile hesaplanan debi katsayıları, Azimi ve Rajaratnam [1] formülü ile hesaplanan debi katsayıları ve çalışma kapsamında elde edilen yeni formülle hesaplanan debi katsayıları Şekil 5 (a) ve (b)'de gösterilmiştir.



Şekil 5 Uzun Başlıklı Savaklarda C_d Katsayılarının Karşılaştırılması

Savak türü ayırt etmeden deney verileri kullanılarak Standart k- ϵ ve RNG k- ϵ türbülans kapatma modeline göre formül 1.3 ile hesaplanan debi katsayıları, Govinda Rao ve Muralidhar [2] formülü ile hesaplanan debi katsayıları ve çalışma kapsamında elde edilen yeni formülle hesaplanan debi katsayıları Şekil 6 (a) ve (b)'de gösterilmiştir.



Şekil 6 Uzun Başlıklı Savaklarda C_d Katsayılarının Karşılaştırılması

Keskin kenarlı savakta, Standart k- ϵ türbülans kapatma modeline göre deney verilerinin formül 2.12 ve Azimi ve Rajaratnam [1] formülü ile hesaplanması sonucunda debi katsayıları arasındaki fark, ortalama olarak %32,00 seviyesinde bulunmuştur. Formül 2.12 kullanılarak hesaplanan debi katsayıları ve yeni oluşturulan formül ile hesaplanan debi katsayıları arasındaki ortalama fark ise %8,90 olarak tespit edilmiştir. RNG k- ϵ türbülans kapatma modeline göre, deney verilerinin Azimi ve Rajaratnam'ın [1] önerdikleri formül ve 2.12'de verilen formül ile hesaplanması sonucunda ortaya çıkan debi katsayıları arasındaki ortalama fark yine %32,00 olarak hesaplanmıştır. Formül 2.12 ile hesaplanan debi katsayıları ve yeni oluşturulan formül arasındaki fark ise %19,70 olarak belirlenmiştir.

Geniş başlıklı savakta, Standart k-ε türbülans kapatma modeline göre deney verilerinin formül 2.12 ve Govinda Rao ve Muralidhar [2] formülü ile karşılaştırılması sonucunda, debi katsayıları arasındaki ortalama fark %10.00 olarak hesaplanmıştır. Yeni oluşturulan formülle formül 2.12 arasında hesaplanan debi katsayıları farkı ise %5.20 olarak belirlenmiştir. Ancak, yeni formülün performans değerlendirme kriterlerine göre düşük tahmin başarısına sahip olduğu görülmüş ve bu nedenle çalışma kapsamında önerilmemiştir. RNG k-ε türbülans kapatma modeline göre, deney verilerinin formül 2.12 ve Govinda Rao ve Muralidhar [2] formülü ile hesaplanması sonucunda ortalama fark %10.00 olarak bulunmuş, yeni formül ile %5.30 fark ortaya çıkmıştır. Performans değerlendirme kriterleri bu durumda yüksek tahmin başarısını işaret etmektedir.

Uzun başlıklı savakta, Standart k-ε türbülans kapatma modeline göre deney verilerinin formül 2.12 ve Azimi [1] formülü ile karşılaştırılması sonucunda, debi katsayıları arasındaki ortalama fark %11.60 olarak hesaplanmıştır. Formül 2.12 ile yeni formül arasında %28.80 fark olduğu belirlenmiştir. RNG k-ε türbülans kapatma modeline göre, deney verilerinin formül 2.12 ve Azimi ve Rajaratnam [1] formülü ile hesaplanması sonucunda %11.60'luk bir fark bulunmuş, yeni formülle bu fark %22.30 olmuştur. Yeni formüllerin performans değerlendirme kriterleri yüksek tahmin başarısına işaret etse de, ortalama farkın büyük olması nedeniyle bu formüller önerilmemektedir. Genel bir formül elde etmek amacıyla, Standart k-ε türbülans kapatma modeline göre deney verilerinin formül 1.3 ve Govinda Rao ve Muralidhar [2] formülü ile karşılaştırılması sonucu %13.10'luk bir ortalama fark tespit edilmiştir. Formül 1.3 ile yeni genel formül arasında hesaplanan debi katsayıları farkı ise %7.70 olarak belirlenmiştir. RNG k-ε türbülans kapatma modeline göre, deney verilerinin formül 1.3 ve Govinda Rao ve Muralidhar [2] formülü ile karşılaştırılması sonucu %13.10'luk bir ortalama fark bulunmuş, yeni genel formülle bu fark %7.80 olarak hesaplanmıştır.

4. Tartışma ve Sonuç

Bu çalışmada, mevcut geniş başlıklı savak deney verileri FLOW-3D paket programı ile çözülerek doğrulanmış ve yeni savak geometrileri belirlenerek Standart k-ε ve RNG k-ε türbülans kapatma modeline sayısal olarak çözümleme yapılmıştır. Elde edilen su yüzü profillerinden her bir savak için Microsoft Excel ile Q_{tahmin} ve $C_{d\text{tahmin}}$ değerleri hesaplanarak yeni c_d debi katsayısı formülleri önerilerek literatürde bulunan formüller ile karşılaştırılmıştır. Bu çalışma sonucunda, debi katsayısının hesabı için kullanılacak genel formüller geliştirilmiştir. Bu formüller, deneysel sonuçlarla uyumlu olup literatürdeki mevcut formüllerden daha başarılı sonuçlar vermiştir. Oluşturulan yeni debi katsayısı formüllerinin başarısı performans kriterlerine göre değerlendirilmiştir. Performans kriterleri açısından değerlendirilmesinin yanı sıra deneysel veriler literatürde bulunan formüller ve yeni üretilen formüller ile hesaplanarak aralarındaki farklar % olarak karşılaştırılmıştır. Her iki sonuca göre uzun başlıklı savaklar için literatürde verilen denklemlerin doğruluğu yeni üretilen denkleme göre daha fazladır. Geniş başlıklı savaklar, keskin kenarlı savaklar ve genel savaklar için üretilen formüller ise literatürde bulunan formüllere göre daha başarılı sonuç vermektedir. Türbülans modeli açısından yapılan değerlendirmelerde, RNG k-ε modeli, Standart k-ε modeline göre daha düşük hata oranlarıyla deneysel sonuçlara daha yakın değerler vermiştir. Özellikle geniş başlıklı savaklarda daha tutarlı sonuçlar elde edilmiştir.

Kaynakça

- [1] Azimi, A.H., Rajaratnam, N., 2009. Discharge characteristics of weirs of finite crest length, Journal of Hydraulic Engineering, ASCE, 135(12): 1081-1085.
- [2] Govinda Rao, N. S., Muralidhar, D., 1963. Discharge characteristics of weirs of finite crest width, Houille Blanche, 18(5), 537-545.
- [3] Ramamurthy, S. A., Tim, U. S., Rao, M. V. J. 1987. Flow Over Sharp Crested Plate Weirs, Journal of Irrigation and Drainage Engineering, 113.
- [4] El-Alfy, K.S., 2005. Effect of vertical curvature of flow at weir crest on discharge coefficient, Ninth International Water Technology Conference, IWTC9, Sharm El-Sheikh, Egypt, 249-262.
- [5] Doğan, Y., 2009. Savaklarda Kret Şeklinin Debi Katsayısına Etkisinin İncelenmesi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elazığ, 50 s.
- [6] Bilhan, Ö., Emiroğlu, M.E., Kişi, Ö., 2010. Application of two different neural network techniques to lateral outflow over rectangular side weirs located on a straight channel, Advances in Engineering Software, 41, 831-837.

- [7] Salması, F., Yıldırım, G., Masoodi, A., Parsamehr, P., 2013. Predicting discharge coefficient of compound broad-crested weir by using genetic programming (GP) and artificial neural network (ANN) techniques, *Arabian Journal of Geosciences*, 6, 2709-2717.
- [8] Al-Khatip, İ., Gogus, M., 2014. Prediction Models For Discharge Estimation In Rectangular Compound Broad-Crested Weirs, *Flow Measurement and Instrumentation*, 36, 1-8.
- [9] Hoseini, S.H., Afshar, H., 2014. Flow over a Broad-Crested Weir in Subcritical Flow Conditions, *Physical Syudy, Journal of River Engineering*, 2(1), 1005-1012.
- [10] İlkentapar, M., 2015. Açık Kanallarda Geniş Başlıklı Savaklar Üzerindeki Akımın Deneysel Ve Sayısal Modellenmesi. Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri, 130 s.
- [11] Nash, J.E., Sutcliffe, J.V., 1970. River flow forecasting through conceptual models, Part 1: A discussion of principles. *J. Hydrol.* 282–290.

Yüksek FFA İçerikli Yağlar: Doğrudan Transesterifikasyon ve Ardışık Esterifikasyon- Transesterifikasyon Prosesleri ile Biyodizel Üretimine Karşılaştırmalı Analizi

Halis Deviren*¹, Erdal Çilgım²

*^{1,2} Dicle Üniversitesi Diyarbakır Teknik Bilimler Meslek Yüksekokulu Motorlu Araçlar ve Ulaştırma
Teknolojileri Bölümü, DİYARBAKIR

(Alınış / Received: 07.10.2024, Kabul / Accepted: 13.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Anahtar Kelimeler

Serbest Yağ Asidi (FFA),
Menengiç Yağı,
Biyodizel Üretimi,
Esterifikasyon +
Transesterifikasyon,
GC-MS,
FT-IR, ¹H NMR ve ¹³C NMR

Öz: Bu çalışmada, yüksek serbest yağ asidi (FFA) içeriğine sahip menengiç yağı (TO) kullanılarak biyodizel üretimi, tek adımlı (transesterifikasyon) ve iki adımlı (esterifikasyon + transesterifikasyon) yöntemleri ile gerçekleştirilmiştir. %5,8 FFA içeriğine sahip TO, tek adımlı (TOTB100) ve iki adımlı (TOETB100) yöntemleriyle biyodizel dönüşürülmüş ve bu süreçlerin FFA oranının biyodizel verimliliğine etkisi analitik karakterizasyon yöntemleri ile incelenmiştir. Gaz Kromatografisi-Kütle Spektrometrisi (GC-MS) analiz sonuçlarına göre, TO örneğinde oleik asit içeriği %48,4 oranında tespit edilmiş ve TOETB100 biyodizelinde toplam Yağ Asidi Metil Esterleri (FAME) oranı %95,7 olarak hesaplanmıştır. Fourier Dönüşümlü Kızılötesi Spektroskopisi (FT-IR) analizinde, TOETB100 biyodizelinde 1438,1 cm⁻¹ dalga boyunda FAME oluşumunu gösteren karakteristik bir pik gözlemlenmiştir. Proton nükleer manyetik rezonans (¹H NMR) ve Karbon nükleer manyetik rezonans (¹³C NMR) analizleri, TOTB100 biyodizelinde düşük dönüşüm verimliliği (%60,74) gösterirken, TOETB100 biyodizelinde bu oran %78,01 olarak belirlenmiştir. Sonuç olarak, yüksek FFA içeriğine sahip yağların biyodizel üretiminde iki adımlı yöntemin, tek adımlı yöntemle kıyasla daha yüksek verimlilik ve FAME oranı sağladığı belirlenmiştir. Bu bulgular, yüksek FFA içerikli yağların biyodizel üretiminde iki adımlı kimyasal sürecin daha uygun bir yöntem olduğunu ortaya koymaktadır.

High FFA Oils: A Comparative Analysis of Biodiesel Production via Direct Transesterification and Sequential Esterification-Transesterification Processes

Keywords

Free Fatty Acid (FFA),
Terebinth Oil,
Biodiesel Production,
Esterification +
Transesterification,
GC-MS,
FT-IR, ¹H NMR and ¹³C NMR

Abstract: In this study, biodiesel production was carried out using a single-step (transesterification) and a two-step (esterification + transesterification) process with Pistacia terebinthus oil (TO), which has a high free fatty acid (FFA) content. TO, containing 5.8% FFA, was converted into biodiesel using single-step (TOTB100) and two-step (TOETB100) methods, and the effects of FFA content on biodiesel yield were analyzed using analytical characterization techniques. According to the Gas Chromatography-Mass Spectrometry (GC-MS) results, the oleic acid content in the TO sample was determined to be 48.4%, while the total Fatty Acid Methyl Ester (FAME) content in TOETB100 biodiesel was calculated as 95.7%. Fourier Transform Infrared Spectroscopy (FT-IR) analysis revealed a characteristic peak at 1438.1 cm⁻¹, indicating FAME formation in the TOETB100 biodiesel. Proton Nuclear Magnetic Resonance (¹H NMR) and Carbon Nuclear Magnetic Resonance (¹³C NMR) analyses showed that the conversion efficiency of TOTB100 biodiesel was lower (60.74%) compared to that of TOETB100 biodiesel (78.01%). As a result, it was determined that the two-step method provides higher conversion efficiency and FAME content compared to the single-step method in biodiesel production from oils with high FFA content. These findings suggest that the two-step chemical process is a more suitable method for biodiesel production from oils with high FFA content.


1. Giriş

Terebinth (*Pistacia terebinthus* L.) bitkisi, halk arasında genellikle menengiç veya terebentin ağacı olarak bilinen, Anacardiaceae (Sakız ağacıgiller) familyasına ait çok yıllık ve yabancı bir bitkidir. Akdeniz coğrafyasının yaygın bir türü olan menengiç, İtalya, Yunanistan, Suriye, Türkiye ve Tunus gibi ülkelerde doğal olarak yetişmektedir [1,2]. Şekil 1'de görüldüğü üzere, bitkinin meyveleri küçük, yuvarlak ve olgunlaştıkça kırmızıdan siyaha dönen tohumlar olup, tüm parçaları reçinemsi bir kokuya sahiptir [3].




Şekil 1. Menengiç (*Pistacia terebinthus*) meyvesinin olgunlaşma ve kurutulmuş hallerinin görünümü

Olgunlaşma sonrası, menengiç meyvesi yağ açısından zengindir ve doymamış yağ asitleri içerir. Bu tip yağların biyodizel dönüştürülmesi sırasında en önemli parametreler FFA içeriği ve nem oranıdır. Biyodizel sentezi amacıyla kullanılacak yağların %FFA oranının %5'in üzerinde olması durumunda, sabun oluşumu metil ester ve gliserol fazlarının ayrılmasını engelleyerek saf su ile yıkama işlemi sırasında emülsiyon oluşumuna yol açar [4]. FFA oranının %5'in üzerinde olması durumunda, FFA'ların metil esterlere dönüştürülmesi için sülfirik asit (H_2SO_4) gibi asidik bir katalizör kullanılarak esterifikasyon işlemi gerçekleştirilebilir (Şekil 2) [5]. Esterifikasyon, 1 mol FFA ile 1 mol alkolün reaksiyona girmesi sonucu 1 mol ester ve 1 mol H_2O 'nun oluştuğu bir kimyasal reaksiyondur [6]. H_2SO_4 katalizörü ile gerçekleştirilen esterifikasyon sonucunda, trigliseritlerin FFA oranı düşer ve biyodizel üretimi için uygun hale gelir.



Şekil 2. Yağ asidi ve metanolün H_2SO_4 katalizörlüğünde esterifikasyonu

Baz katalizörlü transesterifikasyon reaksiyonunun tamamlanabilmesi için yağın FFA oranının %3'ün altında olması gereklidir (Şekil 3) [4,7]. Aksi takdirde, ester dönüşüm verimi düşük olur ve biyodizel üretimi verimsiz hale gelir. Örneğin, Chouhan ve ark. [8], *Jatropha curcas* L. yağının yoğunluğunu 919 kg/m^3 ve asit değerini $7,46 \text{ mg KOH/g}$ (yaklaşık %3,7 FFA) olarak raporlamıştır. Yüksek FFA içeriğini düşürmek amacıyla yağı %1 potasyum hidroksit (KOH) çözeltisi ile yıkamış ve 5-6 kez sıcak su ile durulayarak serbest yağ asitlerini uzaklaştırmışlardır. Kurutma işleminden sonra, *Lemna perpusilla* Torrey külünü heterojen bir katalizör olarak kullanarak biyodizel sentezi gerçekleştirmişlerdir.



Şekil 3. Trigliseritlerin metanol ile transesterifikasyonu yoluyla metil ester (biyodizel) sentezi

Deeba ve ark. [9] ise *Jatropha curcas* bitkisinin yüksek ekonomik değere sahip ve geniş çapta yetiştirilen, ancak yenilemez yağ içeren bir tür olduğunu belirtmiştir. Bitkinin asidik hidrolizinin zorluğu nedeniyle, tek aşamalı bir proses ile FFA'ların alkali katalizör kullanılarak FAME'ye dönüştürülemeyeceğini ve bunun sabunlaşma (saponifikasyon) reaksiyonlarına yol açacağını ifade etmişlerdir. Yüksek FFA oranının (yaklaşık %11,27) biyodizel oluşumunu ve gliserolden ayrılmasını zorlaştırdığı durumlarda, iki aşamalı bir işlem tercih etmişlerdir. İlk aşamada, FFA oranını %11,27'den %1,43'e düşürebilmek için asidik katalizörlü esterifikasyon işlemi

uygulamışlardır. Esterifikasyon sırasında kullanılan metanol konsantrasyonunun FFA miktarını düşürdüğünü vurgulamışlar ve kalan metanolün yağdan ayrılmasının ardından alkali katalizör (KOH) ile transesterifikasyon işlemi gerçekleştirerek %94'e varan yüksek FAME verimleri elde etmişlerdir. Bu işlemi, 65°C'de ve 2 saatlik bir reaksiyon süresi ile KOH (yağın %1'i oranında) kullanarak tamamlamışlardır.

Bu bağlamda, biyodizel, içten yanmalı motorlarda fosil yakıtlara alternatif olarak kullanılabilir çevre dostu bir yakıt türüdür [10]. Yenilenebilir kaynaklardan üretilmesi, sera gazı emisyonlarını azaltması ve biyolojik olarak doğada çözünebilir bir yapıya sahip olması, biyodizeli özellikle önemli kılmaktadır. Türkiye'de, biyodizel üretimi son yıllarda artış göstermiş olsa da kullanım oranları hâlâ sınırlıdır. Bu araştırma, ülkemizde biyodizel üretim süreçlerinin optimize edilmesine ve biyoyakıt kullanımının yaygınlaştırılmasına yönelik bilimsel temeller sunmaktadır.

Bu çalışmanın amacı, yüksek FFA içeriğine sahip bitkisel yağlardan tek aşamalı transesterifikasyon ve iki aşamalı esterifikasyon + transesterifikasyon yöntemleri ile elde edilen biyodizel ürünlerinin FT-IR, GC-MS, ¹H NMR ve ¹³C NMR analizleri kullanılarak kapsamlı bir şekilde karşılaştırmalı analizini yapmaktır. Literatürde bu tür bir karşılaştırmalı çalışma bulunmadığından, araştırmamızın bu alandaki bilgi eksikliğini gidermesi beklenmektedir.

2. Materyal ve Metot

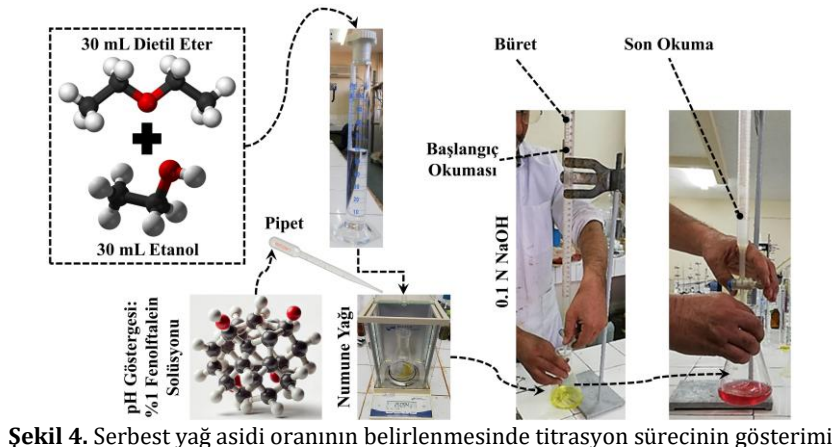
Çalışmamızda biyodizel üretiminde kullanılan TO, Türkiye'nin Güneydoğu Anadolu Bölgesi'nde yer alan Siirt ilinde faaliyet gösteren bir firmadan temin edilmiştir (41° 57' doğu boylamı, 37° 55' kuzey enlemi). Söz konusu yağ, firmanın ticari amaçla satışını yaptığı ve soğuk pres yöntemiyle elde edilen doğal bir yağdır. Biyodizel sentezinde kullanılan kimyasal maddeler ise Merck markası altında temin edilmiştir. Bu maddeler arasında; %1'lik Fenolftalein Solüsyonu, Diethyl Eter [(C₂H₅)₂O], Etanol (C₂H₅OH), Metil Alkol (CH₃OH), Sodyum Hidroksit (NaOH) ve H₂SO₄ bulunmaktadır. Çalışma kapsamında kullanılan tüm kimyasal maddeler, yüksek saflık derecesinde olup, biyodizel üretim sürecinin verimliliğini ve doğruluğunu sağlamak amacıyla dikkatle seçilmiştir. Elde edilen biyodizelin özellikleri, kimyasal safiyeti ve yağın işleme süreci, biyodizel sentezinin etkinliğini doğrudan etkilemiştir.

2.1. TO'nun %FFA oranının belirlenmesi

Biyodizel sentezi için kullanılacak olan TO'nun FFA oranı, oleik asit cinsinden yüzdesel olarak hesaplanmıştır. Bu işlem için öncelikle yaklaşık 2,5 gram TO'ya %1'lik Fenolftalein Solüsyonundan 2-3 damla eklenmiş ve daha sonra bu karışım 0,1 N NaOH çözeltisi ile titre edilmiştir. Titrasyon işlemi, Şekil 4'te gösterildiği üzere renksiz çözeltinin pembe renk aldığı ana kadar devam etmiştir [11,12]. %FFA ise aşağıda verilen Eşitlik (1) kullanılarak hesaplanmıştır:

$$\%FFAs = \frac{V \times 0.028 \times 100}{m} \quad (1)$$

Burada; %FFAs, serbest yağ asidi yüzdesini (%), V, 0,1 N NaOH çözeltisinin hacmini (ml), ve m, TO örneğinin kütlesini (g) ifade etmektedir. Bu yöntem, biyodizel üretimi öncesinde yağın %FFA miktarını belirlemek ve transesterifikasyon verimliliğini artırmak amacıyla titrasyon esaslı bir analiz olarak tercih edilmiştir. Çalışma boyunca FFA değerleri, biyodizel üretim sürecine uygun olarak belirli bir aralıkta tutulmuş ve üretim parametreleri bu değerlere göre optimize edilmiştir.



Şekil 4. Serbest yağ asidi oranının belirlenmesinde titrasyon sürecinin gösterimi

TO örneklerinin titrasyon işlemine tabi tutulması için kullanılacak test numunesinin kütlesi, beklenen asit değerine ve yağın renginde oluşan değişimlere göre belirlenmiştir. Test numunesine ait kütle değerleri ve ölçüm hassasiyetleri, Tablo 1'de verilen %FFA aralıklarına göre hesaplanmıştır. Tabloya göre, FFA yüzdesi beklenen değerden düşük olduğunda, test numunesinin kütlesi daha yüksek tutulmuş; buna karşın, %FFA değeri arttıkça titrasyonun doğruluğunu artırmak amacıyla daha düşük kütlelerde yağ örneği kullanılmıştır. Örneğin, FFA yüzdesi %1'in altında olan yağlar için 20 gramlık bir numune tercih edilirken, %75'in üzerinde bir FFA değerine sahip yağlar için yalnızca 0,1 gramlık numune yeterli görülmüştür. Numune kütlesi ile FFA yüzdesi arasındaki bu ilişki, titre edilen yağ örneklerinin transesterifikasyon verimliliğini doğrudan etkileyen önemli bir parametredir.


Tablo 1. Beklenen FFA yüzdesine göre tartılacak bitkisel veya hayvansal yağ numunesi miktarları [13].

| Beklenen Asit Değeri | Test Numunesi Kütlesi (g) | Test Numunesi Tartım Hassasiyeti (g) |
|----------------------|---------------------------|--------------------------------------|
| <1 | 20 | 0,05 |
| 1-4 | 10 | 0,02 |
| 4-15 | 2,5 | 0,01 |
| 15-75 | 0,5 | 0,001 |
| >75 | 0,1 | 0,0002 |

Tablo 1'de de görüldüğü üzere, numune kütlesinin yanı sıra, tartım hassasiyeti de FFA miktarının doğru ve güvenilir bir şekilde tespit edilmesinde önemli bir rol oynamaktadır. Titrasyon edilen yağ örnekleri için belirlenen bu standartlar, çalışmanın doğruluğunu artırmak ve elde edilen sonuçların güvenilirliğini sağlamak amacıyla titizlikle uygulanmıştır.

2.2. TO'nun biyodizel dönüşürülme mekanizması: tek ve iki aşamalı süreçler

Biyodizel üretiminde kullanılacak olan Terebentin (*Pistacia terebinthus*) yağının esterifikasyon işlemi öncesindeki FFA yüzdesi, titrasyon yöntemi kullanılarak oleik asit cinsinden hesaplanmış ve Eşitlik (1) ile %5,8 olarak tespit edilmiştir. Transesterifikasyon işlemi öncesinde yağın FFA oranını %3'ün altına düşürmek amacıyla, H_2SO_4 katalizörü kullanılarak esterifikasyon reaksiyonu gerçekleştirilmiştir. Bu işlem, Deviren ve ark. [11] çalışmalarında açıklandığı üzere, Şekil 5'te gösterilen yöntem doğrultusunda uygulanmıştır.



Şekil 5. Esterifikasyon sürecinin görselleştirilmesi Ham Yağ ve Esterifikasyon Sonrası Yağın Transesterifikasyon Prosesine Tabi Tutulma Aşamaları

Şekil 5'te yer alan esterifikasyon işlemine ilişkin ayrıntılar aşağıda detaylandırılmıştır [11,12].

A: Yoğunluğu 0.92 g/cm^3 olan, titrasyon yöntemi ile FFA yüzdesi %5,8 olarak hesaplanan 100 ml yağ hacmi ölçülmüştür.

B: Esterifikasyon işlemine tabi tutulacak olan TO'daki potansiyel nem, reaksiyona olumsuz etki yaparak FFA oluşumuna sebep olacağından, yağın nemden arındırılması gerekmektedir. Nem giderme işlemi, BUCHI Rotavapor R-3 marka döner buharlaştırıcıda, $90-95^\circ\text{C}$ 'de ve $-15 \times 100 \text{ kPa}$ vakum koşulları altında, Gast DOA-P504-BN marka diyaframlı yağsız vakum pompası ile gerçekleştirilmiştir.

C: Yağ nemden arındırıldıktan sonra, Eşitlik (2), (3), (4) ve (5) kullanılarak hesaplanan H_2SO_4 miktarı, 20 ml (yağ hacminin %20'si) CH_3OH içerisine eklenmiştir.

$$m_{oil} = \rho_{oil} * V_{oil} \quad (2)$$

Burada, m_{oil} yağın kütleini (g), ρ_{oil} yağın yoğunluğunu (g/cm^3) ve V_{oil} yağın hacmini (ml) ifade eder.

$$m_{FFAs} = m_{oil} * \frac{\%FFAs}{100} \quad (3)$$

Burada, m_{FFAs} 100 ml yağdaki serbest yağ asitlerinin kütleini (g), m_{oil} yağın kütleini (g) ve $\%FFAs$ serbest yağ asidi yüzdesini (%) belirtir.

Esterifikasyon reaksiyonu için gerekli olan H_2SO_4 miktarı, Eşitlik (4) ve Eşitlik (5) ile belirlenmiştir:

$$m_{H_2SO_4} = m_{FFAs} * 0,01 \quad (4)$$

Burada, $m_{H_2SO_4}$ yağın esterifikasyonu için gerekli H_2SO_4 miktarını (g) ve m_{FFAs} 100 ml yağdaki serbest yağ asitlerinin kütleini (g) ifade eder.

$$V_{H_2SO_4} = \frac{m_{H_2SO_4}}{\rho_{H_2SO_4}} \quad (5)$$

Burada, $V_{H_2SO_4}$ esterifikasyon işlemi için gerekli H_2SO_4 miktarını (ml), $m_{H_2SO_4}$ H_2SO_4 'ün kütleini (g) ve $\rho_{H_2SO_4}$ H_2SO_4 'ün yoğunluğunu (g/cm^3) ifade eder.

D: H_2SO_4 ve CH_3OH çözeltileri eklenen 100 ml yağ, $95^\circ C$ 'de 3 saat boyunca esterifikasyon işlemine tabi tutulmuştur.

E: 3 saatlik esterifikasyon işleminin ardından buharlaştırma şişesindeki örnek, 24 saat boyunca bekletilmek üzere ayrıştırma hunisine aktarılmıştır. Bekleme süresinin sonunda alt fazda yoğun konsantrasyonda gliserin oluşumu gözlemlenmiştir. Ancak, esterifikasyon işlemi sadece FFA'lar bazında gerçekleştirildiğinden, alt fazda çok az miktarda gliserin oluşmuş ve üst fazda ise tepkimeye girmemiş TO kalmıştır. Ayrıştırma hunisinin valfi açılarak alt fazdaki gliserin, yağ örneğinden uzaklaştırılmıştır.

F: Alt fazdaki küçük miktarda gliserin uzaklaştırıldıktan sonra, üst fazdaki yağ örneğinin hala gliserin, H_2O içerisinde çözünebilen H_2SO_4 ve istenmeyen CH_3OH içerme olasılığı olduğundan numune, yıkama işlemine tabi tutulmuştur.

G: Ayrıştırma hunisinin valfi açılarak H_2O uzaklaştırılmış, örnek buharlaştırma şişesine aktarılmış ve kalan nem, $95^\circ C$ 'de ve -15×100 kPa vakum koşulları altında 1 saat boyunca uzaklaştırılmıştır.


H: Esterifikasyon işlemi sonrası, yağ örneği tekrar titrasyon edilerek transesterifikasyon işlemi için uygun bir FFA seviyesinde (%3'ten düşük) olup olmadığı kontrol edilmiştir.

I: Titrasyon sonrası yağdaki FFA yüzdesi Eşitlik (1) kullanılarak %2,24 olarak hesaplanmıştır. Bu değer %3'ün altında olduğundan, yağın transesterifikasyon reaksiyonu için uygun olduğu belirlenmiştir.

Esterifikasyon sonrası elde edilen yağ numunesi ve ham yağın biyodizele dönüştürülme süreci, Şekil 6'da gösterildiği gibi belirli bir metodoloji çerçevesinde gerçekleştirilmiştir. İlk olarak, ham yağ esterifikasyon işlemine tabi tutularak asit içeriği azaltılmış ve ardından elde edilen yağ, alkali katalizör kullanılarak transesterifikasyon aşamasına dahil edilmiştir. Bu işlem sırasında, yağın metil ester (ME) formuna dönüşümü, 6:1 metanol-yağ hacim oranında CH_3OH ve yağın kütleinin %1'i oranında KOH katalizörü kullanılarak gerçekleştirilmiştir. Reaksiyon, Deviren ve Aydın [14] ile Deviren [15] tarafından önerilen literatür koşullarına uygun olarak $60^\circ C$ sıcaklık, 600 rpm karıştırma hızı ve 50-60 dakika reaksiyon süresi ile tamamlanmıştır. Reaksiyon süreci boyunca esterifikasyon işlemine tabi tutulmuş yağın metil ester formuna dönüşümü sağlanırken, ham yağdan elde edilen ürünlerde beklenen iki fazlı sistem oluşmamıştır.

Şekil 6'da reaksiyon aşamalarında elde edilen ürünler görsel olarak sunulmuş ve sürecin detayları şematik olarak ifade edilmiştir. Esterifikasyona tabi tutulan yağın transesterifikasyon işlemi sonrasında üst fazda biyodizel, alt fazda ise gliserol birikimi gözlemlenmiştir. Elde edilen iki fazlı sistemde gliserol fazının ayrıştırılmasının ardından,

biyodizelin saflaştırılması amacıyla yıkama işlemi uygulanmıştır. Şekilde de görüldüğü üzere, yıkama sonrasında biyodizel fazında kalan su ve diğer safsızlıkların giderilmesi amacıyla vakumlu kurutma düzeneği kullanılmıştır. Bu saflaştırma adımları, biyodizelin saflığını artırmak ve yan ürünlerin etkin bir şekilde giderilmesini sağlamak amacıyla gerçekleştirilmiştir. Uygulanan ayırma ve kurutma yöntemleri, elde edilen biyoyakıtın kalite standartlarına uygun hale getirilmesine ve yakıt özelliklerinin iyileştirilmesine olanak sağlamaktadır [11,12]. Bu bağlamda, ilgili yöntemler, biyodizel üretim sürecinde verimliliğin ve ürün kalitesinin artırılması açısından büyük önem arz etmektedir.



Şekil 6. Ham yağ ve esterifikasyon işlemi sonrasında elde edilen yağın transesterifikasyon sürecine tabi tutulma aşamaları

2.3. FT-IR, GC-MS ve NMR analizleri

TO ve kimyasal reaksiyonlar sonucu elde edilen ürünlerin fonksiyonel gruplarını belirlemek amacıyla FT-IR, GC-MS ve NMR analizleri gerçekleştirilmiştir. FT-IR spektrumları, Dicle Üniversitesi Eczacılık Fakültesi'nde bulunan Agilent Cary 630 FTIR spektrometresi kullanılarak ATR hücreesine (elmas kristalli) 15-25 µl numune damlatıldıktan sonra 4000-400 cm⁻¹ dalga boyu aralığında ve 8 cm⁻¹ çözünürlükte toplam 128 tarama ile elde edilmiştir. Yeni örnekler için ATR kristali, n-hekzan ile ıslatılmış özel selüloz optik kağıt kullanılarak temizlendikten sonra her örnek ayrı bir Pasteur pipeti ile kristal üzerine damlatılmıştır.

Gaz kromatografisi yöntemi ile ham TO, doğrudan transesterifikasyon işlemi ile elde edilen ürün ve esterifikasyon sonrası transesterifikasyon ile elde edilen biyodizelin bileşimi belirlenmiştir. Örneklerin yağ asitlerinin metil esterlerine dönüştürülmesi için transmetilasyon yöntemi uygulanmış ve %10 (v/v) hekzan içeren 1 µL'lik örnekler 40:1 oranında bölme (split ratio) kullanılarak enjeksiyon yapılmıştır. GC-MS analizleri için Agilent 7890B GC ve 5977B Kütle Seçici Dedektör Sistemi kullanılarak metil ester ve yağ asidi bileşenlerinin tanımlanması gerçekleştirilmiştir. GC-MS cihazlarının koşulları Tablo 2'deki gibidir:

Tablo 2. Gaz Kromatografisi (GC) ve Gaz Kromatografisi/Kütle Spektrometresi (GC/MS) Analiz Koşulları

| Parametre | Değer |
|---|--|
| Sistem (GC) | Agilent 7890B GC Sistemi |
| Kolon (GC ve GC-MS) | Agilent HP-Innowax (60,0 m x 0,25 mm x 0,25 µm) |
| Dedektör (GC ve GC-MS) | Alev iyonizasyon dedektörü (FID) |
| Enjeksiyon Sıcaklığı (GC ve GC-MS) | 250 °C |
| Dedektör Sıcaklığı (GC ve GC-MS) | 250 °C |
| Sıcaklık Programı (GC) | 60°C'de 10 dakika bekleme, 4°C/dak hızla 220°C'ye ısıtma (10 dakika bekleme), 1°C/dak hızla 240°C'ye ısıtma (20 dakika bekleme), Toplam süre: 100 dakika |
| Taşıyıcı Gaz (GC ve GC-MS) | Helyum (0,7 mL/dk) |
| Sistem (GC-MS) | Agilent 7890B GC 5977B Kütle Seçici Dedektör Sistemi |
| İyon Kaynağı Sıcaklığı (GC-MS) | 230 °C |
| İyonizasyon Modu (GC-MS) | EI |
| Elektron Bombardıman İyonizasyonu (GC-MS) | 70 ev |
| Tarama Aralığı (GC-MS) | 35 – 450 m/z |
| Kütle Spektral Kütüphaneleri (GC-MS) | Wiley 9-Nist 11 Kütle Spektral Veri Tabanı |

NMR analizleri için Bruker AVANCE III 400 MHz spektrometresi kullanılarak, sentezlenen ürünlerin ^1H NMR ve ^{13}C NMR analizleri gerçekleştirilmiş ve deuterated chloroform (CDCl_3) çözücü olarak kullanılmıştır. Elde edilen spektrumlar, FAME'lerin proton ve karbon atomlarının doğrulanmasında kullanılmıştır. Yağ asitlerinin metil esterlerine dönüşüm yüzdesini hesaplamak amacıyla, α -metilen protonları ($\sim 2,3$ ppm) ve metoksi protonları ($\sim 3,6$ ppm) arasındaki kimyasal kayma değerleri aşağıdaki Denklem (6) yardımıyla hesaplanmıştır:

$$\text{Biyodizel verimi (\%)} = 100 \times \frac{2I_{Me}}{3I_{Mt}} \quad (6)$$

Burada, I_{Me} metil esterlerin metoksi protonlarının ($\sim 3,67$ ppm'de) integral değeri ve I_{Mt} trigliseritlerdeki α -metilen protonlarının ($\sim 2,29-2,34$ ppm aralığında) integral değeridir. Bu denklem, FAME'lerin dönüşüm oranını belirlemek amacıyla kullanılmaktadır.

3. Bulgular

Bu çalışmada, yüksek FFA içeriğine sahip TO kullanılarak gerçekleştirilen tek ve iki aşamalı kimyasal reaksiyon süreçleri ile elde edilen ürünlerin sentezinin analitik yöntemler kullanılarak ilk kez incelendiği rapor edilmiştir.

3.1. TO'daki %FFA miktarı

Bu çalışmada, biyodizel sentezinde kullanılan terebentin meyvesi yağının FFA yüzdesi, titrasyon yöntemi kullanılarak Denklem (1) ile %5,8 olarak hesaplanmıştır. Literatürdeki önceki çalışmalara göre, FFA yüzdesi %3'ün altında olmadığından, bu yağın tek aşamalı alkali katalizli transesterifikasyon süreci için uygun olmadığı belirlenmiştir. FFA yüzdesini düşürmek amacıyla asit katalizli bir esterifikasyon işlemi uygulanmış ve işlem sonrası FFA yüzdesi Denklem (1) kullanılarak tekrar hesaplanmış ve %2,24 olarak tespit edilmiştir.

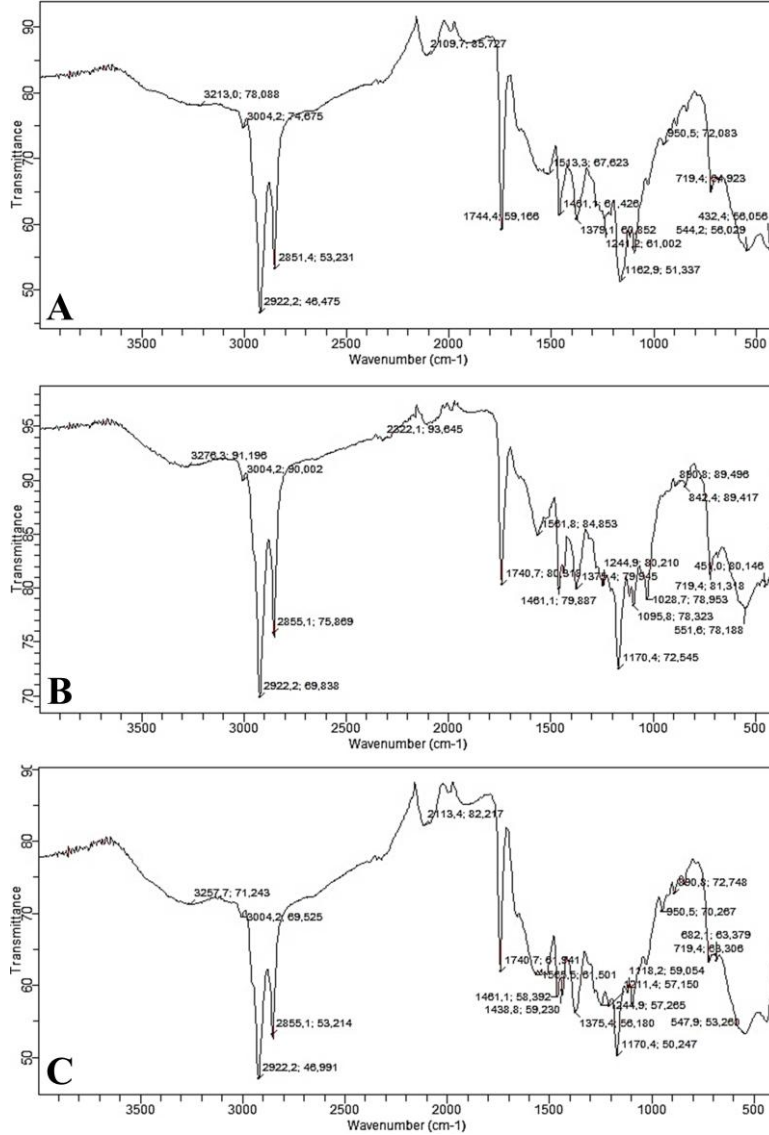
3.2. FT-IR analizi

Şekil 7 (A), (B) ve (C), sırasıyla ham TO, TO'nun alkali katalizli transesterifikasyon süreci ile elde edilen ürünü ve asit katalizli esterifikasyon işlemi sonrası gerçekleştirilen alkali katalizli transesterifikasyon süreci ile elde edilen ürünlerin FT-IR spektrumlarını göstermektedir. Üç örneğin FT-IR spektrumlarında, cis-alken $-\text{HC}=\text{CH}-$ gruplarına ait doymamış yağ asitlerinin karakteristik tepe titreşimleri $3004,2 \text{ cm}^{-1}$ dalga boyunda tespit edilmiştir. Lipitlerdeki metilen ($-\text{CH}_2$) gruplarına ait asimetric vas($\text{C}-\text{H}$) gerilme titreşimleri, TO için $2922,2 \text{ cm}^{-1}$ 'de; simetric vs($\text{C}-\text{H}$) gerilme titreşimleri ise TO için $2851,1 \text{ cm}^{-1}$ 'de ve diğer örneklerde $2855,1 \text{ cm}^{-1}$ 'de gözlemlenmiştir. Lipitler ve yağ asitlerinin ester fonksiyonel gruplarındaki $\nu(\text{C}=\text{O})$ gerilme titreşimleri ise TO için $1744,4 \text{ cm}^{-1}$ 'de, diğer örneklerde ise $1740,7 \text{ cm}^{-1}$ dalga boyunda meydana gelmiştir.

Şekil 7 (A) ve Şekil 7 (B)'de görüldüğü üzere, ham TO ve herhangi bir işlem uygulanmamış yağın tek aşamalı alkali katalizli transesterifikasyon reaksiyonu ile elde edilen ürünlerin FT-IR spektrumlarında yalnızca bir tepe noktası, $1461,1 \text{ cm}^{-1}$ dalga boyunda gözlemlenmiştir. Buna karşın, Şekil 7 (C)'de gösterildiği gibi, asit katalizli esterifikasyon işlemi ile FFA oranı %2,24'e düşürüldükten sonra gerçekleştirilen transesterifikasyon süreci sonucunda elde edilen biyodizellerin FT-IR spektrumlarında, CH_2 ve CH_3 gruplarının bükülme titreşimlerine ait çift tepe noktası sırasıyla $1438,8 \text{ cm}^{-1}$ ve $1461,1 \text{ cm}^{-1}$ dalga boylarında tespit edilmiştir. Bu karakteristik titreşimler, literatürde biyodizel dönüşüm süreçlerinin kantitatif olarak izlenmesi için en hassas tepe noktaları olarak kabul edilmektedir. Özellikle, trigliseritlerin FAME'lere dönüşümü sırasında $1438,8 \text{ cm}^{-1}$ dalga boyundaki (metil CH asimetric bükülme) emilimde meydana gelen artış, metil ester oranının yükselmesi ile ilişkilendirilmektedir. Literatürde Deviren ve Aydın (1.435 cm^{-1}) [14], Satis ve arkadaşları (1.445 cm^{-1}) [16] ve Reyman ve arkadaşları (1.437 cm^{-1}) [17] tarafından rapor edilen bu tepe noktası, FAME karışımlarında CH_3 gruplarının varlığını gösteren önemli bir gösterge olarak kabul edilmektedir. Bu bulgular, biyodizel üretim süreçlerinde metil ester oluşumunun izlenmesi ve reaksiyon verimliliğinin değerlendirilmesi açısından önemli bir referans noktası sunmaktadır.

Bu bağlamda, çalışmamızda elde edilen FT-IR sonuçları, literatürde belirtilen değerler ile büyük oranda örtüşmekte olup, uygulanan yöntemlerin etkinliğini doğrulamaktadır. Serbest yağ asitlerinin esterleşme oranının düşürülmesi ile transesterifikasyon verimliliğinde artış sağlandığı ve biyodizel dönüşüm sürecinin başarıyla tamamlandığı, spektrum analizleri ile açıkça ortaya konulmuştur. Bu bulgular, yağların biyodizele dönüştürülme sürecinde optimum koşulların, özellikle uygun %FFA değerlerinin sağlanmasının, kritik bir rol oynadığını göstermektedir. Ayrıca, daha yüksek verimlilikte biyodizel üretimi için reaksiyon parametrelerinin dikkatlice kontrol edilmesi gerektiği de vurgulanmaktadır. Uygun %FFA değerine sahip yağ örnekleri ile gerçekleştirilen transesterifikasyon sürecinde gözlemlenen yüksek verim, biyodizel üretiminde maliyet ve zaman açısından da avantaj sağlamaktadır. Bu durum, sadece laboratuvar ortamında değil, endüstriyel üretim süreçlerinde de

transesterifikasyonun etkin bir şekilde uygulanabilmesi için yol gösterici niteliktedir. Dolayısıyla, bu çalışma, biyodizel üretim verimliliğinin artırılması ve biyoyakıt üretim süreçlerinin optimizasyonu açısından önemli bir referans sunmaktadır.




Şekil 7. (A) TO'nun, (B) TOTB100'ün ve (C) TOETB100'ün FT-IR spektrumu

3.3. GC-MS analizi

Ham TO numunesine uygulanan GC-MS analizi sonuçlarına göre, elde edilen yağ asidi kompozisyonu Şekil 8'de sunulmuştur. Ham yağ ve esterifikasyon işlemi sonrasındaki numunenin alkali katalizör kullanılarak gerçekleştirilen transesterifikasyon süreciyle elde edilen biyodizelin FAME dönüşüm oranları ise Şekil 9 ve Şekil 10'da detaylandırılmıştır.


Analiz sonuçları, TO numunesinde en yüksek oranda bulunan doymamış yağ asidinin %48,4 ile oleik asit olduğunu ortaya koymuştur. Bu yağ asidini sırasıyla linoleik asit (%20,6), elaidik asit (%3,8), palmitoleik asit (%2,8) ve linolenik asit (%0,8) takip etmektedir. Doymuş yağ asitleri arasında ise en baskın bileşik %20,2 ile palmitik asit, ardından %2,5 oranında stearik asittir. Bu veriler, TO'nun kompozisyonunda doymamış yağ asitlerinin baskın olduğunu ve bu durumun yağın trigliserid yapısının büyük ölçüde oleik asit ailesine ait olduğunu göstermektedir. Oleik asidin yüksek oranı, TO'yu biyodizel üretiminde avantajlı kılmakta ve bu yağın biyodizel sentezi için uygun bir hammadde olduğunu işaret etmektedir.

Doymamış yağ asitleri içeriği, biyodizel yakıtların kalite kriterlerini etkileyen viskozite, setan sayısı ve oksidasyon kararlılığı gibi özellikleri pozitif yönde etkilemektedir. Bu da TO'nun biyodizel üretimi için hem ekonomik hem de çevresel açıdan sürdürülebilir bir seçenek olduğunu kanıtlamaktadır [18-20].



Şekil 8. TO'nun GC - kromatogramı

Daha önce belirtildiği gibi, TO'daki FFA oranı %5,8 olarak tespit edilmiştir. Bu oranın biyodizel sentezi üzerindeki etkisini değerlendirebilmek amacıyla, ham yağ üzerinde nem giderme ve filtrasyon işlemleri dışında herhangi bir ön işlem uygulanmaksızın, doğrudan tek aşamalı alkali katalizli transesterifikasyon yöntemi uygulanmıştır (Şekil 6). Genellikle düşük FFA oranına sahip yağlar için tercih edilen alkali katalizli transesterifikasyon prosesi, TO'nun yüksek FFA içeriğine rağmen uygulanmış ve Şekil 9'da görüldüğü üzere, dönüşüm veriminde bir miktar düşüş gözlemlense de belirli bir dönüşüm sağlanabilmiştir. Bu durum, alkali katalizli transesterifikasyon yönteminin yüksek FFA içeriğine sahip yağlar için de kısmen kullanılabilir olduğunu göstermektedir.




Şekil 9. TOTB100'ün GC - kromatogramı

Şekil 9'da gösterildiği gibi, bu işlem sonucunda elde edilen TOTB100 örneğinin GC-MS analizi, FAME ve FFA olarak farklı bileşenlere dönüştüğünü ortaya koymuştur. Elde edilen yeni metil ester bileşenlerinin oranları sırasıyla: palmitik asit metil esteri (%18,7), metil palmitoleat (%2,6), stearik asit metil esteri (%2,3), metil oleat (%44,1), metil elaidat (%3,6), metil linoleat (%19,2) ve metil linolenat (%0,7) olarak belirlenmiştir. Bu oranlar, biyodizel ürününün temel bileşenlerini oluşturan metil esterlerin, ham yağdaki yağ asitlerinin büyük çoğunluğunu dönüştürdüğünü ve FAME'lerin biyodizel sentezindeki istenilen özellikleri sağladığını göstermektedir. Tek aşamalı transesterifikasyon işlemi sonucunda, elde edilen toplam FAME oranı %91,2, toplam esterleşmemiş yağ asitlerinin oranı ise %8,8 olarak hesaplanmıştır.

İki aşamalı işlem (esterifikasyon + transesterifikasyon) sonrasında, biyodizel sentezi için kullanılan TO'nun yağ asidi bileşenleri, Şekil 10'da görüldüğü üzere biyodizel bileşenlerine dönüşmüştür. Bu işlem sonucunda elde edilen metil ester bileşenlerinin oranları; palmitik asit metil esteri (%19,3), metil palmitoleat (%2,7), stearik asit metil esteri (%2,4), metil oleat (%46,6), metil elaidat (%3,7), metil linoleat (%20,2) ve metil linolenat (%0,8) olarak tespit edilmiştir. Bu oranlar, elde edilen biyodizel örneğinin temel metil ester bileşenlerini başarıyla içerdiğini ve yüksek verimlilikte bir dönüşüm sağlandığını göstermektedir. İki aşamalı reaksiyon sonucunda elde edilen biyodizelin toplam metil ester içeriği %95,7 olarak belirlenmiştir. Bu yüksek metil ester oranı, TO'nun biyoyakıt

üretiminde büyük bir potansiyele sahip olduğunu ve biyodizel sentezi için uygun bir hammadde olduğunu ortaya koymaktadır.




Şekil 10. TOETB100'ün GC - kromatogramı

Elde edilen biyodizelin yüksek oleik asit metil esteri (%46,6) ve linoleik asit metil esteri (%20,2) içeriği, biyodizel kalitesini artıran önemli unsurlar olarak değerlendirilmiştir. Ayrıca, düşük stearik asit metil esteri (%2,4) ve diğer doymuş yağ asitlerinin düşük seviyelerde bulunması, yakıtın akışkanlık özelliklerini iyileştirecek ve soğuk hava performansını artıracaktır. Dolayısıyla, iki aşamalı esterifikasyon ve transesterifikasyon işleminin, yüksek serbest yağ asidi içeriğine sahip TO'nun biyodizel dönüşürülmesinde başarılı bir yöntem olduğu ve biyoyakıt üretimi için avantajlı bir süreç sunduğu söylenebilir.

3.4. Nükleer Manyetik Rezonans (NMR) analizi


Sıvı bitkisel yağlar veya katı hayvansal yağların yağ asidi profillerini elde etmenin bir yaklaşımı, sentezlenen biyodizel içerisindeki yağ bileşiklerinin seviyelerini belirlemek ve biyodizel-dizel karışımlarını analiz etmek için NMR analizinden yararlanmaktır [21–23]. Şekil 16'da görüldüğü üzere, gliserol molekülündeki karbon atomları "stereospesifik numaralandırma (sn) sistemi" kullanılarak numaralandırılmış ve yağ asitlerinin (FA) asil grubu sn-1 pozisyonuna, ikinci asil grubu (orta karbon) sn-2 pozisyonuna ve üçüncü asil grubu sn-3 pozisyonuna bağlanmıştır [24].



Şekil 11. Triasilgliserollerin stereospesifik 'sn' numaralandırması


Genel olarak, bitkisel veya hayvansal yağların ^1H NMR kimyasal kaymaları, belirli rezonans aralıklarında sınıflandırılabilir: izole çift bağların olefinik protonları için 5,3–6,2 ppm; konjuge çift bağların olefinik protonları için 5,2–6,4 ppm; gliserol grubu protonları için 3,7–5,1 ppm; allilik protonlar için 2,6–3,05 ppm; $\alpha\text{-CH}_2$ protonları için 2,3–2,5 ppm; $\text{CH}_2\text{-CH=CH}$ protonları için ~2,0 ppm; ve sırasıyla $(\text{CH}_2)_n$ ve CH_3 protonları için 1,2–1,6 ppm ve 0,86–0,98 ppm aralıkları [25]. Çalışmamızda, TO, TOTB100 ve TOETB100 numunelerinin ^1H NMR spektrumları Şekil 12, Şekil 13 ve Şekil 14'te sunulmuştur. TO, TOTB100 ve TOETB100 numunelerinin ^1H NMR spektrumları incelendiğinde, 0,89–0,91 ppm aralığında linolenil grubu dışında, hem doymuş (C16–C18) hem de doymamış (C16=1; C18=1–3) yağ asidi zincirlerinden oluşan trigliseritlerin terminal ($-\text{CH}_3$) protonlarının spektrumlarının bulunduğu görülmüştür. Tüm asil zinciri protonları 1,26–1,32 ppm ($(\text{CH}_2)_n$), 1,61–1,64 ppm ($-\text{OCO-CH}_2\text{-CH}_2-$) ve 2,28–2,34 ppm ($-\text{OCO-CH}_2-$) aralığında gözlemlenmiştir ve doymamış yağ asidi protonları ise 2,01–2,09 ppm ($-\text{CH}_2\text{-CH=CH-}$) aralığında tespit edilmiştir. Son olarak, üç numunenin tümünde doymamış yağ asidi protonları ($-\text{CH=CH-}$; sn-2) 5,34–5,40 ppm aralığında gözlemlenmiş olup, bu aralık çözücü olarak kullanılan deuterokloroform (CDCl_3) sinyalinden kaynaklanmaktadır (7,28 ppm).

TO (Şekil 12) ve TOTB100 (Şekil 13) örneklerinin ^1H NMR spektrumları incelendiğinde, gliserol molekülünün fonksiyonel grubu nedeniyle 4,13–4,18 ppm ($-\text{CH}_2-\text{OCO}-$ sn-1,3) ve 4,28–4,33 ppm ($-\text{CH}_2-\text{OCO}-$ sn-1,2) aralığında pikler gözlemlenmiştir. Ayrıca, bu iki örnekte 5,27–5,30 ppm aralığında gözlemlenen piklerin gliserolden (triasilgliseroller $>\text{CHOCOR}$) kaynaklandığı tespit edilmiştir.



Şekil 12. TO'nun ^1H -NMR spektrumu


Şekil 13'teki TOTB100 örneğinin ^1H NMR spektrumu incelendiğinde, metil esterlerin metoksi protonları ($-\text{CH}_3\text{COOH}$) 3,67 ppm'de tespit edilmiş olup, 4,13–4,18 ppm ($-\text{CH}_2-\text{OCO}-$ sn-1,3) ve 5,27–5,30 ppm ($>\text{CHOCOR}$) aralığındaki sinyaller ise minimum seviyeye inmemiş veya kaybolmamıştır. Bu numunede, biyodizel içindeki istenmeyen metil grubu ($-\text{CH}_3\text{OH}$) protonları için 3,47 ppm'de bir pik gözlemlenmiştir.



Şekil 13. TOTB100'ün ^1H -NMR spektrumu

İki aşamalı (esterifikasyon + transesterifikasyon) işlem sonrası elde edilen TOETB100 örneğinin Şekil 14'teki ^1H NMR spektrumu incelendiğinde, 4,13–4,18 ppm ($-\text{CH}_2-\text{OCO}-$ sn-1,3) ve 5,27–5,30 ppm ($>\text{CHOCOR}$) aralığındaki sinyallerin minimum seviyeye düştüğü veya tamamen kaybolduğu gözlemlenmiştir. Bu, biyodizel dönüşümü gösteren metil esterlerin metoksi protonlarının ($-\text{CH}_3\text{COOH}$) 3,67 ppm'de görüldüğünü doğrulamaktadır. Chutia

ve ark. [26], 3,66 ppm'de gözlemlenen yüksek yoğunluktaki sinyalin (-CO-OCH₃) Xanthium strumarium metil esterlerinin oluşumunu doğruladığını bildirmiştir.




Şekil 14. TOETB100'ün ¹H-NMR spektrumu

TOTB100 ve TOETB100 numunelerinin ¹H NMR spektrumları incelendiğinde, her iki numunede de 3,67 ppm'de pik yapan metoksi (-CH₃COOH) protonlarının integral değerleri, TOTB100 ve TOETB100 için sırasıyla 4,1 ve 5,5 olarak hesaplanmıştır. Trigliseritlerde 2,29–2,34 ppm aralığında pik yapan α-metilen (-OCO-CH₂-) protonlarının integral değerleri ise, TOTB100 ve TOETB100 numuneleri için sırasıyla 4,5 ve 4,7 olarak belirlenmiştir. Bu değerler, Eşitlik (6) kullanılarak hesaplandığında biyodizel dönüşüm oranı TOTB100 için %60,74 ve TOETB100 için %78,01 olarak hesaplanmıştır.


Bu çalışmada elde edilen tüm numunelere ait ¹H NMR spektrumları incelendiğinde, TOTB100 numunesinde 3,67 ppm'de metoksi protonlarının (-CH₃COOH) varlığı muhtemel olsa da, TO numunesi ile benzer fonksiyonel gruplara sahip olduğu görülmektedir.

Bitkisel ve hayvansal yağlar ile metil esterlerin ¹³C NMR spektrumları, geniş kimyasal kayma aralığına ve yüksek çözünürlüğe sahip olması nedeniyle, yağ profillerinin ve yağ asitleri bileşimlerinin daha hassas bir şekilde belirlenmesine olanak tanımaktadır [27–29]. Bu sebeple, çalışmamızda biyodizelin kimyasal yapısını doğrulamak amacıyla ¹³C NMR analizi kullanılmıştır. Şekil 15, Şekil 16 ve Şekil 17'de TO, TOTB100 ve TOETB100 numunelerinin ¹³C NMR spektrumları sunulmuştur. Farklı kimyasal kayma bölgelerinin genişletilmiş görüntüleri, trigliseritlere ve yağ asidi zincirlerine özgü keskin sinyalleri yüksek çözünürlükte ortaya koymaktadır.

Üç numunenin ¹³C NMR spektrumları incelendiğinde, doymuş ve doymamış yağ asitlerine ait karbonil grupları 172,79–173,28 ppm (-OCH₂- sn-1,2/1,3) aralığında gözlemlenmiştir. Doymamış yağ asidi karbonları için 129,67–130,17 ppm aralığında pikler meydana gelirken, konjüge olmayan (-CH=CH-CH₂-CH=CH-) yapıdaki dış karbonlar için de bu aralıkta sinyaller tespit edilmiştir. Konjüge olmayan yapıdaki iç karbonlar ise 127,89–128,06 ppm aralığında gözlemlenmiştir. Çözücü olarak kullanılan CDCl₃'ten kaynaklanan triplet sinyaller 876,72–877,36 ppm aralığında ortaya çıkmıştır. 62,07–68,88 ppm aralığındaki sinyaller ise trigliseritlerin doymuş ve doymamış yağ asitlerinin karbonil gruplarından (OCH₂ sn-1,3/2) kaynaklanmaktadır. Ayrıca, 27,17–29,75 ppm aralığında gözlemlenen sinyaller etilen karbonuna (-CH₂-) ait iken, 31,51–34,17 ppm aralığında gözlemlenen pikler alifatik metilen (CH₂-S) karbon atomlarından kaynaklanmaktadır. Diğer taraftan, 22,5–22,7 ppm aralığındaki sinyaller (β-CH₂) ve 14,00–14,12 ppm aralığındaki pikler ise (α-CH₃) karbon atomlarının varlığını göstermektedir. Biyodizelin tanımlanmasında kullanılan karakteristik ester sinyalleri, doymuş esterler için 174,22 ppm (C=O) ve 174,18 ppm (C=O), doymamış esterler için ise 51,37 ppm (OCH₃) aralığında gözlemlenmiştir [30].



Şekil 16 ve Şekil 17'de görüldüğü üzere, TOTB100 numunesinde ester karbonil grubuna (-COO-) ait sinyaller 174,32–174,36 ppm aralığında gözlemlenirken, TOETB100 numunesinde ise bu sinyaller 174,25–174,28 ppm aralığında tespit edilmiştir. Her iki örnekte de 51,37–51,40 ppm aralığında karakteristik ester sinyalleri gözlemlenmiştir. Benzer şekilde, Chutia ve ark. [26], ¹³C NMR spektrumunda biyodizel ait metoksi karbonlarının (-CO-OCH₃) 51,03 ppm'de gözlemlenen pik ile doğrulandığını ve Xanthium strumarium tohum yağı (trigliserit) dönüşümünün 173,6 ppm'de gözlemlenen ester karbonil grubu (-COOR) sinyalleri ile teyit edildiğini belirtmiştir.



örneğinde toplam FAME oranı %91,2, toplam esterleşmemiş yağ asitleri oranı ise %7,3 olarak hesaplanırken; iki aşamalı işlemle elde edilen TOETB100 örneğinde bu oranlar sırasıyla %95,7 ve %3,1 olarak belirlenmiştir. Bu bulgular, iki aşamalı sürecin daha yüksek metil ester dönüşüm oranı sağladığını ve biyodizel verimliliğini artırdığını göstermektedir.

¹H NMR spektrumları incelendiğinde, TO, TOTB100 ve TOETB100 örneklerinin uzun alkil yağ asidi zinciri sinyalleri 0,89–2,80 ppm aralığında benzer özellikler sergilemiştir. Bununla birlikte, TOETB100 örneğinde spektral özelliklere ait herhangi bir pik gözlemlenmezken, TOTB100 örneğinde gliserol fonksiyonel gruplarına ait δ 4,13– δ 4,17, δ 4,28– δ 4,32 ve δ 5,27– δ 5,30 ppm aralıklarında pikler gözlemlenmiştir. Benzer şekilde, ¹³C NMR spektrumlarında da TOETB100 örneğinde δ 63,30– δ 63,40 ppm aralığında gliseril grubuna (–CH₂OCOR) ait fonksiyonel grupların olmadığı tespit edilmiştir. Ester karbonil grupları (–COO–) TOTB100 ve TOETB100 örneklerinde sırasıyla δ 174,32– δ 174,36 ppm ve δ 174,25– δ 174,28 ppm aralıklarında gözlemlenmiştir. Ancak, TOTB100 örneğinde trigliserit yağ asidi profili ile benzer özellikler tespit edilmiştir. Ayrıca, TOTB100 örneğinde biyodizel içerisindeki istenmeyen –CH₃OH (metil grubu) fonksiyonel grupları ¹H NMR ve ¹³C NMR spektrumlarında sırasıyla δ 3,47 ppm ve δ 50,61 ppm aralıklarında gözlemlenmiştir.

Biyodizel yakıtlarının dizel motorlarda kullanımı çeşitli avantajlar ve dezavantajlar sunmaktadır. Biyodizelin önemli avantajlarından biri, sera gazı emisyonlarını azaltmasıdır. Biyodizel kullanımı, fosil yakıtların yanmasıyla ortaya çıkan karbondioksit (CO₂) emisyonlarını önemli ölçüde düşürmektedir [31]. Ayrıca, biyodizelin yenilenebilir kaynaklardan elde edilmesi ve biyolojik olarak parçalanabilir yapıya sahip olması, çevresel sürdürülebilirliğe katkı sağlamaktadır [32]. Bununla birlikte, biyodizelin yağlama özelliklerinin motor bileşenlerinin aşınmasını azalttığı bilinmektedir [33]. Ancak biyodizelin viskozite ve yoğunluk özelliklerinin, püskürtme kalitesini ve yanma sürecini etkileyebileceği belirtilmektedir [34].

Bu çalışmada, biyodizel üretiminde kullanılan tek aşamalı transesterifikasyon yöntemi ile iki aşamalı esterifikasyon + transesterifikasyon yöntemi arasındaki maliyet faktörleri, literatürde sunulan veriler ve mevcut teorik bilgiler çerçevesinde değerlendirilmiştir. Literatür verilerine göre, iki aşamalı yöntemin tek aşamalı yöntemle kıyasla daha fazla reaktif ve enerji gerektirdiği yaygın olarak rapor edilmektedir. Özellikle, esterifikasyon aşamasında kullanılan H₂SO₄ ve metanol gibi kimyasalların maliyet üzerindeki etkisinin belirgin olduğu vurgulanmaktadır. Bunun yanı sıra, iki aşamalı yöntemde toplam reaksiyon süresinin daha uzun olması nedeniyle enerji tüketiminin arttığı ve bu durumun yöntemin maliyetine katkı sağladığı bildirilmektedir. Bununla birlikte, iki aşamalı yöntemin, biyodizel dönüşüm verimliliğini artırması sebebiyle üretim sürecinde verimlilik-maliyet dengesinin dikkate alınması gerektiği ifade edilmektedir. Bu bağlamda, yüksek FFA içeriğine sahip bitkisel yağların, öncelikle bir asit katalizör (örneğin H₂SO₄) ile esterifikasyon işlemine tabi tutulması ve %FFA oranı %3'ün altına düşürüldükten sonra baz katalizli transesterifikasyon işlemine geçilmesi gerektiği belirtilmektedir. Bu işlem sırası, biyodizel dönüşümünde yüksek verimlilik elde edilmesini sağlamaktadır. Çalışmadan elde edilen bulgular, TO gibi yüksek FFA içeriğine sahip yağların biyodizel üretimi için uygun bir hammadde olabileceğini ve uygun kimyasal işlemlerle dönüşüm verimliliğinin artırılabilirliğini göstermektedir. Bu hususlar, literatürdeki bulgular ve teorik beklentiler ışığında çalışmada dikkate alınmıştır.

Simgeler ve Kısaltmalar

| | | | |
|---------------------|--|---|-------------------------|
| FFA | : Serbest Yağ Asidi | H ₂ SO ₄ | : Sülfirik Asit |
| TO | : Menengiç Yağı | KOH | : Potasyum Hidroksit |
| TOTB100 | : Menengiç Yağı Transesterifiye Biyodizel (%100) | (C ₂ H ₅) ₂ O | : Dietyl Eter |
| TOETB100 | : Menengiç Yağı Esterifiye ve Transesterifiye Biyodizel (%100) | C ₂ H ₅ OH | : Etanol |
| GC-MS | : Gaz Kromatografisi-Kütle Spektrometrisi | CH ₃ OH | : Metil Alkol |
| FAME | : Yağ Asidi Metil Esterleri | NaOH | : Sodyum Hidroksit |
| FT-IR | : Fourier Dönüşümlü Kızılötesi Spektroskopisi | ME | : Metil Ester |
| ¹ H NMR | : Proton Nükleer Manyetik Rezonans | CDCl ₃ | : Deuterated Chloroform |
| ¹³ C NMR | : Karbon Nükleer Manyetik Rezonans | CO ₂ | : Karbondioksit |

Kaynakça

- [1] Townsend CC, Davis PH. Flora of Turkey and the East Aegean Islands. Kew Bulletin 1973;28:328. <https://doi.org/10.2307/4119794>.
- [2] Gercheva P, Zhivondov A, Nacheva L, Avanzato D. Transsexual forms of pistachio (*pistacia terebinthus* l.) from bulgaria - Biotechnological approaches for preservation, multiplication and inclusion in selection programs. Bulgarian Journal of Agricultural Science 2008;14:449-53.
- [3] Özgür T, Özcanlı M, Aydın K. Investigation of nanoparticle additives to biodiesel for improvement of the performance and exhaust emissions in a compression ignition engine. International Journal of Green Energy 2015;12:51-6. <https://doi.org/10.1080/15435075.2014.889011>.
- [4] Dorado MP, Ballesteros E, De Almeida JA, Schellert C, Löhrlin HP, Krause R. An alkalai-catalyzed transesterification process for high free fatty acid waste oils. Transactions of the American Society of Agricultural Engineers 2002;45:525-9. <https://doi.org/10.13031/2013.8849>.
- [5] Van Gerpen J. Biodiesel processing and production. Fuel Processing Technology 2005;86:1097-107. <https://doi.org/10.1016/j.fuproc.2004.11.005>.
- [6] Gebremariam SN, Marchetti JM. Biodiesel production through sulfuric acid catalyzed transesterification of acidic oil: Techno economic feasibility of different process alternatives. Energy Conversion and Management 2018;174:639-48. <https://doi.org/10.1016/j.enconman.2018.08.078>.
- [7] Ali MH, Mashud M, Rubel MR, Ahmad RH. Biodiesel from Neem oil as an alternative fuel for diesel engine. Procedia Engineering 2013;56:625-30. <https://doi.org/10.1016/j.proeng.2013.03.169>.
- [8] Chouhan APS, Sarma AK. Biodiesel production from *Jatropha curcas* L. oil using Lemna perpusilla Torrey ash as heterogeneous catalyst. Biomass and Bioenergy 2013;55:386-9. <https://doi.org/10.1016/j.biombioe.2013.02.009>.
- [9] Deeba F, Kumar V, Gautam K, Saxena RK, Sharma DK. Bioprocessing of *Jatropha curcas* seed oil and deoiled seed hulls for the production of biodiesel and biogas. Biomass and Bioenergy 2012;40:13-8. <https://doi.org/10.1016/j.biombioe.2012.01.009>.
- [10] İlkiliç C, Aydın S, Behcet R, Aydın H. Biodiesel from safflower oil and its application in a diesel engine. Fuel Processing Technology 2011;92:356-62. <https://doi.org/10.1016/j.fuproc.2010.09.028>.
- [11] Deviren H, Çılğın E, Aydın S. Study on using nano magnesium oxide (MNMgO) nanoparticles as fuel additives in terebinth oil biodiesel blends in a research diesel engine. Energy Sources, Part A: Recovery, Utilization and Environmental Effects 2023;45:12181-200. <https://doi.org/10.1080/15567036.2023.2270559>.
- [12] Deviren H, Çılğın E, Bayındır H. Role of analytical methods in verifying biodiesel upgrades: Emphasis on nanoparticle and acetone integration for enhanced performance, combustion, and emissions. Heat Transfer 2024;n/a. <https://doi.org/10.1002/htj.23110>.
- [13] Fuse T, Kusu F, Takamura K. Determination of acid values of fats and oils by flow injection analysis with electrochemical detection. Journal of Pharmaceutical and Biomedical Analysis 1997;15:1515-9. [https://doi.org/10.1016/S0731-7085\(97\)00039-3](https://doi.org/10.1016/S0731-7085(97)00039-3).
- [14] Deviren H, Aydın H. Production and physicochemical properties of safflower seed oil extracted using different methods and its conversion to biodiesel. Fuel 2023;343:128001. <https://doi.org/10.1016/j.fuel.2023.128001>.
- [15] Deviren H. Enhancing diesel engine efficiency and emission performance through oxygenated and non-oxygenated additives: A comparative study of alcohol and cycloalkane impacts on diesel-biodiesel blends. Energy 2024;307:132569. <https://doi.org/10.1016/j.energy.2024.132569>.
- [16] Siatis NG, Kimbaris AC, Pappas CS, Tarantilis PA, Polissiou MG. Improvement of biodiesel production based on the application of ultrasound: Monitoring of the procedure by FTIR spectroscopy. JAOCS, Journal of the American Oil Chemists' Society 2006;83:53-7. <https://doi.org/10.1007/s11746-006-1175-1>.
- [17] Reyman D, Saiz Bermejo A, Ramirez Uceda I, Rodriguez Gamero M. A new FTIR method to monitor transesterification in biodiesel production by ultrasonication. Environmental Chemistry Letters 2014;12:235-40. <https://doi.org/10.1007/s10311-013-0440-4>.
- [18] Sokoto M, Hassan L, Dangoggo S, Ahmad H, Uba A. Influence of Fatty Acid Methyl Esters on Fuel properties of Biodiesel Produced from the Seeds Oil of *Curcubita pepo*. Nigerian Journal of Basic and Applied Sciences 2011;19. <https://doi.org/10.4314/njbas.v19i1.69348>.

- [19] Peng X, Chen H. Single cell oil production in solid-state fermentation by *Microsphaeropsis* sp. from steam-exploded wheat straw mixed with wheat bran. *Bioresource Technology* 2008;99:3885–9. <https://doi.org/10.1016/j.biortech.2007.08.015>.
- [20] Vicente G, Bautista LF, Rodríguez R, Gutiérrez FJ, Sádaba I, Ruiz-Vázquez RM, et al. Biodiesel production from biomass of an oleaginous fungus. *Biochemical Engineering Journal* 2009;48:22–7. <https://doi.org/10.1016/j.bej.2009.07.014>.
- [21] Hämäläinen T, Kamal-Eldin A. Analysis of Lipid Oxidation Products by NMR Spectroscopy. *Analysis of Lipid Oxidation* 2005:70–126. <https://doi.org/10.1201/9781439822395.ch5>.
- [22] Knothe G, Kenar JA. Determination of the fatty acid profile by ¹H-NMR spectroscopy. *European Journal of Lipid Science and Technology* 2004;106:88–96. <https://doi.org/10.1002/ejlt.200300880>.
- [23] Knothe G. Analysis of oxidized biodiesel by ¹H-NMR and effect of contact area with air. *European Journal of Lipid Science and Technology* 2006;108:493–500. <https://doi.org/10.1002/ejlt.200500345>.
- [24] Noh S, Yoon SH. Stereospecific Positional Distribution of Fatty Acids of *Camellia* (*Camellia japonica* L.) Seed Oil. *Journal of Food Science* 2012;77:C1055–7. <https://doi.org/10.1111/j.1750-3841.2012.02854.x>.
- [25] Alexandri E, Ahmed R, Siddiqui H, Choudhary MI, Tsiafoulis CG, Gerothanassis IP. High resolution NMR spectroscopy as a structural and analytical tool for unsaturated lipids in solution. *Molecules* 2017;22:1663. <https://doi.org/10.3390/molecules22101663>.
- [26] Chutia GP, Chutia S, Kalita P, Phukan K. *Xanthium strumarium* seed as a potential source of heterogeneous catalyst and non-edible oil for biodiesel production. *Biomass and Bioenergy* 2023;172:106773. <https://doi.org/10.1016/j.biombioe.2023.106773>.
- [27] AS S, CR Costa I. Investigation of Biodiesel Potential of Biomasses of Microalgae *Chlorella*, *Spirulina* and *Tetraselmis* by NMR and GC-MS Techniques. *Journal of Biotechnology & Biomaterials* 2016;06:2. <https://doi.org/10.4172/2155-952x.1000220>.
- [28] Sarpal AS, Teixeira CMLL, Silva PRM, Lima GM, Silva SR, Monteiro T V., et al. Determination of lipid content of oleaginous microalgal biomass by NMR spectroscopic and GC-MS techniques. *Analytical and Bioanalytical Chemistry* 2015;407:3799–816. <https://doi.org/10.1007/s00216-015-8613-6>.
- [29] Sarpal AS, Silva SR, Silva PRM, Monteiro T V., Itacolomy J, Cunha VS, et al. Direct Method for the Determination of the Iodine Value of Biodiesel by Quantitative Nuclear Magnetic Resonance (¹H NMR) Spectroscopy. *Energy and Fuels* 2015;29:7956–68. <https://doi.org/10.1021/acs.energyfuels.5b01462>.
- [30] S Sarpal A, R M. Silva P. Monitoring of Development of Certified Reference Material of Biodiesel by High Field NMR Spectroscopic Techniques. *Journal of Scientific and Industrial Metrology* 2016;01. <https://doi.org/10.21767/2472-1948.100013>.
- [31] Sharma YC, Singh B, Upadhyay SN. Advancements in development and characterization of biodiesel: A review. *Fuel* 2008;87:2355–73. <https://doi.org/10.1016/j.fuel.2008.01.014>.
- [32] Knothe G. Biodiesel and renewable diesel: A comparison. *Progress in Energy and Combustion Science* 2010;36:364–73. <https://doi.org/10.1016/j.pecs.2009.11.004>.
- [33] Moser BR. Biodiesel production, properties, and feedstocks. *In Vitro Cellular and Developmental Biology - Plant* 2009;45:229–66. <https://doi.org/10.1007/s11627-009-9204-z>.
- [34] Atabani AE, Silitonga AS, Badruddin IA, Mahlia TMI, Masjuki HH, Mekhilef S. A comprehensive review on biodiesel as an alternative energy resource and its characteristics. *Renewable and Sustainable Energy Reviews* 2012;16:2070–93. <https://doi.org/10.1016/j.rser.2012.01.003>.

Güvenlik Duvarlarındaki Ağ Trafik Log Kayıtlarının Analizinde Açıklanabilir Yapay Zekâ ve Derin Sinir Ağlarının Kullanımı: Karşılaştırmalı Bir Analiz

Anıl Utku*¹ 

*¹ Munzur Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği, TUNCELİ

(Alınış / Received: 10.10.2024, Kabul / Accepted: 19.11.2024, Online Yayınlanma / Published Online: 30.12.2024)

Anahtar Kelimeler

Açıklanabilir Yapay Zekâ,
Derin Sinir Ağları,
Makine Öğrenmesi,
Derin Öğrenme,
Ağ Trafik Analizi

Öz: İnternet kullanımında yaşanan hızlı büyüme, siber tehditlerin çeşitlenmesine ve karmaşıklığının artmasına neden olmuştur. Bu durum, özellikle ağ güvenliği konusunda daha gelişmiş ve dinamik çözümler geliştirilmesini zorunlu kılmaktadır. Geleneksel güvenlik yöntemleri, özellikle güvenlik duvarları, belirli kurallar çerçevesinde çalıştığından, yeni nesil siber tehditlere karşı yetersiz kalabilmektedir. Güvenlik duvarları, ağ trafiğini izleyerek potansiyel tehditleri tespit eden ve engelleyen önemli araçlar olarak uzun yıllardır kullanılmaktadır. Ancak, statik kurallara dayanan geleneksel güvenlik duvarları, karmaşık ve dinamik tehditleri algılamada yetersiz kalmakta ve yüksek oranda yanlış pozitif/negatif sonuçlar üretmektedir. Bu durum, daha esnek ve kendini sürekli olarak geliştirebilen yapay zekâ tabanlı güvenlik çözümlerine olan ihtiyacı artırmıştır. Bu çalışmada, açıklanabilir yapay zekâ ve DNN tabanlı bir derin öğrenme modeli kullanarak güvenlik duvarlarındaki ağ trafiği loglarının analiz edilmesi hedeflenmiştir. Geliştirilen DNN tabanlı model, RF, kNN, SVM, LR ve XGBoost gibi popüler makine öğrenmesi algoritmalarıyla karşılaştırılarak performansı değerlendirilmiştir. Deneysel sonuçlar, geliştirilen DNN tabanlı modelin %99,87 doğruluk oranıyla karşılaştırılan modellerden ve literatürdeki çalışmalardan daha başarılı olduğunu göstermiştir.

Use of Explainable Artificial Intelligence and Deep Neural Networks in Analyzing Network Traffic Logs in Firewalls: A Comparative Analysis

Keywords

Explainable Artificial
Intelligence,
Deep Neural Networks,
Machine Learning,
Network Traffic Analysis

Abstract: The rapid growth in internet usage has led to the diversification and complexity of cyber threats. This situation necessitates the development of more advanced and dynamic solutions, especially in network security. Since traditional security methods, especially firewalls, operate within the framework of certain rules, they may be insufficient against new generation cyber threats. Firewalls have been used for many years as important tools that detect and block potential threats by monitoring network traffic. However, traditional firewalls based on static rules are insufficient in detecting complex and dynamic threats and produce high rates of false positive/negative results. This situation has increased the need for more flexible and continuously improving artificial intelligence-based security solutions. In this study, it is aimed to analyze network traffic logs on firewalls using explainable artificial intelligence and a DNN-based deep learning model. The developed DNN-based model was compared with popular machine learning algorithms such as RF, kNN, SVM, LR and XGBoost and their performances were evaluated. Experimental results showed that the developed DNN-based model was more successful than the compared models and studies in the literature with 99.87% accuracy.

1. Giriş

Günümüzde artan bilgi miktarı ve bilgi teknolojileri kullanımının yaygınlaşmasıyla birlikte siber suçlarda artış görülmektedir. Bu durum, özellikle hassas verilerin korunması için daha güvenli ağ altyapılarına olan ihtiyacı artırmaktadır [1]. Güvenlik duvarları (firewall), iç ve dış ağlar arasında ağ geçidi görevi görerek kötü amaçlı yazılımların yayılmasını önlemeye, saldırı girişimlerini engellemeye ve diğer çevrimiçi tehditlere karşı korumaya yardımcı olur [3]. Güvenlik duvarları ağ trafiği verilerinin içeriğini, verilerin hangi güvenlik duvarı bağlantı noktalarını kullanmaya çalıştığı ve verilerin nereden kaynaklandığı açılarından analiz eder [3]. Farklı güvenlik duvarı türleri, potansiyel olarak kötü amaçlı kaynakları değerlendirmek için farklı yöntemler kullanır [4].

Güvenlik duvarları, bir ağın iç ve dış trafiği arasındaki veri paketlerini izler ve belirli bir dizi kural doğrultusunda bu trafiği engeller veya geçişine izin verir. Güvenlik duvarları, ağa izinsiz girişleri engelleyerek veri hırsızlığı veya yetkisiz işlemler gibi tehditlerin önüne geçer [5]. Gelen ve giden ağ trafiğini izleyerek anormal davranışları tespit eder [6]. Geleneksel güvenlik duvarları, statik kurallar seti kullanarak ağ trafiğini inceler. Ancak bu sistemler karmaşık saldırıları tespit etmede verimsiz kalmaları, dinamik tehditlere karşı esnek olmamaları ve yüksek yanlış pozitif/negatif oranı gibi sınırlılıklara sahiptirler [2].

Güvenlik duvarları, ağ tabanlı saldırılara karşı ilk savunma hattı olarak kullanılan önemli bir güvenlik aracıdır. Gelen ve giden ağ trafiğini belirli kurallara göre izleyen ve kontrol eden güvenlik duvarları, ağ güvenliğini sağlamak için gereklidir [7]. Ancak, siber tehditlerin giderek daha karmaşık hale gelmesi ve geleneksel saldırı tespit yöntemlerinin sınırlamaları, güvenlik duvarlarının da evrim geçirmesini zorunlu kılmıştır [8]. Ağ güvenliğini sağlamak için kullanılan en önemli araçlardan biri olan güvenlik duvarları, artan tehditlerle başa çıkmak için daha gelişmiş ve dinamik çözümler gerektirmektedir. Geleneksel güvenlik duvarları, sabit kurallar üzerinden çalışarak belirli tehditleri tespit etse de, modern siber saldırıların karmaşıklığı karşısında yetersiz kalabilmektedir [9]. Bu nedenle, yapay zekâ tabanlı güvenlik duvarları siber tehditlere karşı daha etkili bir savunma mekanizması olarak öne çıkmaktadır.

Yapay zekâ tabanlı güvenlik duvarları, ağ trafiğini daha akıllı ve dinamik bir şekilde izleyerek tehditlere daha etkili bir şekilde yanıt verebilir. Yapay zekâ tabanlı güvenlik duvarları dinamik öğrenme, anomali tespiti, büyük veri analizi ve sürekli öğrenme gibi avantajlara sahiptir [10]. Yapay zekâ tabanlı güvenlik duvarları ağ trafiği verilerini sürekli olarak analiz ederek yeni tehdit modellerini otomatik olarak öğrenebilir ve geleneksel güvenlik duvarlarında bir sınırlılık olarak nitelendirilebilecek dinamik tehdit algılama yeteneğine sahiptir. Ağ üzerindeki normal ve anormal davranışları öğrenebilir ve bu davranışların dışına çıkan hareketleri tespit ederek potansiyel saldırıları engelleyebilir. Büyük miktarda veri üzerinde eğitim yaparak ağ trafiğindeki tüm paketleri analiz edebilir ve gerçek zamanlı tehdit tespiti sağlayabilir.

Yapay zekâ yöntemlerinin sunduğu bu gibi avantajlar sebebiyle bu çalışmada Deep Neural Network (DNN) tabanlı bir model ile güvenlik duvarındaki ağ trafiği loglarının analiz edilmesi amaçlanmıştır. Geliştirilen model, güvenlik duvarları üzerinden geçen veri trafiğine dair kayıtları ve özellikleri içeren bir veri seti kullanılarak Rastgele Orman (Random Forest-RF), k-En Yakın Komşu (k Nearest Neighbour-kNN), Destek Vektör Makinesi (Support Vector Machine-SVM), Lojistik Regresyon (Logistic regression-LR) ve Ekstrem Gradyan Arttırma (eXtreme Gradient Boosting-XGBoost) gibi popüler makine öğrenmesi algoritmalarıyla uygulamalı olarak karşılaştırılmıştır.

Bu çalışmanın literatüre olan katkıları aşağıdaki gibi özetlenebilir:

- Geliştirilen DNN tabanlı bir model ile ağ üzerindeki trafik loglarının sınıflandırılması amaçlanmıştır.
- Geliştirilen model literatürdeki popüler makine öğrenmesi algoritmalarıyla kapsamlı olarak karşılaştırılmıştır.
- Açıklanabilir Yapay Zekâ (Explainable Artificial Intelligence -XAI) yöntemleri kullanılarak yapılan sınıflandırma işlemlerinin şeffaflığı sunulmuştur.
- Bu çalışma ile XAI konusunda Türkçe literatüre katkıda bulunmak hedeflenmiştir.
- Geliştirilen DNN tabanlı derin öğrenme modeli, %99,87 sınıflandırma doğruluğuyla karşılaştırılan modellerden ve literatürdeki çalışmalardan daha başarılı deneysel sonuçlara sahip olmuştur.

2. Literatürdeki Çalışmalar

Bu bölümde, literatürdeki aynı veri setini kullanan çalışmaların kullandıkları modeller ve elde edilen başarı oranları incelenmiştir.

Ertam ve Kaya, bu çalışmada kullanılan veri setini kullanarak SVM'in bir uygulamasını sunmuştur [11]. Çalışmada linear, polynomial, RBF ve sigmoid SVM çekirdekleri kullanılarak karşılaştırmalı bir analiz sunulmuştur. Deneyle,

Sigmoid çekirdek kullanan SVM'in %98,5 duyarlılık, %60,3 kesinlik ve %74,8 F-skoru değerine sahip olduğunu göstermiştir.

Al-Haijaa ve Ishtaiwi, bu çalışmada kullanılan veri setini kullanarak Sığ Sinir Ağı (Shallow Neural Network-SNN) Optimize Edilebilir Karar Ağacı (Optimizable Decision Tree-ODT) yöntemlerini kullanarak bir sınıflandırma sistemi geliştirmiştir [12]. Deneysel sonuçlar, SNN'in %98,5, ODT'nin ise %99,8 doğruluk değerine ulaştığını göstermiştir.

Al-Behadili, bu çalışmada kullanılan veri setini kullanarak Karar Ağacı (Decision Tree-DT), SVM, One Rule (OneR), Yapay Sinir Ağı (Artificial Neural Network-ANN), Çok Sınıflı Sınıflandırıcı, Particle Swarm Optimization (PSO) ve Zero Rule (ZeroR) modellerinin karşılaştırmalı bir analizini sunmuştur [13]. Deneysel sonuçlar, DT'nin %99,83 sınıflandırma doğruluğuyla karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Naryanto ve Delimayanti, bu çalışmada kullanılan veri setini kullanarak DT ve kNN modellerinin karşılaştırmalı bir analizini sunmuştur [14]. Rapidminer kullanılarak yapılan deneysel çalışmalar, DT'nin %94,84 sınıflandırma doğruluğuyla kNN'den daha başarılı olduğunu göstermiştir.

Aljabri ve ark., bu çalışmada kullanılan veri setini kullanarak NB, kNN, J48, RF ve ANN'in uygulamalı bir analizini sunmuştur [15]. Deneysel çalışmalar, RF'in %99,64 doğrulukla karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Rahman ve ark., bu çalışmada kullanılan veri setini kullanarak RF modelinin bir uygulamasını sunmuştur [16]. Deneysel sonuçlar, RF'in %99 doğruluk değerine ulaştığını göstermiştir.

Al-Tarawneh ve Bani-Salameh, bu çalışmada kullanılan veri setini kullanarak kNN, RF ve DNN modellerinin karşılaştırmalı bir analizini sunmuştur [17]. Deneysel sonuçlar, kNN'in %99,38 sınıflandırma doğruluğuyla karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Efeoğlu ve Tuna, bu çalışmada kullanılan veri setini kullanarak Decision Stump, Simple Cart ve NB Tree algoritmalarının karşılaştırmalı bir analizini sunmuştur [18]. Deneysel sonuçlar, Simple Cart ve NB Tree'nin %99,84, Decision Stump'in ise %79,68 sınıflandırma doğruluğuna sahip olduğunu göstermiştir.

Lee ve ark., bu çalışmada kullanılan veri setini kullanarak NB, kNN, OneR, J48, SVM, LR ve ANN'in uygulamalı bir analizini sunmuştur [19]. Deneysel sonuçlar, kNN ve ANN'in %97 doğrulukla karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Tablo 1'de literatürdeki çalışmaların kullandıkları modeller ve deneysel sonuçları sunulmuştur.

Tablo 1. Literatürdeki çalışmaların deneysel sonuçları ve kullandıkları modeller

| Referans | Kullanılan model(ler) | Başarı oranı |
|----------------|--|---|
| 11 | linear, polynomial, RBF ve sigmoid SVM | %98,5 duyarlılık, %60,3 kesinlik ve %74,8 F-skoru (Sigmoid SVM) |
| 12 | SSN ve ODT | %98,5 doğruluk (SNN), %99,8 doğruluk (ODT) |
| 13 | DT, SVM, OneR, ANN, Çok Sınıflı Sınıflandırıcı, PSO ve ZeroR | %99,83 (DT) |
| 14 | DT ve kNN | %94,84 doğruluk (DT) |
| 15 | NB, kNN, J48, RF ve ANN | %99,64 doğruluk (RF) |
| 16 | RF | %99 doğruluk (RF) |
| 17 | kNN, RF ve DNN | %99,38 doğruluk (kNN) |
| 18 | Decision Stump, Simple Cart ve NB Tree | %99,84 doğruluk (Simple Cart ve NB Tree) |
| 19 | NB, kNN, OneR, J48, SVM, LR ve ANN | %97 doğruluk (kNN ve ANN) |
| Mevcut çalışma | RF, kNN, SVM, LR, XGBoost ve DNN | %99,87 doğruluk, %99,86 kesinlik, %99,89 duyarlılık ve %99,87 F-skoru |

Tablo 1'de görüldüğü gibi geliştirilen DNN tabanlı derin öğrenme modeli, %99,87 doğruluk, %99,86 kesinlik, %99,89 duyarlılık ve %99,87 F-skoru değerleriyle karşılaştırılan literatürdeki çalışmalardan daha başarılı olmuştur. DNN'in başarılı olmasının sebepleri arasında geliştirilen modelin mimari yapısı ve yapılan hiper-parametre optimizasyonu gösterilebilir.

3. Açıklanabilir Yapay Zekâ

XAI, karmaşık yapay zekâ tabanlı modellerin çıktılarını daha şeffaf ve anlaşılır hale getirerek modelin çıktılarında güven duyulmasını sağlayan yöntemler bütünüdür [20]. XAI model güvenliğini sağlamada önemli bir rol oynar. Özellikle karmaşık yapay zekâ sistemlerinin iç süreçlerini anlamak ve güvenilir kararlar almak için önemli bir araçtır. XAI'nin önemi, özellikle yüksek doğruluk oranlarına sahip olsa bile kara kutu olarak bilinen modellerin nasıl çalıştığını anlamının zor olduğu senaryolarda artmaktadır [21]. Şeffaflık ve güven, hesap verebilirlik, etik ve yasal yükümlülükler, önyargı, sürekli iyileştirme, sağlamlık, gizlilik ve hata ayıklama XAI'nin bileşenleri olarak değerlendirilebilir [22].

Yapay zekâ modelleri karar verme sürecinde genellikle insanlar açısından anlaşılması karmaşık algoritmalar ve büyük veri kullanmaktadır. Şeffaflık ve güven, XAI ile model tarafından kararların nasıl alındığının sunulması ile şeffaflığının bu sayede son kullanıcıların güveninin artırılmasını ifade etmektedir [23]. Hesap verebilirlik, sistemlerinin düzenleyici gereklilikleri karşılamak için olmazsa olmaz olan kararları için açık ve anlaşılır nedenler sunmasını sağlar. Örneğin, finans sektöründe düzenlemeler genellikle kredi onayları veya kredi puanlama gibi kararların şeffaf olmasını gerektirir [24]. XAI, belirli bir kararın neden alındığına dair ayrıntılı iç görüler sunarak sürecin şeffaf olmasını ve düzenleyiciler tarafından denetlenebilmesini sağlar. Etik ve yasal yükümlülükler, özellikle sağlık, finans ve hukuk gibi kritik alanlarda ön plana çıkmaktadır. Bu alanlarda XAI, sistemlerin neden belirli bir karara vardığını anlamayı sağlar ve etik sorumluluklar için destek sunar [25]. Önyargı, yapay zekâ tabanlı sistemlerin ırk, cinsiyet veya diğer korunan özelliklere dayalı olarak bireylere haksız muameleye yol açabilecek önyargılardan arınmış olmasını ifade etmektedir [26]. XAI, karar alma sürecini şeffaf hale getirerek önyargıları belirlemeye ve azaltmaya yardımcı olur. Kuruluşlar, bu sayede ayrımcılık karşıtı yasalara ve düzenlemelere uyduklarını gösterebilirler. Sürekli iyileştirme, geliştiricilerin ve veri bilimcilerin, yapay zekâ modellerinin neden hatalı çıktılar verdiğini XAI yöntemleriyle anlayarak modeli geliştirmelerini ifade etmektedir [27]. Hangi özelliklerin ve veri noktalarının modele nasıl etki ettiğini bilmek, daha doğru ve etkin modeller geliştirmeye yardımcı olur. Sağlamlık, model hiper-parametrelerindeki değişimlere ve beklenmeyen senaryolara karşı tutarlı olmayı ifade etmektedir [28]. Gizlilik, hassas kullanıcı bilgilerinin korunmasını garanti altına almayı ifade etmektedir. Hata ayıklama ise XAI'nin, bir sorunun belirli bölümlerini ve sistemin mantığındaki veya eğitim verilerindeki hataları belirlemeye yardımcı olmasını ifade etmektedir [29].

Yapay zekâ modellerin verdiği kararlar neticesinde kara kutu paradoksu ön plana çıkmaktadır. Yapay zekâ sistemlerinin sonuçlara nasıl ulaştığı konusunda daha fazla netliğe ihtiyaç duyulması sebebiyle, bu süreçler için yorumlayıcı yöntemler geliştirilmiştir [30]. Bu yöntemler, yapay zekânın belirsiz işleyişi ile insanın kavrama ve güven ihtiyacı arasında ilişki kurmayı amaçlamaktadır. Özellik önem analizi, her bir girdi değişkeninin modelin tahminleri üzerindeki etkisini inceleyen bir yöntemdir. Hangi özelliklerin algoritmanın kararlarını en çok etkilediğini vurgulayarak, insanların akıl yürütme örüntüleri hakkında net bir çerçeve oluşturmayı amaçlamaktadır [31].

SHapley Additive exPlanations (SHAP) gibi teknikler, yapay zekânın karmaşıklığını daha anlaşılabilir bir yapıya dönüştürmektedir. Modelin tahminlerini bireysel düzeyde parçalara ayırarak belirli durumlarda kullanılan mantığın anlık görüntüsünü sunmaktadır. SHAP, her bir özelliğin tahmine katkısını hesaplayarak bir örneğin tahminini açıklamayı amaçlamaktadır [32]. SHAP, modelden bağımsız bir yöntemdir ve yalnızca bireysel örnekler için açıklamalar sağladığı anlamına gelen yerel bir yöntemdir. Bir veri örneğinin özellik değerleri, bir koalisyondaki oyuncular gibi davranır [33]. Shapley değeri, tüm olası koalisyonlar arasında bir özellik değerinin ortalama marjinal katkısıdır. SHAP, bir modelin girdilerinin her birinin çıktıya katkısını hesaplar. Bu katkı, her bir girdinin karar üzerindeki etkisini gösterir ve modellerin daha anlaşılır hale gelmesini sağlar [34].


4. Materyal ve Metot

Bu çalışmada, ağ trafiği analizi ve güvenlik duvarı etkinliğinin değerlendirilmesi amacıyla, XAI ve DNN yöntemleri kullanılmıştır. İlk olarak, Kaggle üzerinden genel erişime açık olarak sunulan bir ağ trafiği veri seti analiz edilmiştir. Kullanılan veri seti, farklı protokollere ve trafiğin sınıflandırılmasına yönelik çok sayıda özelliği içermektedir. DNN, ağ trafiğindeki zararlı aktivitelerin tespitinde kullanılmış, model performansını artırmak için hiper-parametre optimizasyonu gerçekleştirilmiştir. Ayrıca, XAI teknikleriyle modellerin karar süreçleri analiz edilerek, güvenlik duvarlarının ağ trafiği üzerindeki etkinliğini şeffaf bir şekilde ortaya koymak amaçlanmıştır. Bu bölümde kullanılan veri seti ve karşılaştırılan modellere ilişkin detaylar sunulmaktadır.

4.1. Veriseti

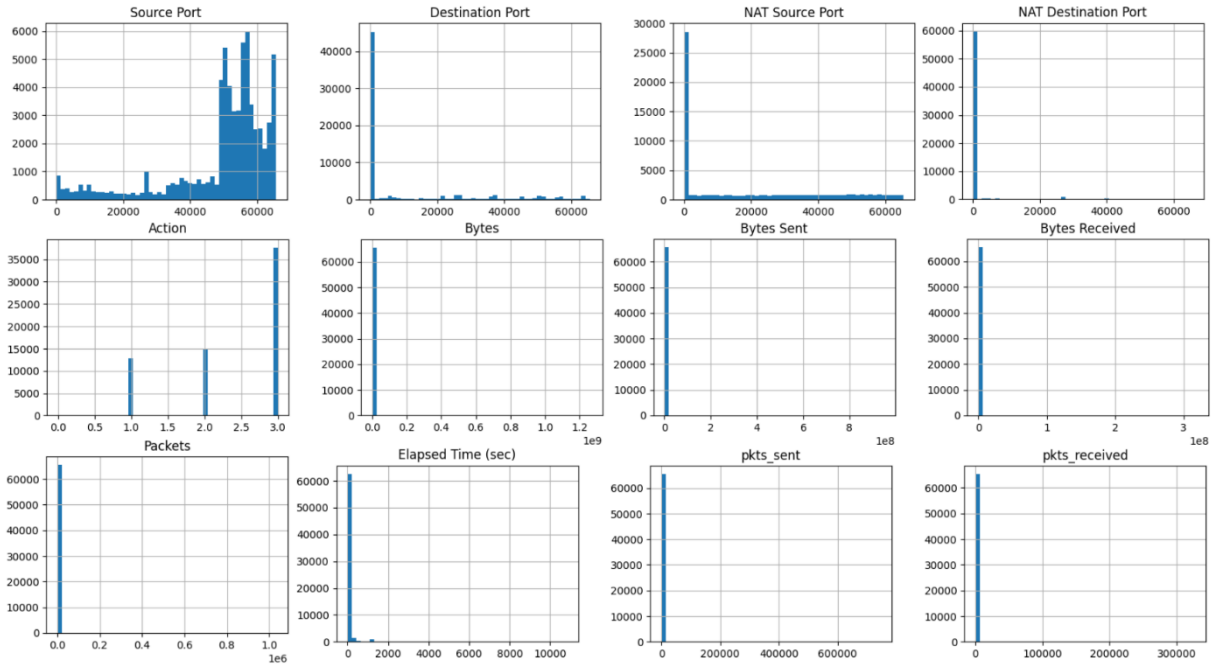
Bu çalışmada, ağ üzerindeki trafiği izleyen bir güvenlik duvarının (firewall) log verileri kullanılmıştır [35]. Güvenlik duvarı, genellikle bir ağın giriş ve çıkışında bulunan, zararlı veya istenmeyen trafiklerin engellenmesini sağlayan bir güvenlik sistemi olduğundan, bu veriler siber güvenlik ve ağ güvenliği alanında kullanılabilir potansiyel verilerdir. Veri seti, güvenlik duvarları üzerinden geçen veri trafiğine dair kayıtları ve özellikleri içermektedir. Özellikle siber saldırı girişimleri veya şüpheli faaliyetler gibi anormal davranışları tespit etmek amacıyla önemlidir.

Kullanılan veri seti toplamda 12 öznitelik ve izin ver (allow), engelle (deny), reddet (drop) ve sıfırla (reset-both) olmak üzere 4 sınıf olmak üzere 65532 satır veriden oluşmaktadır. İzin ver etiketi, güvenlik duvarının gelen veya giden trafiğe izin verdiğini, veri paketinin güvenlik duvarından geçip hedefe ulaştığını ifade etmektedir. Engelle etiketi, güvenlik duvarının kaynağa ya da hedefe herhangi bir bildirimde bulunmadan veri paketlerini engellemesini, paketleri yok saymasını ifade eder. Reddet etiketi, güvenlik duvarının belirli bir veri paketinin hedefe ulaşmasını aktif olarak engellemesini ifade eder. Reddet işlemi, engelle işlemine benzerdir ancak kaynağa bağlantının reddedildiğine yönelik bir bildirim gönderilmektedir ve yetkisiz veya zararlı trafiği durdurmak için kullanılır. Sıfırla etiketi ise güvenlik duvarının bağlantının sıfırlandığına ya da sonlandırıldığına yönelik kaynağa ve hedefe bir bildirim gönderilmesini ifade etmektedir. Şekil 1’de veri setinde bulunan sınıflar ve dağılımları görülmektedir.




Şekil 1. Veri setinde bulunan sınıfların dağılımı

Şekil 1’de görüldüğü gibi veri setinde izin ver (allow) sınıfına ait 37640 örnek, engelle (deny) sınıfına ait 14987 örnek, reddet (drop) sınıfına ait 12851 örnek ve sıfırla (reset-both) sınıfına ait 54 örnek bulunmaktadır. Veri setinde bulunan öznitelikler hedef portu (destination port), kaynak portu (source port), NAT hedef portu (NAT destination port), NAT kaynak portu (NAT source port), aksiyon (action), gönderilen baytlar (bytes sent), baytlar (bytes), alınan baytlar (bytes received), geçen süre (elapsed time), paketler (packets), alınan paket (pkts_received) ve gönderilen pakettir (pkts_sent). Şekil 2’de veri setinde bulunan özniteliklerin histogram grafikleri görülmektedir.




Şekil 2. Veri setinde bulunan özneliklerin histogram grafikleri

Kaynak portu, veriyi gönderen kaynak cihazın kullandığı port numarasını ifade eder. Hedef portu, verinin gönderilmiş olduğu hedef port numarasını göstermektedir. NAT kaynak portu, Network Address Translation (NAT) sırasında kaynak portun değiştirilmiş halini yani verinin dış ağa çıktığında aldığı port numarasını ifade eder. NAT hedef portu, NAT sonrası hedef portun değiştirilmiş halini yani dış ağdaki hedef portun yerel ağa döndüğünde aldığı numarayı ifade eder. Aksiyon, güvenlik duvarının veri paketine karşı aldığı izin verildi veya engellendi şeklindeki aksiyonu ifade eder. Baytlar, bağlantı sırasında gönderilen ve alınan toplam veri miktarını byte cinsinden ifade eder. Gönderilen baytlar, kaynak cihazdan hedef cihaza gönderilen veri miktarını byte cinsinden ifade eder. Alınan baytlar, hedef cihazdan kaynak cihaza alınan veri miktarını byte cinsinden ifade eder. Paketler, toplam paket sayısını göstermektedir. Geçen süre, bağlantının başlangıcından bitişine kadar geçen süreyi saniye cinsinden ifade eder. Gönderilen paket, kaynak cihaz tarafından gönderilen toplam paket sayısını, alınan paket ise hedef cihaz tarafından alınan toplam paket sayısını ifade eder. Şekil 3'te veri setinde bulunan öznelikler arasındaki ilişkiler görülmektedir.



Şekil 3. Veri setinde bulunan öznelikler arasındaki ilişkiler

Şekil 3'te görüldüğü gibi Bytes ile Bytes Sent, Bytes Received, Packets, ve Elapsed Time öznelikleri arasında güçlü pozitif korelasyonlar olduğu, daha fazla veri gönderilip alındığında, daha fazla paket ve zaman harcadığı görülmektedir. Packets ile pkts_sent ve pkts_received arasında olan güçlü pozitif ilişki, paket sayısının artmasıyla gönderilen ve alınan paketlerin de arttığını göstermektedir. Veri setinde bulunan özelliklerin önem değerleri Şekil 4'te görülmektedir.



Şekil 4. Veri setinde bulunan öznelıkların önem değerleri

Şekil 4'te her bir özneliğin modelin tahmin performansına olan katkısı görülmektedir. Packets özneliği, en yüksek önem değerine sahip özneliktir ve modelin karar verme sürecinde en etkili özneliktir. NAT destination port ve NAT source port, NAT üzerinden yönlendirilen bağlantılarda hedef ve kaynak portlar modelin doğru kararlar vermesi için önemlidir. Gönderilen ve alınan veri miktarlarını ifade eden bytes sent ve bytes received öznelikleri, paket sayıları kadar yüksek öneme sahip değildir. Destination port, source port ve action öznelikleri, göreceli olarak daha az öneme sahiptir. Elapsed time özneliği ise en az öneme sahip özneliklerden biri olarak görülmektedir.

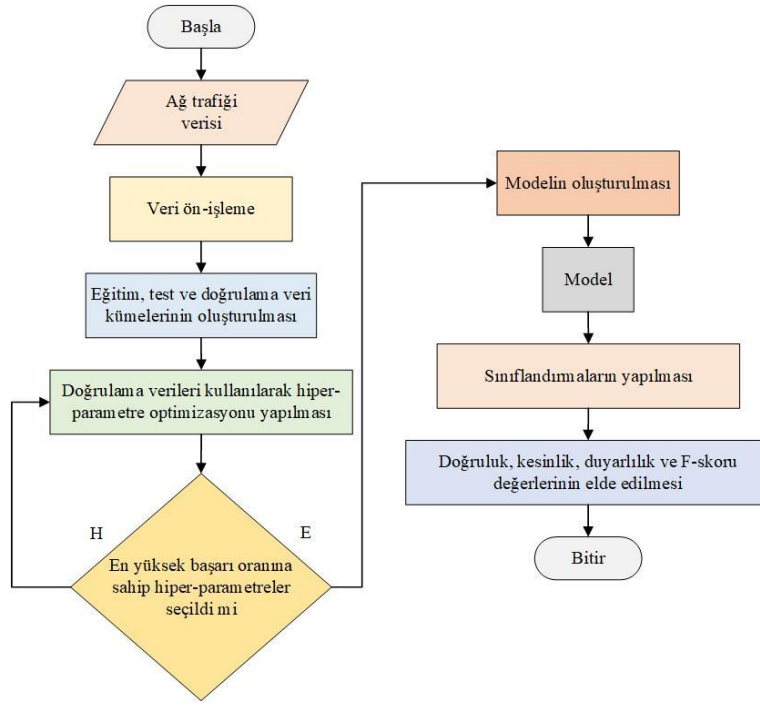
Veri ön-işleme aşamasında kategorik-nümerik veri dönüşümü yapılmıştır. Allow sınıf etiketi 3, deny sınıf etiketi 2, drop sınıf etiketi 1 ve reset-both sınıf etiketi ise 0'a dönüştürülmüştür. Yapılan deneysel çalışmalar neticesinde elde edilen başarı oranları karşılaştırılarak verisetinin %80'i eğitim, %20'si ise test için ayrılmıştır. Model hiper-parametrelerinin belirlenmesi amacıyla eğitim verisetinin %10'u doğrulama için kullanılmıştır. Uygulanan her bir modelin en başarılı sonuçlara sahip olabilmesi amacıyla ızgara arama (grid search) kullanılarak hiper-parametre analizleri yapılmıştır. ızgara arama, makine öğrenmesi ve derin öğrenme modellerinde en iyi hiperparametreleri belirlemek için kullanılan bir optimizasyon yöntemidir. Grid Search, belirli hiperparametrelerin her bir olası kombinasyonu için modelin performansını değerlendirmektedir. İlk adımda, hangi hiperparametrelerin ayarlanacağını ve bu parametreler için hangi değer aralıklarının denenmesi gerektiğini belirlemektedir. Parametrelerin her olası kombinasyonunu bir ızgara şeklinde oluşturur. Her bir kombinasyon için model eğitilir ve belirlenen bir değerlendirme metriğine göre modelin performansını ölçer. Modeller uygulanırken 5-katlı çapraz doğrulama tekniği kullanılmıştır. Çapraz doğrulama, makine öğrenmesi modellerinin doğruluğunu ve genelleme yeteneğini daha iyi değerlendirmek için kullanılan bir tekniktir. Çapraz doğrulama, veri setini birden fazla alt küme (katman) olarak böler ve her bir alt kümeyi modelin doğruluğunu değerlendirmek için kullanır. Bu sayede modelin farklı veri bölümlerindeki performansı ölçülür ve overfitting (aşırı uyum) gibi sorunlar tespit edilebilir. Çapraz doğrulama, modelin eğitim ve test verisi üzerindeki performansını daha iyi değerlendirmek ve modelin yalnızca belirli bir veri kümesine değil, genel veri yapısına ne kadar iyi uyduğunu görmek için kullanılır.

Tablo 2'de modellerin hiper-parametre optimizasyonu sonucunda elde edilen parametreleri görülmektedir.

Tablo 2. Modeller ve sahip oldukları hiper-parametreler

| Model | Hiper-parametreler |
|---------|---|
| kNN | n_neighbors: 5, weights: distance, algorithm: auto, p = 2 |
| LR | penalty: l2, C: 1.0, solver: lbfgs |
| RF | n_estimators: 100, max_depth: 20, min_samples_split: 2, min_samples_leaf: 1, max_features: sqrt |
| SVM | C: 1.0, kernel: rbf, gamma: scale |
| XGBoost | n_estimators: 100, max_depth: 6, learning_rate: 0.1, subsample: 0.8, colsample_bytree: 0.8, gamma: 0 |
| DNN | Gizli katman sayısı: 4, öğrenme oranı: 0.01, epoch: 50, batch boyutu: 32, optimizer: Adam, dropout oranı: 0.2 |

Geliştirilen sistemin akış diyagramı Şekil 5'te görülmektedir.



Şekil 5. Geliştirilen sistemin akış diyagramı

Şekil 5'te görüldüğü gibi geliştirilen sistemde öncelikle ağ trafiği verileri üzerinde veri ön-işleme yapılmaktadır. Veri ön-işlemenin ardından eğitim, test ve doğrulama veri kümeleri oluşturulmaktadır ve doğrulama verileri üzerinde modellerin hiper-parametreleri optimize edilmektedir. Izgara arama yöntemi kullanılarak belirlenen en yüksek başarı oranına sahip hiper-parametreler ile modeller oluşturulmaktadır. Model sınıflandırma işlemleri neticesinde doğruluk, kesinlik, duyarlılık ve F-skoru metriklerine göre deneysel sonuçlar elde edilmektedir.

4.2. Sınıflandırma Modelleri

RF, birden fazla karar ağacını (decision tree) kullanarak çalışır ve sonuçları birleştirir. Ana prensibi, veriyi küçük parçalara bölerek farklı ağaçlar oluşturmak ve her ağacın ayrı bir tahmin yapmasına olanak sağlamaktır [36]. RF, birden fazla karar ağacının sonuçlarını birleştirerek daha doğru ve dengeli tahminler elde eder. Sınıflandırma problemlerinde, her bir ağacın yaptığı tahminlerin çoğunluğu alınarak sonuç belirlenir [37]. Verilerden rastgele örnekler seçilerek her ağaç eğitilir. Bu sayede, aşırı öğrenme riskini azaltır. Her karar ağacı için özelliklerin sadece bir alt kümesi kullanılır. Bu sayede karar ağaçlarının birbirinden farklı olmasını ve çeşitli tahminler üretmesini sağlar [38].

kNN, bir veri noktasının benzerliğini, eğitim veri kümesiyle karşılaştırmak için yakınlığı kullanan bir makine öğrenme algoritmasıdır. kNN, benzer noktaların birbirine yakın bulunabileceği varsayımıyla çalışır [39]. kNN, komşuları içindeki çoğunluk kümesine yeni bir veri noktası atamaktadır. kNN, veri dağılımı hakkında herhangi bir varsayım gerektirmez. Belirli bir veri kümesindeki veri noktalarının benzerliğine dayalı tahminler yapan parametrik olmayan bir yöntemdir [40]. kNN, diğer algoritmalara kıyasla aykırı değerlere karşı daha az hassastır. kNN, öklid mesafesi gibi bir mesafe metriğine dayanarak belirli bir veri noktasına en yakın k komşuyu bularak çalışır [41].

SVM'nin temel amacı, iki farklı sınıfı mümkün olan en geniş sınırla (maksimum marjin) ayıran bir hiper düzlem (decision boundary) bulmaktır [42]. SVM, verileri iki sınıfa ayırmak için bir hiper düzlem tanımlar. İki boyutlu bir problemde bu hiper düzlem bir doğru olabilir, ancak daha yüksek boyutlarda düzlem ya da daha karmaşık bir yüzey olabilir [43]. SVM, iki sınıf arasında mümkün olan en geniş mesafeyi (marjin) sağlayan bir hiper düzlem seçmeye çalışır. Sınıflar arasındaki en yakın veri noktalarıyla (destek vektörleri) hiper düzlem arasındaki mesafe en büyük olacak şekilde bir ayırım yapılır. Sınıfları ayıran hiper düzleme en yakın veri noktalarına destek vektörleri adı verilir. Bu noktalar, hiper düzlemi belirlemede kritik bir rol oynar [44].

LR, bir veri noktasının iki farklı sınıftan birine ait olma olasılığını tahmin etmek için kullanılır. Temel amacı, bir olayın olasılığını hesaplayarak sınıflandırma yapmaktır [45]. LR, doğrusal regresyonda olduğu gibi her bir girdinin (özelliğin) ağırlıklandırıldığı doğrusal bir fonksiyonla başlar. doğrusal modelin çıktısını sigmoid fonksiyonu adı verilen bir fonksiyona uygular. Sigmoid fonksiyonu, tahmin edilen değeri 0 ile 1 arasında sıkıştırır [46]. Çok sınıflı LR, her bir sınıf için bir olasılık tahmin eder ve bu olasılıkların toplamı 1 olacak şekilde normalizasyon sağlar. Her sınıf için bir olasılık hesaplanır ve Softmax fonksiyonu kullanılarak olasılıkların toplamının 1 olmasını sağlayacak şekilde normalize edilir. Bu, hangi sınıfa ait olduğuna karar verirken her sınıfa bir olasılık atanmasını sağlar [47].

XGBoost, gradyan artırma (gradient boosting) metoduna dayalı bir yöntemdir. Gradyan artırma, bir dizi zayıf tahminleyici karar ağacını ardışık olarak eğiterek tahmin hatalarını minimize etmeyi hedefler [48]. Her yeni ağaç, önceki modelin hatalarını öğrenir ve böylece genel tahmin performansını iyileştirir. Model, hatalı tahminlerin daha fazla dikkate alındığı ve hataların minimize edilmeye çalışıldığı iteratif bir süreç kullanır. Hataları minimize etmek için model, gradyan tabanlı optimizasyon tekniklerini kullanarak ağırlıklarını günceller [49]. XGBoost, optimizasyon amacıyla bir kayıp fonksiyonu kullanır. XGBoost, modelin aşırı öğrenme riskini azaltmak için L1 (Lasso) ve L2 (Ridge) regularizasyon yöntemlerini kullanır. L1 regularizasyonu, özelliklerin bazılarını sıfıra düşürerek modelin basitleştirilmesine yardımcı olur. L2 regularizasyonu, ağırlıkları küçültmeye yardımcı olur ve böylece modelin daha iyi genellemesini sağlar [50].

4.3. Performans Değerlendirme Metrikleri

Sınıflandırma modellerinin değerlendirilmesinde temel olarak karışıklık matrisi kullanılarak elde edilen doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F-skoru (F-score) metrikleri kullanılmaktadır. Şekil 6'da çok sınıflı sınıflandırma problemleri için karışıklık matrisi görülmektedir.

| | | Tahmin edilen değerler | | | |
|-----------------|------------|------------------------|------|-------|------------|
| | | Deny | Drop | Allow | Reset-both |
| Gerçek değerler | Deny | DN | YP | DN | DN |
| | Drop | YN | DP | YN | YN |
| | Allow | DN | YP | DN | DN |
| | Reset-both | DN | YP | DN | DN |

Şekil 6. Çok sınıflı sınıflandırma problemleri için karışıklık matrisi

Şekil 6'da, örnek olarak drop sınıfı için Doğru pozitif (DP), Yanlış Negatif (YN), Doğru Negatif (DN) ve Yanlış Pozitif (YP) değerlerinin nasıl seçileceği renkli biçimde sunulmuştur. Drop olduğu tahmin edilen ancak aslında başka bir sınıfa ait olan örnekler (YP) turuncu renkte, gerçekte drop sınıfına ait olması gereken ancak farklı bir sınıfa ait olduğu tahmin edilen örnekler (YN) ise sarı renkte gösterilmiştir. Drop sınıfı için tahmin edilen ve gerçek değerlerin kesiştiği hücre (DP) yeşil renkte gösterilmiştir. Doğru şekilde tahmin edilen farklı sınıflara ait örnekler (DN) mavi renkte gösterilmiştir.

Doğruluk, Eş. 1'de görüldüğü gibi, model tarafından doğru şekilde sınıflandırılan örnek sayısının toplam örnek sayısına bölünmesiyle elde edilir [51].

$$\text{Doğruluk} = \frac{DP+DN}{DP+YN+DN+YP} \quad (1)$$

Kesinlik, Eş. 2'de görüldüğü gibi, drop olarak sınıflandırılan örneklerden kaçının aslında drop sınıfına ait olduğunu gösterir [52].

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (2)$$

Duyarlılık, Eş. 3'te görüldüğü gibi drop olarak sınıflandırılması gereken örneklerden kaçının doğru şekilde sınıflandırıldığını gösterir [53].

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3)$$


F-skoru, kesinlik ve duyarlılık değerlerinin etkisini korumak için bu değerlerin harmonik ortalaması alınarak Eş. 4'te görüldüğü gibi hesaplanmaktadır [54].

$$F\text{-skoru} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

4.4. Geliştirilen DNN Modeli

Bu çalışmada, popüler makine öğrenme algoritmaları ile geliştirilen DNN tabanlı modelin güvenlik duvarlarındaki ağ trafiğinin analizi problemine yönelik karşılaştırmalı bir analizi sunulmuştur. DNN, temelde, insan beyindeki nöronların çalışma prensibini taklit eden bir yapıya sahiptir. DNN'de bulunan gizli katmanlar, dış dünyaya doğrudan bağlı olmayan, hesaplamalar yapan ve giriş düğümlerinden çıkış düğümlerine bilgi ileten yapılardır. DNN, birden fazla gizli katman içerebilir. Her gizli katman, önceki katmandan aldığı verileri işler ve daha karmaşık özellikler öğrenir. Çıktı katmanı ise bilgi işleme ve bilgiyi ağdan dış dünyaya aktarmaktan sorumludur. Çıktı katmanı, modelin ne tür sonuçlar üreteceğini belirler. Geliştirilen DNN modeli, eğitim veri setindeki ağ trafiği verilerini girdi olarak alır ve test veri setindeki ağ trafiğine yönelik verilecek kararı tahmin eder. Her bir nöron, kendisine gelen girişleri belirli bir ağırlık ile çarpar ve ardından bir aktivasyon fonksiyonu uygular. Aktivasyon fonksiyonları, gizli katmanlardaki nöronların çıkışlarını belirleyen fonksiyonlardır. Geriye yayılım ile hesaplanan hata, modelin ağırlıklarının güncellenmesi için geri yayılır. Geri yayılım, DNN'nin öğrenme sürecinde en kritik adımdır.

Geliştirilen DNN modelinin mimarisi Şekil 7'de görülmektedir.




Şekil 7. Geliştirilen DNN modelinin mimarisi

Şekil 7'de görüldüğü gibi DNN modeli girdi ve çıktı katmanları ile 3 gizli katmandan oluşmaktadır. Model, ağ trafiği verilerini alarak bu verileri sınıflandırmayı amaçlamaktadır. Giriş katmanı modelin ağ trafiği verilerini aldığı ilk katmandır. Her düğüm, ağ trafiği verilerinin bir özelliğini veya değişkenini temsil eder. Ağ trafiği verileri, modelin işleyebileceği sayısal formata dönüştürülerek bu katmanda işlenmeye başlar. Gizli katmanlar, modelin ağ trafiği verilerinden özellikleri öğrenmesini sağlar. Her gizli katman, önceki katmandan aldığı bilgileri işleyerek bir sonraki katmana iletir. Her düğüm, önceden tanımlanmış bir aktivasyon fonksiyonunu kullanarak verileri işler ve ileri doğru yayılım yapar. Gizli katmanlar 64 nörondan oluşmaktadır ve Rectified Linear Unit (ReLU) aktivasyon fonksiyonundan oluşmaktadır. Çıktı katmanı, modelin sınıflandırma sonuçlarını verir. Her düğüm, modelin sınıflandıracığı bir sınıfı temsil eder. Çıktı katmanı ise allow, deny, drop ve reset-both sınıflarını ifade etmek üzere 4 nörondan oluşmaktadır ve çoklu sınıflandırma için softmax aktivasyon fonksiyonunu kullanmaktadır. Modelin öğrenme oranı 0.01, epoch sayısı 50, batch boyutu 32, optimizasyon algoritması Adam ve dropout oranı 0.2'dir. Her bir düğüm, kendisinden sonraki tüm düğümlerle bağlantılıdır. Bu, tam bağlantılı (fully connected) bir sinir ağı yapısını ifade eder. Giriş katmanından gelen veriler, gizli katmanlarda işlenir ve ardından çıktı katmanında nihai sınıflandırma yapılır.

5. Deneysel Sonuçlar

Bu çalışmada geliştirilen DNN tabanlı derin öğrenme modeli, RF, kNN, SVM, LR ve XGBoost ile uygulamalı olarak karşılaştırılmıştır. Her bir model ve sınıf için doğruluk, kesinlik, duyarlılık ve F-skoru metriklerine göre deneysel sonuçlar elde edilmiştir. Ayrıca ağırlıklı ortalama ve makro ortalamalar alınarak sınıf tahminlerinin etkileri ölçülmüştür. Test veri kümesinde deny sınıfına ait 2626 örnek, drop sınıfına ait 7457 örnek, allow sınıfına ait 3011 örnek ve reset-both sınıfına ait 13 örnek bulunmaktadır.

Şekil 8'de RF için karışıklık matrisi görülmektedir.



Şekil 8. RF için karışıklık matrisi


Şekil 8’de görüldüğü gibi RF deny sınıfına ait 2626 örnekten 2585’ini, drop sınıfına ait 7457 örnekten 7433’ünü, allow sınıfına ait 3011 örnekten 2974’ünü ve reset-both sınıfına ait 13 örnekten 5’ini doğru bir şekilde sınıflandırmıştır. RF, 13107 örneğin 12997’sini doğru, 110’unu ise yanlış sınıflandırarak %99,16 doğruluğa ulaşmıştır.

Tablo 3’te RF için deneysel sonuçlar görülmektedir.

Tablo 3. RF için deneysel sonuçlar

| Sınıf | Doğruluk | Kesinlik | Duyarlılık | F-skoru |
|--------------------|----------|----------|------------|---------|
| Deny | | %99,57 | %98,43 | 99,00% |
| Drop | | %99,71 | %99,67 | 99,69% |
| Allow | | %98,73 | %98,77 | 98,75% |
| Reset-both | %99,16 | %11,11 | %38,46 | 17,24% |
| Makro ortalama | | %77,28 | 83,83% | 78,67% |
| Ağırlıklı ortalama | | %99,36 | %99,15 | %99,25 |

Şekil 9’da kNN için karışıklık matrisi görülmektedir.



Şekil 9. kNN için karışıklık matrisi


Şekil 9’da görüldüğü gibi kNN deny sınıfına ait 2626 örnekten 2578’ini, drop sınıfına ait 7457 örnekten 7432’sini, allow sınıfına ait 3011 örnekten 2967’sini ve reset-both sınıfına ait 13 örnekten 4’ünü doğru bir şekilde sınıflandırmıştır. kNN, 13107 örneğin 12981’ini doğru, 126’sını ise yanlış sınıflandırarak %99,03 doğruluğa ulaşmıştır.

Tablo 4'te kNN için deneysel sonuçlar görülmektedir.

Tablo 4. kNN için deneysel sonuçlar

| Sınıf | Doğruluk | Kesinlik | Duyarlılık | F-skoru |
|--------------------|----------|----------|------------|---------|
| Deny | | %99,88 | %98,17 | %99,02 |
| Drop | | %99,59 | %99,65 | %99,62 |
| Allow | %99,03 | %98,53 | %98,53 | %98,53 |
| Reset-both | | %8,00 | %30,76 | %12,70 |
| Makro ortalama | | %76,50 | %81,78 | %77,47 |
| Ağırlıklı ortalama | | %99,31 | %99,02 | %99,16 |

Şekil 10'da SVM için karışıklık matrisi görülmektedir.



Şekil 10. SVM için karışıklık matrisi


Şekil 10'da görüldüğü gibi SVM deny sınıfına ait 2626 örnekten 2587'sini, drop sınıfına ait 7457 örnekten 7436'sını, allow sınıfına ait 3011 örnekten 2979'unu ve reset-both sınıfına ait 13 örnekten 6'sını doğru bir şekilde sınıflandırmıştır. SVM, 13107 örneğin 13008'ini doğru, 99'unu ise yanlış sınıflandırarak %99,24 doğruluğa ulaşmıştır.

Tablo 5'te SVM için deneysel sonuçlar görülmektedir.

Tablo 5. SVM için deneysel sonuçlar

| Sınıf | Doğruluk | Kesinlik | Duyarlılık | F-skoru |
|--------------------|----------|----------|------------|---------|
| Deny | | %99,61 | %98,51 | %99,06 |
| Drop | | %99,75 | %99,71 | %99,73 |
| Allow | %99,24 | %98,90 | %98,93 | %98,91 |
| Reset-both | | %13,63 | %46,15 | %21,04 |
| Makro ortalama | | %77,97 | %85,83 | %79,69 |
| Ağırlıklı ortalama | | %99,44 | %99,23 | %99,32 |

Şekil 11'de LR için karışıklık matrisi görülmektedir.



Şekil 11. LR için karışıklık matrisi


Şekil 11’de görüldüğü gibi LR deny sınıfına ait 2626 örnekten 2572’sini, drop sınıfına ait 7457 örnekten 7430’unu, allow sınıfına ait 3011 örnekten 2905’ini ve reset-both sınıfına ait 13 örnekten 3’ünü doğru bir şekilde sınıflandırmıştır. LR, 13107 örneğin 12910’unu doğru, 197’sini ise yanlış sınıflandırarak %98,49 doğruluğa ulaşmıştır.

Tablo 6’da LR için deneysel sonuçlar görülmektedir.

Tablo 6. LR için deneysel sonuçlar

| Sınıf | Doğruluk | Kesinlik | Duyarlılık | F-skoru |
|--------------------|----------|----------|------------|---------|
| Deny | | %99,49 | %97,94 | %98,71 |
| Drop | | %99,33 | %99,63 | %99,48 |
| Allow | %98,49 | %98,54 | %96,47 | %97,49 |
| Reset-both | | %3,19 | %23,07 | %5,60 |
| Makro ortalama | | %75,14 | %79,28 | %75,32 |
| Ağırlıklı ortalama | | %99,08 | %98,48 | %98,77 |

Şekil 12’de XGBoost için karışıklık matrisi görülmektedir.



Şekil 12. XGBoost için karışıklık matrisi


Şekil 12’de görüldüğü gibi XGBoost deny sınıfına ait 2626 örnekten 2605’ini, drop sınıfına ait 7457 örnekten 7435’ini, allow sınıfına ait 3011 örnekten 2985’ini ve reset-both sınıfına ait 13 örnekten 8’ini doğru bir şekilde sınıflandırmıştır. XGBoost, 13107 örneğin 13033’ünü doğru, 74’ünü ise yanlış sınıflandırarak %99,43 doğruluğa ulaşmıştır.

Tablo 7’de XGBoost için deneysel sonuçlar görülmektedir.

Tablo 7. XGBoost için deneysel sonuçlar

| Sınıf | Doğruluk | Kesinlik | Duyarlılık | F-skoru |
|--------------------|----------|----------|------------|---------|
| Deny | | %99,61 | %99,20 | %99,40 |
| Drop | | %99,82 | %99,70 | %99,76 |
| Allow | %99,43 | %99,20 | %99,13 | %99,16 |
| Reset-both | | %22,85 | %61,53 | %33,32 |
| Makro ortalama | | %80,37 | %89,89 | %82,91 |
| Ağırlıklı ortalama | | %99,55 | %99,43 | %99,48 |

Şekil 13’te DNN için karışıklık matrisi görülmektedir.



Şekil 13. DNN için karışıklık matrisi

Şekil 13’te görüldüğü gibi DNN deny sınıfına ait 2626 örnekten 2626’sını, drop sınıfına ait 7457 örnekten 7436’sını, allow sınıfına ait 3011 örnekten 2993’ünü ve reset-both sınıfına ait 13 örnekten 10’unu doğru bir şekilde sınıflandırmıştır. DNN, 13107 örneğin 13065’ini doğru, 42’sini ise yanlış sınıflandırarak %99,67 doğruluğa ulaşmıştır.

Tablo 8’de DNN için deneysel sonuçlar görülmektedir.


Tablo 8. DNN için deneysel sonuçlar

| Sınıf | Doğruluk | Kesinlik | Duyarlılık | F-skoru |
|--------------------|----------|----------|------------|---------|
| Deny | | %99,69 | %100,00 | %99,84 |
| Drop | | %99,94 | %99,87 | %99,90 |
| Allow | %99,87 | %99,83 | %99,93 | %99,87 |
| Reset-both | | %100,00 | %84,61 | %91,66 |
| Makro ortalama | | %99,87 | %96,10 | %97,82 |
| Ağırlıklı ortalama | | %99,86 | %99,89 | %99,87 |

Tablo 9 ve Şekil 14’te ağırlıklı ortalamaya göre karşılaştırmalı deneysel sonuçlar görülmektedir.

Tablo 9. Ağırlıklı ortalamaya göre karşılaştırmalı deneysel sonuçlar


| Model | Doğruluk | Kesinlik | Duyarlılık | F-skoru |
|---------|----------|----------|------------|---------|
| LR | %98,49 | %99,08 | %98,48 | %98,77 |
| kNN | %99,03 | %99,31 | %99,02 | %99,16 |
| RF | %99,16 | %99,36 | %99,15 | %99,25 |
| SVM | %99,24 | %99,44 | %99,23 | %99,32 |
| XGBoost | %99,43 | %99,55 | %99,43 | %99,48 |
| DNN | %99,87 | %99,86 | %99,89 | %99,87 |



Şekil 14. Ağırlıklı ortalamaya göre karşılaştırmalı deneysel sonuçlar

Tablo 9 ve Şekil 14'te güvenlik duvarı üzerinden geçen ağ trafiğinin sınıflandırılması problemine yönelik uygulanan modellerin performans karşılaştırmaları sunulmuştur. LR, %98,49 doğruluk değerine sahip olmuştur. LR için tahmin edilen doğru pozitiflerin oranı yüksektir yani model yanlış pozitif oranını düşük tutabilmiştir ancak LR gerçek pozitiflerin %98,48'ini yakalayabilmiştir. kNN, %99,03 doğrulukla LR'ye kıyasla daha yüksek doğruluk sunmaktadır. kNN, hem yanlış pozitifleri azaltmada hem de gerçek pozitifleri bulmada dengelidir. RF, %99,16 doğrulukla kNN'e kıyasla daha doğru tahminler yapmaktadır. %99,36 kesinlik ve %99,15 duyarlılık değeriyle, doğru sınıflamaları yapmada başarılıdır. SVM genellikle doğrusal olmayan ayırım çizgileri gerektiren verilerde iyi çalışır ve bu problemde %99,24 doğrulukla RF ve kNN'e göre daha iyi sonuç vermiştir. XGBoost, genellikle büyük veri setleri ve karmaşık sınıflandırma problemleri için çok güçlü bir modeldir. Diğer modellere göre daha karmaşık bir optimizasyon tekniği kullandığı için bu problemde oldukça yüksek performans göstermiştir. DNN, en yüksek doğruluğa ve dengeli performansa sahip model olarak öne çıkmaktadır. XGBoost ve SVM de oldukça yüksek doğruluk değerine sahip olmuş ve duyarlılık/kesinlik oranlarında oldukça başarılıdır. Deneysel sonuçlar güvenlik duvarı üzerinden geçen ağ trafiğinin sınıflandırılmasında DNN'in karşılaştırılan modellerden daha başarılı olduğunu, XGBoost ve SVM'in DNN'in ardından en başarılı modeller olduğunu göstermiştir.

DNN'in epoch/loss grafikleri Şekil 15'te görülmektedir.



Şekil 15. DNN'in epoch/loss grafikleri

Şekil 15'te görülen model doğruluğu grafiğinde mavi çizgi eğitim doğruluğunu, turuncu çizgi ise test doğruluğunu ifade etmektedir. Modelin doğruluğunun başlangıçta düşük olduğu ancak yaklaşık 10. epoch'tan sonra hızla arttığını ve ardından 1'e yakın sabit bir değere ulaştığını gösteriyor. Model doğruluğu grafiği, modelin eğitim ve test doğruluğunun yüksek olduğunu ve dolayısıyla eğitimin başarılı bir şekilde ilerlediğini göstermektedir. Model loss grafiğinde ise ilk epoch'larda kayıp değeri yüksek olsa da, model eğitim aldıkça kayıp değeri düşmektedir. Yaklaşık 20. epoch'tan sonra kayıp değerleri stabilize olmuş, eğitim ve test kaybı birbirine yakın seyretmektedir. Şekil 15, modelin eğitim sürecinin başarılı bir şekilde ilerlediğini gösteriyor. Model doğruluğunun hızla yükselip sabit kalması ve kayıp değerinin düşerek az bir farkla seyretmesi, modelin iyi bir şekilde genelleme yapabildiğini ve aşırı uyum (overfitting) olmadığını gösterir.


5.1. XAI ile Elde Edilen Sonuçların İncelenmesi

SHAP, makine öğrenmesi ve derin öğrenme modellerinin tahminlerini açıklamak için kullanılan güçlü bir XAI yöntemidir. Modelin karar verme sürecini şeffaflaştırır ve bir modelin nasıl çalıştığını anlamayı sağlar. Shapley değeri, oyun teorisinde her oyuncunun oyun sonucuna ne kadar katkıda bulunduğunu hesaplamak için kullanılır. SHAP, bu matematiksel çerçeveyi makine öğrenimi modellerine uyarlayarak, her bir özellik için modelin tahminine olan katkıyı belirler. SHAP değeri, bir özelliğin modelin tahminine olan katkısını ölçen değerdir. Modelin ürettiği tahmin, tüm özelliklerin toplu etkisi ile elde edilmektedir. Her bir tahminin, tüm özelliklerin katkılarının (pozitif veya negatif) toplamı ile elde edildiği varsayılmaktadır. Modelin tahmin ettiği değer, Eş. 5 kullanılarak hesaplanmaktadır.

$$f(x) = \phi_0 + \sum_{i=1}^n \phi_i \quad (5)$$

ϕ_0 Modelin ortalama tahmini, ϕ_i ise i . özelliğin tahmin üzerindeki katkısını (SHAP değeri) ifade etmektedir.


Bu bölümde, DNN ile yapılan tahminlerin SHAP kullanılarak XAI ile incelenmesine yönelik deneysel sonuçlar sunulmuştur. Şekil 16'da ortalama SHAP değeri görülmektedir.



Şekil 16. Ortalama SHAP değeri

Şekil 16, modelin tahmininde hangi özelliklerin ne kadar etkili olduğunu göstermektedir. Özellikler, SHAP değerlerinin ortalama etkisine göre sıralanmıştır. En üstteki Elapsed Time (sec) özneliği, modelin tahminlerinde en büyük etkiye sahipken, pkts_sent en az etkili özelliktir. Özelliklerin rengine göre drop, allow, deny ve reset-both sınıfları için nasıl katkıda bulunduğu görülmektedir. Modelin kararlarını en çok etkileyen özelliklerin başında Elapsed Time (sec) ve NAT port özellikleri gelmektedir.


Şekil 17'de SHAP değerinin model çıktısı üzerindeki etkisi görülmektedir.



Şekil 17. SHAP değerinin model çıktısı üzerindeki etkisi

Şekil 17, her bir veri noktasındaki SHAP değerlerinin model çıktısı üzerindeki etkisini göstermektedir. Yüksek SHAP değerlerine sahip veri noktaları, modelin tahminlerini pozitif yönde etkilerken, düşük SHAP değerlerine sahip olanlar ise negatif etkiler. Renk skalası, ilgili özelliğin değeriyle SHAP değerini ilişkilendirmektedir. Örneğin, Elapsed Time (sec) özneliğindeki yüksek değerlere sahip veri noktaları modelin çıktılarını pozitif etkilemektedir.


Şekil 18'de NAT kaynak portu ile kaynak portu arasındaki ilişki görülmektedir.



Şekil 18. Kaynak portu ile NAT kaynak portu arasındaki ilişki

Şekil 18, kaynak portu ile NAT kaynak portu arasındaki ilişkiyi göstermektedir ve noktaların rengi NAT kaynak portu değerlerine göre değişmektedir. Şekil 18, özellikle bu iki özelliğin model tahminlerini nasıl etkilediğini anlamak için kullanılmaktadır. Belirli bir NAT kaynak portu aralığında SHAP değerlerinin nasıl dağıldığını ve model çıktısına olan etkisini gözlemlemeyi mümkün kılmaktadır.

Şekil 19'da tek bir gözlem için sunulan SHAP değerleri görülmektedir.



Şekil 19. Tek bir gözlem için SHAP değerleri

Şekil 19'da, her bir özellik, modelin tahminini nasıl etkilediğine göre pozitif (kırmızı) veya negatif (mavi) renkte gösterilmiştir. Örneğin, bu gözlemden Elapsed Time (sec) özneliği tahmini büyük ölçüde pozitif etkilerken, Packets ve pkts_received gibi özellikler tahmini negatif yönde etkilemektedir. Gözlemin genel tahminine en büyük katkıyı sağlayanlar kırmızı renkle, en büyük olumsuz etkileri sağlayanlar ise mavi renkle gösterilmiştir.

6. Tartışma

Veri setindeki sınıfların dengesizliği, LR'nin başarılı bir sınıflandırma yapamamasına neden olmuştur. kNN, basit bir sınıflandırma algoritmasıdır ve herhangi bir parametre ayarı gerektirmeden doğrudan veri üzerinde çalışabilir. kNN, veri noktalarının yerel yapısını kullanarak sınıflandırma yapar, bu da sınıflar arasında belirgin ayrımlar olduğunda etkili olabilir. RF, birden fazla karar ağacını bir araya getirerek, aşırı öğrenme riskini azaltmıştır ve daha güçlü bir genel performans sağlamıştır. SVM, yüksek boyutlu alanlarda oldukça iyi çalışır ve karmaşık sınıflandırma problemlerinde başarılıdır. XGBoost'un, aşırı öğrenme riskini azaltmak için L1 düzenleme kullanılmıştır ve hiper-parametre optimizasyonu ile bellek kullanımının verimli bir hale getirilmesi sağlanmıştır. DNN, derin katmanları sayesinde karmaşık ilişkileri öğrenerek yüksek boyutlu bu veri setinde etkili olmuştur. DNN'ler, çok sayıda katmandan oluşur ve her bir katman, verinin farklı özelliklerini öğrenir. Bu yapı, modelin karmaşık ilişkileri ve örüntüleri yakalamasına olanak tanır. Özellikle büyük ve karmaşık veri kümeleri için etkili bir şekilde öğrenebilir. DNN, ReLU ve Sigmoid gibi aktivasyon fonksiyonları kullanarak karmaşık doğrusal olmayan ilişkileri modelleyebilmiştir.

6. Sonuçlar

Küresel çapta internet kullanımındaki artış, yalnızca bireylerin ve işletmelerin çevrimiçi etkinliklerini hızlandırmakla kalmamış, aynı zamanda siber tehditlerin de daha karmaşık hale gelmesine neden olmuştur. Artan kullanıcı etkinlikleri ve çevrimiçi hizmetlere yönelik talepler, internet trafiğini giderek daha yoğun ve karmaşık bir yapıya dönüştürmüştür. Geleneksel ağ güvenliği yöntemleri ve özellikle güvenlik duvarları gibi çözümler, belirli kurallar setine dayandıkları için dinamik tehditler karşısında yetersiz kalabilmektedir. Güvenlik duvarları, ağlar arasındaki trafiği denetleyerek tehditlerin tespitine ve engellenmesine olanak sağlasa da, modern siber saldırıların karmaşıklığı karşısında bu yöntemler verimsiz hale gelmektedir. Bu noktada, yapay zekâ tabanlı çözümler, özellikle güvenlik duvarlarındaki log kayıtlarının daha etkin bir şekilde analiz edilmesi açısından yeni ve güçlü bir savunma mekanizması olarak öne çıkmaktadır. Ağ trafiği üzerindeki olası tehditlerin gerçek zamanlı olarak tespit edilebilmesi ve anormalliklerin fark edilmesi, yalnızca verilerin korunmasını sağlamakla kalmayıp, aynı zamanda önleyici tedbirlerin alınmasına da katkıda bulunmaktadır. Giderek daha karmaşık hale gelen saldırı türlerine karşı dinamik öğrenme yeteneği, yapay zekâ tabanlı sistemlerin daha esnek ve uyarlanabilir olmasına olanak tanır. Bu çalışmada, güvenlik duvarları üzerinden geçen ağ trafiği loglarının analizine yönelik DNN tabanlı bir derin öğrenme modeli geliştirilmiştir. Geliştirilen model ile verimli ve etkili bir analiz yöntemi sunarak geleneksel yöntemlerin sınırlılıklarını aşmak hedeflenmiştir. DNN, RF, kNN, SVM, LR ve XGBoost gibi popüler makine öğrenmesi algoritmalarıyla karşılaştırılarak kapsamlı bir değerlendirme sunulmuştur. Bu çalışma, sadece ağ güvenliği için değil, aynı zamanda yapay zekâ tabanlı güvenlik yaklaşımlarının açıklanabilirliğine de katkıda bulunmayı amaçlamaktadır. Güvenlik sistemlerinin karar alma süreçlerini şeffaflaştıran SHAP XAI yöntemi kullanılarak, yapılan sınıflandırma işlemlerinin anlaşılır ve izlenebilir olması sağlanmıştır. Çalışmanın sonuçları,

geliştirilen DNN tabanlı modelin %99,87 doğruluk oranıyla karşılaştırılan modellerden ve literatürdeki çalışmalardan daha yüksek bir performans sergilediğini ortaya koymuştur.

Kaynakça

- [1] Diwan, T. D. 2021. An investigation and analysis of cyber security information systems: latest trends and future suggestion. *Information Technology in Industry*, 9(2), 477-492.
- [2] Alsaqour, R., Motmi, A., Abdelhaq, M. 2021. A systematic study of network firewall and its implementation. *International Journal of Computer Science & Network Security*, 21(4), 199-208.
- [3] Islam, M. S., Uddin, M. A., Hossain, D. M. D., Ahmed, D. M. S., Moazzam, D. M. G. 2023. Analysis and evaluation of network and application security based on next generation firewall. *International Journal of Computing and Digital Systems*, 13(1), 193-202.
- [4] Anwar, R. W., Abdullah, T., Pastore, F. 2021. Firewall best practices for securing smart healthcare environment: A review. *Applied Sciences*, 11(19).
- [5] Varzaneh, M. R., Habbal, A., Dakkak, O. 2024. Firewalls and Internet of Things Security: A Survey. *Current Trends in Computing*, 1(1), 22-43.
- [6] Lyu, M., Gharakheili, H. H., Russell, C., Sivaraman, V. 2021. Hierarchical anomaly-based detection of distributed DNS attacks on enterprise networks. *IEEE Transactions on Network and Service Management*, 18(1), 1031-1048.
- [7] Lamdakar, O., Ameer, I., Eleyatt, M. M., Carlier, F., Ibourek, L. A. 2024. Toward a modern secure network based on next-generation firewalls: recommendations and best practices. *Procedia Computer Science*, 238, 1029-1035.
- [8] Malhotra, P., Singh, Y., Anand, P., Bangotra, D. K., Singh, P. K., Hong, W. C. 2021. Internet of things: Evolution, concerns and security challenges. *Sensors*, 21(5).
- [9] Aslan, Ö., Aktuğ, S. S., Ozkan-Okay, M., Yilmaz, A. A., Akin, E. 2023. A comprehensive review of cyber security vulnerabilities, threats, attacks, and solutions. *Electronics*, 12(6).
- [10] Ahmadi, S. 2023. Next Generation AI-Based Firewalls: A Comparative Study. *International Journal of Computer (IJC)*, 49(1), 245-262.
- [11] Ertam, F., Kaya, M. 2018. Classification of firewall log files with multiclass support vector machine. In 2018 6th International symposium on digital forensic and security (ISDFS), 22-25 Mart, Antalya, 1-4.
- [12] Al-Haijaa, Q. A., Ishtaiwia, A. 2021. Machine learning based model to identify firewall decisions to improve cyber-defense. *International Journal on Advanced Science, Engineering and Information Technology*, 11(4), 1688-1695.
- [13] Al-Behadili, H. N. K. 2021. Decision tree for multiclass classification of firewall access. *International Journal of Intelligent Engineering and Systems*, 14(3), 294-302.
- [14] Naryanto, R. F., Delimayanti, M. K. (2022, November). Machine Learning Technique for Classification of Internet Firewall Data Using RapidMiner. 2022 6th International Conference on Electrical, Telecommunication and Computer Engineering (ELTICOM), 22-23 Kasım, Medan, 155-159.
- [15] Aljabri, M., Alahmadi, A. A., Mohammad, R. M. A., Aboulmour, M., Alomari, D. M., Almotiri, S. H. 2022. Classification of firewall log data using multiclass machine learning models. *Electronics*, 11(12), 1851.
- [16] Rahman, M. H., Islam, T., Rana, M. M., Tasnim, R., Mona, T. R., Sakib, M. M. 2023. Machine Learning Approach on Multiclass Classification of Internet Firewall Log Files. 2023 International Conference on Computational Intelligence and Sustainable Engineering Solutions (CISES), 28-30 Nisan, Delhi, 358-364.
- [17] Al-Tarawneh, B. A., Bani-Salameh, H. 2023. Classification of firewall logs actions using machine learning techniques and deep neural network. *AIP Proceedings*, 2979(1).
- [18] Efeoğlu, E., Tuna, G. 2024. Classification of Firewall Log Files with Different Algorithms and Performance Analysis of These Algorithms. *Journal of Web Engineering*, 23(4), 561-593.
- [19] Lee, J. K., Hong, T., Lee, G. 2024. AI-Based Approach to Firewall Rule Refinement on High-Performance Computing Service Network. *Applied Sciences*, 14(11).
- [20] Haque, A. B., Islam, A. N., Mikalef, P. 2023. Explainable Artificial Intelligence (XAI) from a user perspective: A synthesis of prior literature and problematizing avenues for future research. *Technological Forecasting and Social Change*, 186.
- [21] Hassija, V., Chamola, V., Mahapatra, A., Singal, A., Goel, D., Huang, K., Hussain, A. 2024. Interpreting black-box models: a review on explainable artificial intelligence. *Cognitive Computation*, 16(1), 45-74.
- [22] Díaz-Rodríguez, N., Del Ser, J., Coeckelbergh, M., de Prado, M. L., Herrera-Viedma, E., Herrera, F. 2023. Connecting the dots in trustworthy Artificial Intelligence: From AI principles, ethics, and key requirements to responsible AI systems and regulation. *Information Fusion*, 99.
- [23] Haque, A. B., Islam, A. N., Mikalef, P. 2023. Explainable Artificial Intelligence (XAI) from a user perspective: A synthesis of prior literature and problematizing avenues for future research. *Technological Forecasting and Social Change*, 186.

- [24] Novelli, C., Taddeo, M., Floridi, L. 2024. Accountability in artificial intelligence: what it is and how it works. *Ai & Society*, 39(4), 1871-1882.
- [25] McDermid, J. A., Jia, Y., Porter, Z., Habli, I. 2021. Artificial intelligence explainability: the technical and ethical dimensions. *Philosophical Transactions of the Royal Society A*, 379(2207).
- [26] Hagendorff, T., Bossert, L. N., Tse, Y. F., Singer, P. 2023. Speciesist bias in AI: how AI applications perpetuate discrimination and unfair outcomes against animals. *AI and Ethics*, 3(3), 717-734.
- [27] Goldman, C. V., Baltaxe, M., Chakraborty, D., Arinez, J., Diaz, C. E. 2023. Interpreting learning models in manufacturing processes: towards explainable AI methods to improve trust in classifier predictions. *Journal of Industrial Information Integration*, 33.
- [28] Tripathi, S., Muhr, D., Brunner, M., Jodlbauer, H., Dehmer, M., Emmert-Streib, F. 2021. Ensuring the robustness and reliability of data-driven knowledge discovery models in production and manufacturing. *Frontiers in artificial intelligence*, 4.
- [29] Dwivedi, R., Dave, D., Naik, H., Singhal, S., Omer, R., Patel, P., Ranjan, R. 2023. Explainable AI (XAI): Core ideas, techniques, and solutions. *ACM Computing Surveys*, 55(9), 1-33.
- [30] Maruthi, S., Dodda, S. B., Yellu, R. R., Thuniki, P., Reddy, S. R. B. 2022. Toward a Hermeneutics of Explainability: Unraveling the Inner Workings of AI Systems. *Journal of Artificial Intelligence Research and Applications*, 2(2), 27-44.
- [31] El-Khawaga, G., Abu-Elkheir, M., Reichert, M. 2022. Xai in the context of predictive process monitoring: An empirical analysis framework. *Algorithms*, 15(6).
- [32] Feng, D. C., Wang, W. J., Mangalathu, S., Taciroglu, E. 2021. Interpretable XGBoost-SHAP machine-learning model for shear strength prediction of squat RC walls. *Journal of Structural Engineering*, 147(11).
- [33] Sahakyan, M., Aung, Z., Rahwan, T. 2021. Explainable artificial intelligence for tabular data: A survey. *IEEE Access*, 9, 135392-135422.
- [34] Sim, T., Choi, S., Kim, Y., Youn, S. H., Jang, D. J., Lee, S., Chun, C. J. 2022. eXplainable AI (XAI)-based input variable selection methodology for forecasting energy consumption. *Electronics*, 11(18).
- [35] Tunguz, B. 2021. Internet Firewall Data Set. <https://www.kaggle.com/datasets/tunguz/internet-firewall-data-set/data> (Erişim Tarihi: 01.09.2024).
- [36] Mosavi, A., Sajedi Hosseini, F., Choubin, B., Goodarzi, M., Dineva, A. A., Rafiei Sardooi, E. 2021. Ensemble boosting and bagging based machine learning models for groundwater potential prediction. *Water Resources Management*, 35, 23-37.
- [37] Aria, M., Cuccurullo, C., Gnasso, A. 2021. A comparison among interpretative proposals for Random Forests. *Machine Learning with Applications*, 6.
- [38] Subbiah, S., Anbananthen, K. S. M., Thangaraj, S., Kannan, S., Chelliah, D. 2022. Intrusion detection technique in wireless sensor network using grid search random forest with Boruta feature selection algorithm. *Journal of Communications and Networks*, 24(2), 264-273.
- [39] Zhang, S., Li, J., Li, Y. 2022. Reachable distance function for KNN classification. *IEEE Transactions on Knowledge and Data Engineering*, 35(7), 7382-7396.
- [40] Dong, Y., Ma, X., Fu, T. 2021. Electrical load forecasting: A deep learning approach based on K-nearest neighbors. *Applied Soft Computing*, 99.
- [41] Uddin, S., Haque, I., Lu, H., Moni, M. A., Gide, E. 2022. Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction. *Scientific Reports*, 12(1).
- [42] Wisanwanichthan, T., Thammawichai, M. 2021. A double-layered hybrid approach for network intrusion detection system using combined naive bayes and SVM. *Ieee Access*, 9, 138432-138450.
- [43] Ke, T., Ge, X., Yin, F., Zhang, L., Zheng, Y., Zhang, C., Wang, W. 2024. A general maximal margin hyper-sphere SVM for multi-class classification. *Expert Systems with Applications*, 237, 121647.
- [44] Anyanwu, G. O., Nwakanma, C. I., Lee, J. M., Kim, D. S. 2022. Optimization of RBF-SVM kernel using grid search algorithm for DDoS attack detection in SDN-based VANET. *IEEE Internet of Things Journal*, 10(10), 8477-8490.
- [45] Khalifa, R. M., Yacout, S., Bassetto, S. 2021. Developing machine-learning regression model with Logical Analysis of Data (LAD). *Computers & Industrial Engineering*, 151.
- [46] Huang, K., Zhang, H. 2022. Classification and regression machine learning models for predicting aerobic ready and inherent biodegradation of organic chemicals in water. *Environmental Science & Technology*, 56(17), 12755-12764.
- [47] Theissler, A., Thomas, M., Burch, M., Gerschner, F. 2022. ConfusionVis: Comparative evaluation and selection of multi-class classifiers based on confusion matrices. *Knowledge-Based Systems*, 247.
- [48] Kiangala, S. K., Wang, Z. 2021. An effective adaptive customization framework for small manufacturing plants using extreme gradient boosting-XGBoost and random forest ensemble learning algorithms in an Industry 4.0 environment. *Machine Learning with Applications*, 4.
- [49] Mohiuddin, G., Lin, Z., Zheng, J., Wu, J., Li, W., Fang, Y., Zeng, X. 2023. Intrusion detection using hybridized meta-heuristic techniques with Weighted XGBoost Classifier. *Expert Systems with Applications*, 232.

- [50] Hajhosseinlou, M., Maghsoudi, A., Ghezlbash, R. 2024. Regularization in machine learning models for MVT Pb-Zn prospectivity mapping: applying lasso and elastic-net algorithms. *Earth Science Informatics*, 1-15.
- [51] Vujović, Ž. 2021. Classification model evaluation metrics. *International Journal of Advanced Computer Science and Applications*, 12(6), 599-606.
- [52] Mubarak, A. A., Cao, H., Hezam, I. M. 2021. Deep analytic model for student dropout prediction in massive open online courses. *Computers & Electrical Engineering*, 93.
- [53] Lee, W., Seo, K. 2022. Downsampling for binary classification with a highly imbalanced dataset using active learning. *Big Data Research*, 28.
- [54] Agarwal, N., Tayal, D. K. 2022. FFT based ensemble model to predict ranks of higher educational institutions. *Multimedia Tools and Applications*, 81(23), 34129-34162.

Ekler

Ek A. Ek başlığı

Bu başlık zorunlu değildir. Metin içerisindeki şekil, grafik, tablo veya resim gibi görseller hakkında uzun ek bilgilere gerek duyulması durumunda bu kısımda verilmelidir. Bölüm başlığı “Cambria” fontunda 10 punto ve kalın olarak yazılmalıdır. Birden fazla ek kullanılacak olması durumunda alt başlıklar “**Ek A., Ek B., vb.**” şeklinde “Cambria” fontunda 9 punto ve kalın olarak yazılmalıdır. Eğer çalışmanızı İngilizce sunmak istiyorsanız bölüm başlığını “**Appendices**”, alt başlıkları ise “**Appendix A., Appendix B., etc**” olarak değiştiriniz.

Avrupa Ülkelerinde ve Türkiye'de Trafik Kazalarının İstatistik Tekniğine Göre Kümelenmesi

Burçin Paçacı^{*1}, Reşat Kasap², Kürşat Çubuk³

^{*1} Gazi Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği, ANKARA

Gazi Üniversitesi Fen Fakültesi İstatistik Bölümü, ANKARA

³ Gazi Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği, ANKARA

(Alınış / Received: 18.11.2024, Kabul / Accepted: 25.12.2024, Online Yayınlanma/ Published Online: 30.12.2024)

Anahtar Kelimeler

Trafik Kazaları,
Kümeleme Analizi,
İstatistiksel Analiz,
Karayolu Güvenliği

Öz:Trafik kazaları her yıl ölümlü, yaralanmalı ve maddi kayıplı sonuçlara yol açan, milyonlarca insanı etkileyen önemli bir sorundur. Tüm dünyada bir sorun teşkil eden trafik kazalarının minimum seviyeye inmesi ile toplumda daha güvenilir ulaşım sağlanacaktır. Bu sebeple dünyada trafik kazalarını azaltmaya yönelik mevcut önlemlerin, yatırımların ve uygulamaların dikkate alınması gerekmektedir. Bu çalışmada Avrupa ülkelerinde ve Türkiye'de meydana gelen trafik kazaları istatistiksel teknik kullanılarak kümelendi. Bu kapsamda çalışmada analiz edilen ülkelerin yüz ölçümü, nüfusu, trafik kaza sayısı, trafik kazasında ölen kişi sayısı, trafik kazasında ölen kişi sayısının nüfusa ve trafik kaza sayısına oranı, trafik kazasında yaralanan kişi sayısı, trafik kazasında yaralanan kişi sayısının nüfusa ve trafik kaza sayısına oranı faktörleri kullanılmıştır. Ayrıca çalışmanın veri aralığı 2018-2021 yılları seçilerek trafik kazalarının pandemiden önce, pandemi esnasında ve pandemiden sonrasındaki değişimi de incelenmiştir. Bu doğrultuda benzer özellik gösteren ülkeler belirlenmiş ve bu ülkelerde uygulanan yaptırımlar da dikkate alınarak değerlendirilmiştir.

Clustering of Traffic Accidents In European Countries and Türkiye According to Statistical Technique


Keywords

TrafficAccidents,
Clustering Analysis,
StatisticTechnique,
Transportation Security

Abstract:Traffic accidents are an important problem that leads to fatal, injured and financially lost consequences every year, affected millions of people. With the reduction of traffic accidents to a minimum level, which pose a problem all over the world, more reliable transportation will be provided in society. For this reason, it is necessary to take into account the existing measures, investments and applications aimed at reducing traffic accidents in the world. In this study, traffic accidents occurring in European countries and Türkiye were clustered using statistical technique. In this context, area and population of country, number of traffic accidents, number of people killed in traffic accidents, the ratio of the number of people killed in traffic accidents to the population and to the number of traffic accidents, the number of people injured in traffic accidents, the ratio of the number of people injured in traffic accidents to the population and to the number of traffic accidents were used in the study. In addition, the change in traffic accidents before, during and after the pandemic was examined selecting 2018-2021 which the data range of the study. In this direction, countries with similar characteristics have been identified and the sanctions applied in these countries have been evaluated taking into account.

1. Giriş

Trafik kazaları her yıl milyonlarca insanı doğrudan veya dolaylı olarak etkilemektedir [1]. Ulaştırma altyapısının gayrimenkul ve sanayi gibi sektörlerle aynı hızda büyümemesi trafik kazalarının meydana gelmesinde ana neden olarak değerlendirilmekte [2] olup trafik kazaları ülkelere göre farklılıklar gösterebilmektedir [3]. Ülkelerin ekonomik seviyesi [4], sürücülerin sürüş alışkanlıkları, sosyodemografik durumları araç, yol altyapısı, yol kullanıcısı ve bunların etkileşimleri [5] trafik kazalarının meydana gelmesinde yer alan faktörlerdendir. Trafik kazalarını azaltarak güvenli karayolu ulaşımını sağlamak amacıyla çok sayıda yaptırım uygulanmış ve bu yaptırımların etkisi yıllara göre incelenmiştir. Şekil 1'de 2001-2018 yılları arasında Avrupa ülkelerinin ve Türkiye'nin trafik kazalarındaki değişimleri gösterilmektedir.



Şekil 1. 2001-2018 arası Avrupa ülkeleri ve Türkiye'de ölümlü yol kaza oranlarındaki değişimler [6]

Avrupa ülkelerinin ve Türkiye'nin ölümlü yol kaza oranlarındaki değişimlerinin yer aldığı Şekil 1 incelendiğinde Litvanya'da %75,9 ile en büyük oranda ve Romanya'da %23,9 ile en küçük oranda azalış, Türkiye'de ise %30,6 ile artış meydana geldiği anlaşılmaktadır.

Trafik kazalarının meydana gelmesinde birçok faktör bulunmaktadır. Dünya Sağlık Örgütü tarafından pandemi olarak ilan edilen, tüm dünyayı etkileyen bir salgın olan Covid 19 [7] birçok ülkede olduğu gibi Türkiye'de de araştırılmıştır [8]. Covid 19'un trafik kazalarına etkisinin incelenmesi amacıyla çok sayıda çalışma yapılmıştır. Regresyon kurularak yapılan bir çalışmada trafik hacmi üzerinde Covid 19 zorunluluklarının trafik hacminde ve sınıflandırmasında etkisinin olduğu gözlenmiştir [9]. ABD'de yapılan bir çalışmada Covid 19 karantina döneminde trafik kazalarında azalma olduğu bulgulanmıştır. Covid 19 karantina döneminin dışarı çıkma yasağı, uzaktan çalışma gibi yaptırımları getirmesi trafik yoğunluğunun azalmasını sağlamıştır. Bu durum sonucunda ise trafik kazalarının azalması gözlenmiştir [10]. Yapılan bir çalışmada ABD'deki New York City, Los Angeles ve Boston'daki karayolu trafik güvenliğinin pandemiden, ilgili yerel yönetim emirlerinden ve kısıtlamalarından nasıl etkilendiği analiz edilmiştir. Çalışmada trafik kazalarının sıcak noktaları incelenmiş olup salgının ortaya çıkışından önceki ve sonraki yıllarda trafik kazalarının yer ve zaman bakımından değişime uğradığı bulunmuştur [11]. ABD'de Covid 19'un trafik kazaları üzerine etkisinin incelendiği çalışmada Covid 19 karantina döneminde meydana gelen trafik kazalarının önceki yıllarda gerçekleşen trafik kazalarına göre daha düşük fakat daha şiddetli olduğu tespit edilmiştir [12].

Bu çalışmada Avrupa ülkeleri ve Türkiye'de meydana gelen trafik kazaları, verilerin gruplara ayrılmasında kullanılan bir sınıflandırma yöntemi olan kümeleme analizi [13] ile incelenmiştir. Literatürde kümeleme analizinin yapıldığı birçok çalışma mevcuttur. Murat ve Şekerler, Denizli ilinde meydana gelen trafik kazalarını kümeleme yöntemini kullanarak analiz etmişlerdir [14]. Atalay ve Tortum çalışmalarında Türkiye'de 1997-2006 yılları arasında meydana gelen trafik kazalarını kümeleme yöntemi ile analiz etmişlerdir [15]. Tortum ve arkadaşları 2002-2007 yıllarında Erzurum ilinde meydana gelen trafik kazalarını incelemek amacıyla kümeleme analizi yapmışlardır [16]. Söylemez ve arkadaşları, makine öğrenme tekniklerinden olan birliktelik kuralı kullanarak

Ankara ilinde meydana gelen trafik kazalarını analiz etmiştir[17]. Atalay ve Bircik, toplu taşıma sistemlerini kümeleme analizi ile incelemiştir [18]. Yuan ve arkadaşları Çin’de meydana gelen trafik kazalarını incelemek amacıyla kümeleme ve faktör analizlerini kullanmışlardır [19]. Tamneh ve arkadaşları Abu Dabi’de 2008-2013 yılları arasında meydana gelen trafik kazalarını incelemek amacıyla hiyerarşik kümeleme analizini kullanmışlardır [20]. Budiawan ve Purwanggono çalışmalarında Semarang kentinde trafik kazalarını analiz etmek amacıyla kümeleme yöntemini kullanmışlardır [21]. Li ve arkadaşları, trafik kazalarında yaralanma şiddetini belirlemek amacıyla kümeleme analizini kullanmışlardır [22]. Bolat ve arkadaşları makine öğrenmesi yöntemlerini kullanarak Kahramanmaraş ilinde trafik kazalarını incelemiştir [23].

Bu çalışmada Avrupa ve Türkiye’de meydana gelen Covid 19 öncesi, Covid 19 dönemi ve Covid 19 sonrası trafik kazalarındaki değişim TÜİK’ten temin edilen faktörlere göre kümeleme analizi ile incelenmiştir. Bu doğrultuda incelenen ülkelerde meydana gelen trafik kazaları arasında birbirine benzer özellik gösteren ülkelerin trafik düzenine ilişkin yaptırımları, uygulamaları dikkate alınarak güvenli ulaşımın sağlanması amacıyla öneriler sunulmuştur.

2. Avrupa Ülkelerinde ve Türkiye’de Trafik Kazaları

Bu kısımda ilk olarak Avrupa ülkeleri ve Türkiye’de meydana gelen trafik kazaları incelenmiştir. İkinci kısımda trafik güvenliğine yönelik Avrupa ülkelerinin aldığı önlemlere yer verilmiştir.

2.1. Avrupa ülkelerinde ve Türkiye’de meydana gelen trafik kazaları

Avrupa ülkelerinde ve Türkiye’de 2021 yılına ait trafik kaza verisi Tablo 1’de yer almaktadır [24]. Sekiz ayrı parametrenin incelendiği Tablo 1’de “Nüfus (1)”, “Trafik kaza sayısı (2)”, “Ölü sayısı (3)”, “Yaralı sayısı (4)”, “Ölü sayısının nüfusa oranı (5)”, “Yaralı sayısının nüfusa oranı (6)”, “Ölü sayısının kaza sayısına oranı (7)” ve “Yaralı sayısının kaza sayısına oranı (8)” yer almaktadır. TÜİK’ten elde edilen “Yaralı sayısının kaza sayısına oranı” bulunurken İrlanda, İsveç, Letonya, Malta ve Slovakya ülkelerinde 2021 yılına ait veri bulunmamaktadır. Buna bağlı yaralı sayısının nüfusa oranı ve yaralı sayısının kaza sayısına oranı elde edilememektedir.

Tablo 1’de temin edilen veri kapsamında incelenen ülkeler arasında Türkiye, nüfus, trafik kaza sayısı, trafik kazalarında ölü sayısı ve trafik kazasında yaralı sayısı parametrelerinde ilk iki sırada yer almaktadır. Oransal olarak incelemelerde ise Türkiye’de üst sıralarda yer almaktadır. Ölü sayısının nüfusa oranına göre en düşük değer 0,01 ile Norveç, en yüksek değer ise 0,08 ile Romanya’ya aittir. Türkiye ise 0,06 oran ile Macaristan, Yunanistan ve Polonya ile aynı orana sahiptir. Trafik kazası sonuçlarında yaralı sayısının nüfusa oranı incelendiğinde Danimarka 0,44 ile en düşük orana, Avusturya ise 4,57 ile en yüksek orana sahiptir. Türkiye ise 3,24 ile yüksek bir orana sahiptir. Ölü sayısının kaza sayısına oranı incelendiğinde Türkiye’nin 16. sırada ve 0.03 orana sahip olduğu anlaşılmaktadır. Yaralı sayısının kaza sayısına oranı incelendiğinde ise Türkiye veriyi sahip ülkeler arasında 1.46 ile en yüksek orana sahiptir.

Tablo 2’de 2022 yılına ait Avrupa ülkeleri ve Türkiye’nin “Ölümlü ve Yaralanmalı Kaza Sayısı”, “Ölü Sayısı”, “Bin Kişiye Düşen Otomobil Sayısı”, “Bir Milyon Otomobile Düşen Ölü Sayısı” ve “Bir Milyon Kişiye Düşen Ölü Sayısı” faktörleri yer almaktadır [25]. Tablo 2 incelendiğinde Türkiye incelenen ülkeler arasında “Ölümlü ve Yaralanmalı Kaza Sayısı” parametresinde 2., “Ölü Sayısı” ve “Bir Milyon Otomobile Düşen Ölü Sayısı” parametrelerinde 1., “Bir Milyon Kişiye Düşen Ölü Sayısı” parametresinde 10. ve “Bin Kişiye Düşen Otomobil Sayısı” parametresinde ise sonuncu olmuştur. Bin kişiye düşen araç sayısı, trafik kaza sayısı ile beraber değerlendirildiğinde incelenen ülkeler arasında bin kişiye düşen araçta sonuncu sırada yer alan Türkiye’nin trafik kaza sayısı bakımından ikinci sırada yer alması dikkat çekicidir. Tablo 1 ve Tablo 2’de hem oransal hem de sayı bakımından Türkiye’de meydana gelen trafik kazaları Avrupa ülkelerine göre daha yüksektir.

Tablo 1. 2021 yılına ait ülkelerin trafik kaza oranları [24]

| Sıra | Ülke | 1 | Ülke | 2 | Ülke | 3 | Ülke | 4 | Ülke | 5 | Ülke | 6 | Ülke | 7 | Ülke | 8 |
|------|------------------|--------------|------------------|---------------|------------------|-------------|------------------|---------------|------------------|-------------|------------------|-------------|------------------|-------------|------------------|-------------|
| 1 | Türkiye | 84680 | Almanya | 258987 | Türkiye | 5362 | İrlanda | - | Bulgaristan | 0,08 | İrlanda | - | Polonya | 0,1 | İrlanda | - |
| 2 | Almanya | 83200 | Türkiye | 187963 | Fransa | 2931 | İsveç | - | Letonya | 0,08 | İsveç | - | Bulgaristan | 0,09 | İsveç | - |
| 3 | Fransa | 68084 | İtalya | 151875 | İtalya | 2875 | Letonya | - | Romanya | 0,08 | Letonya | - | Finlandiya | 0,07 | Letonya | - |
| 4 | Birleşik Krallık | 67081 | Birleşik Krallık | 95422 | Almanya | 2562 | Malta | - | Macaristan | 0,06 | Malta | - | Romanya | 0,07 | Malta | - |
| 5 | İtalya | 62390 | İspanya | 89862 | Polonya | 2245 | Slovakya | - | Polonya | 0,06 | Slovakya | - | Slovakya | 0,06 | Slovakya | - |
| 6 | İspanya | 47260 | Fransa | 53521 | Romanya | 1779 | Almanya | 323129 | Türkiye | 0,06 | Avusturya | 4,57 | Yunanistan | 0,06 | Türkiye | 1,46 |
| 7 | Polonya | 38185 | Belçika | 34640 | İspanya | 1533 | Türkiye | 274615 | Yunanistan | 0,06 | Almanya | 3,88 | Danimarka | 0,05 | Birleşik Krallık | 1,4 |
| 8 | Romanya | 21230 | Avusturya | 32774 | Birleşik Krallık | 1528 | İtalya | 204728 | Çek Cumhuriyeti | 0,05 | Portekiz | 3,7 | Fransa | 0,05 | Lüksemburg | 1,36 |
| 9 | Hollanda | 17337 | Portekiz | 30691 | Yunanistan | 624 | Birleşik Krallık | 133793 | Estonya | 0,05 | Belçika | 3,57 | Litvanya | 0,05 | İtalya | 1,35 |
| 10 | Belçika | 11778 | Romanya | 26805 | Portekiz | 561 | İspanya | 118162 | İtalya | 0,05 | İtalya | 3,28 | Estonya | 0,04 | İspanya | 1,31 |
| 11 | Çek Cumhuriyeti | 10702 | Polonya | 22816 | Bulgaristan | 561 | Fransa | 67049 | Litvanya | 0,05 | Türkiye | 3,24 | Letonya | 0,04 | Macaristan | 1,31 |
| 12 | Yunanistan | 10569 | Hollanda | 18449 | Macaristan | 544 | Belçika | 42050 | Portekiz | 0,05 | Slovenya | 3,06 | Macaristan | 0,04 | Almanya | 1,25 |
| 13 | Portekiz | 10264 | Çek Cumhuriyeti | 18156 | Çek Cumhuriyeti | 532 | Avusturya | 40889 | Slovakya | 0,05 | İspanya | 2,5 | Çek Cumhuriyeti | 0,03 | Avusturya | 1,25 |
| 14 | İsveç | 10261 | Macaristan | 14233 | Belçika | 516 | Portekiz | 38014 | Slovenya | 0,05 | Çek Cumhuriyeti | 2,07 | Hollanda | 0,03 | Bulgaristan | 1,25 |
| 15 | Macaristan | 9728 | İsveç | 12625 | Hollanda | 509 | Romanya | 33409 | Avusturya | 0,04 | Birleşik Krallık | 1,99 | Lüksemburg | 0,03 | Fransa | 1,25 |
| 16 | Avusturya | 8956 | Yunanistan | 10454 | Avusturya | 362 | Polonya | 26415 | Belçika | 0,04 | Lüksemburg | 1,94 | Türkiye | 0,03 | Romanya | 1,25 |
| 17 | Bulgaristan | 6919 | Bulgaristan | 6080 | Slovakya | 247 | Çek Cumhuriyeti | 22146 | Finlandiya | 0,04 | Macaristan | 1,91 | Birleşik Krallık | 0,02 | Portekiz | 1,24 |
| 18 | Norveç | 5910 | İrlanda | 6057 | Finlandiya | 225 | Hollanda | 20046 | Fransa | 0,04 | Romanya | 1,57 | İrlanda | 0,02 | Norveç | 1,23 |
| 19 | Danimarka | 5895 | Slovenya | 5326 | İsveç | 210 | Macaristan | 18599 | Lüksemburg | 0,04 | Estonya | 1,43 | İspanya | 0,02 | Çek Cumhuriyeti | 1,22 |
| 20 | Finlandiya | 5587 | Slovakya | 4302 | Litvanya | 148 | Yunanistan | 12356 | Almanya | 0,03 | Litvanya | 1,18 | İsveç | 0,02 | Belçika | 1,21 |
| 21 | Slovakya | 5436 | Norveç | 3620 | Letonya | 147 | Bulgaristan | 7609 | Hollanda | 0,03 | Yunanistan | 1,17 | İtalya | 0,02 | Slovenya | 1,21 |
| 22 | İrlanda | 5225 | Letonya | 3403 | İrlanda | 137 | Slovenya | 6438 | İrlanda | 0,03 | Hollanda | 1,16 | Norveç | 0,02 | Finlandiya | 1,2 |
| 23 | Litvanya | 2711 | Finlandiya | 3243 | Danimarka | 130 | Norveç | 4458 | İspanya | 0,03 | Bulgaristan | 1,1 | Portekiz | 0,02 | Yunanistan | 1,18 |
| 24 | Slovenya | 2102 | Litvanya | 2808 | Slovenya | 114 | Finlandiya | 3886 | Danimarka | 0,02 | Fransa | 0,98 | Slovenya | 0,02 | Polonya | 1,16 |
| 25 | Letonya | 1862 | Danimarka | 2402 | Norveç | 80 | Litvanya | 3211 | Birleşik Krallık | 0,02 | Norveç | 0,75 | Almanya | 0,01 | Litvanya | 1,14 |
| 26 | Estonya | 1220 | Estonya | 1538 | Estonya | 55 | Danimarka | 2607 | İsveç | 0,02 | Finlandiya | 0,7 | Avusturya | 0,01 | Estonya | 1,13 |
| 27 | Lüksemburg | 640 | Malta | 1004 | Lüksemburg | 24 | Estonya | 1740 | Malta | 0,02 | Polonya | 0,69 | Belçika | 0,01 | Danimarka | 1,09 |
| 28 | Malta | 461 | Lüksemburg | 916 | Malta | 9 | Lüksemburg | 1243 | Norveç | 0,01 | Danimarka | 0,44 | Malta | 0,01 | Hollanda | 1,09 |

1 Nüfus (Bin)

2 Trafik kaza sayısı

3 Ölü sayısı

4 Yaralı sayısı

5 Ölü sayısının nüfusa oranı

6 Yaralı sayısının nüfusa oranı

7 Ölü sayısının kaza sayısına oranı

8 Yaralı sayısının kaza sayısına oranı

Tablo 2. 2022 yılı Avrupa ülkeleri ve Türkiye trafik verisi [25]

| Sıra | Ülke İsmi | Ölümlü ve Yaralanmalı Kaza Sayısı | Ülke İsmi | Ölü Sayısı | Ülke İsmi | Bin Kişiye Düşen Otomobil Sayısı | Ülke İsmi | Bir Milyon Otomobile Düşen Ölü Sayısı | Ülke İsmi | Bir Milyon Kişiye Düşen Ölü Sayısı |
|------|----------------|-----------------------------------|----------------|--------------|----------------|----------------------------------|----------------|---------------------------------------|----------------|------------------------------------|
| 1 | Almanya | 264.500 | Türkiye | 5.229 | Lüksemburg | 682 | Türkiye | 366 | Romanya | 85 |
| 2 | Türkiye | 197.261 | Almanya | 2.719 | İtalya | 670 | Romanya | 232 | Letonya | 73 |
| 3 | İtalya | 118.300 | Fransa | 2.538 | Finlandiya | 656 | Letonya | 190 | Bulgaristan | 67 |
| 4 | İspanya | 72.960 | Polonya | 2.491 | GKRY | 645 | Bulgaristan | 163 | Polonya | 66 |
| 5 | Fransa | 45.120 | İtalya | 2.395 | Polonya | 644 | Hırvatistan | 137 | Litvanya | 63 |
| 6 | Avusturya | 30.670 | Romanya | 1.644 | Estonya | 608 | Macaristan | 119 | Türkiye | 61 |
| 7 | Belçika | 30.230 | İspanya | 1.370 | Malta | 597 | Litvanya | 114 | Hırvatistan | 59 |
| 8 | Portekiz | 27.730 | Yunanistan | 584 | Almanya | 580 | Yunanistan | 107 | Yunanistan | 55 |
| 9 | Polonya | 23.540 | Portekiz | 536 | Avusturya | 570 | Slovakya | 102 | GKRY | 54 |
| 10 | Romanya | 22.810 | Çekya | 518 | Fransa | 567 | Polonya | 101 | Portekiz | 52 |
| 11 | Çekya | 18.420 | Hollanda | 515 | Çekya | 565 | Portekiz | 97 | Çekya | 48 |
| 12 | Hollanda | 17.040 | Belçika | 499 | Litvanya | 560 | Belçika | 85 | Macaristan | 47 |
| 13 | Macaristan | 13.780 | Bulgaristan | 463 | Slovenya | 555 | Çekya | 83 | Slovakya | 45 |
| 14 | İsveç | 13.680 | Macaristan | 460 | Portekiz | 540 | GKRY | 83 | Estonya | 44 |
| 15 | Yunanistan | 9.080 | Avusturya | 344 | İspanya | 521 | Estonya | 74 | Belçika | 43 |
| 16 | Hırvatistan | 7.710 | Slovakya | 247 | Yunanistan | 514 | Avusturya | 68 | Lüksemburg | 41 |
| 17 | İrlanda | 5.880 | Hırvatistan | 237 | Belçika | 509 | Slovenya | 68 | Finlandiya | 40 |
| 18 | Bulgaristan | 5.710 | Finlandiya | 223 | Hollanda | 503 | Fransa | 66 | İtalya | 40 |
| 19 | Slovenya | 4.780 | İsveç | 204 | İsveç | 476 | İrlanda | 66 | Avusturya | 39 |
| 20 | Slovakya | 4.300 | Litvanya | 175 | Danimarka | 466 | Finlandiya | 62 | Fransa | 38 |
| 21 | Finlandiya | 3.610 | Danimarka | 163 | Slovakya | 447 | Danimarka | 61 | Slovenya | 38 |
| 22 | Letonya | 3.400 | İrlanda | 146 | İrlanda | 446 | İtalya | 60 | Almanya | 33 |
| 23 | Litvanya | 2.830 | Letonya | 139 | Hırvatistan | 433 | Lüksemburg | 60 | Hollanda | 30 |
| 24 | Danimarka | 2.530 | Slovenya | 80 | Bulgaristan | 414 | Hollanda | 59 | İrlanda | 29 |
| 25 | Estonya | 1.410 | Estonya | 59 | Macaristan | 403 | Almanya | 57 | İspanya | 29 |
| 26 | Malta | 1.340 | GKRY | 48 | Letonya | 390 | İspanya | 56 | Danimarka | 28 |
| 27 | Lüksemburg | 770 | Lüksemburg | 26 | Romanya | 379 | İsveç | 42 | Malta | 21 |
| 28 | GKRY* | 340 | Malta | 11 | Türkiye | 167 | Malta | 36 | İsveç | 20 |

*GKRY: Güney Kıbrıs Rum Yönetimi

2.2. Avrupa ülkelerinde trafik kazalarını azaltmaya yönelik uygulamalar

Ölümlü yol kaza oranlarında azalış gerçekleşen ülkelere ait uygulanan yaptırımların ve denetimlerin incelenmesi güvenli karayolu ulaşımı açısından faydalıdır. Avrupa ülkelerinin karayolu güvenliğine ilişkin raporunda yer alan uygulamalar aşağıda yer almaktadır [26].

Almanya:

Almanya'da ulaşım güvenliği kapsamında Vizyon Sıfır politikası benimsenmektedir. Bu politika doğrultusunda belediyelere 30 km/s hız limitleri getirme, dar kırsal yollarda hız sınırının 80 km/s'ye düşürülmesi ve otoyollarda genel bir hız sınırı getirilmesi, ayrıca trafik kanunu ihlalleri için denetim sisteminin gözden geçirilmesi, alkollü araç kullanma eşliğinin düşürülmesi, 1,1- 1,6 promil arasında alkollü sürücülerin sürücü belgesi geri alınmadan önce tıbbi ve psikolojik bir değerlendirmeye tabi tutulması ve karayolu trafik güvenliği çalışmalarından sorumlu tüm uzman yetkililer için sürekli eğitim sağlanması talep edilmektedir.

Belçika:

Belçika'da karayolu güvenliği çalışmalarının son on yılında, farklı seviyelerdeki kamu yetkililerinin hız yönetimi ne ve denetimine odaklanmış, birçok belediye yerel hız azaltma önlemleri almıştır. Flanders'ta yerleşim alanları dışındaki standart hız sınırı 2017'de 90 km/s iken 70 km/s'ye düşürülmüştür. 2021 yılının Ocak ayında, Brüksel Başkent bölgesinde yerleşim alanı içinde 30 km/s'lik genel bir hız sınırı getirilmiştir. Alkol seviyesi en az 1,2 g/l olan mükerrer ihlalciler ve alkol seviyesi en az 1,8 g/l olan ilk ihlalciler için araçta alkol kilidi zorunlu hale gelmiştir.

Birleşik Krallık:

Karayolu trafik güvenliğine ilişkin sorumluluklar Birleşik Krallık'taki farklı uluslara devredilmiştir. Bu doğrultuda İskoçya alkollü araç kullanma sınırını kaldırmış, Kuzey İrlanda, kademeli sürücü belgesi ve daha düşük alkollü araç kullanma limitleri konusunda ilerleme kaydetmiş ve Galler, ulusal zorunlu 30km/s hız sınırı belirlemiştir. İngiltere'de Londra Ulaştırma ve İngiltere Karayolları Vizyon Sıfır politikasını benimsemiştir. Merkezi hükümet, bisiklet güvenliği yatırımları, yeni bir kazazede raporlama sistemi (CRASH) ve bireysel programları desteklemiş ve kaza soruşturması, genç sürücü güvenliği, karayolu polisliği konularında araştırmalar başlatmıştır. Bu araştırmaların gelecekte olumlu sonuçlar vereceği öngörülmektedir.

Finlandiya:

Finlandiya, hız ihlali, alkollü araç kullanma ve güvenlik ekipmanlarının kullanılmaması gibi geleneksel karayolu güvenliğini tehdit eden problemleri çözmeye yönelmiştir. Araç filosunun altyapıdaki iyileştirmelerle daha hızlı yenilenmesinin ve denetlemenin trafik güvenliği kapsamında iyi bir temel oluşturacağı öngörülmüştür. Ayrıca komşu ülkelerin iyi uygulamalarının benimsenmesi de trafik güvenliği konusunda gerekli görülmüştür.

Fransa:

Fransa'da şehirlerarası yollarda yasal hız sınırının 90 km/s'den 80 km/s'ye düşürüldükten sonra ölümlerin 2018'de 2017'ye göre %6 azaldığı gözlenmiştir. Fransız hükümeti 2018'in başında, iki şeritli şehirlerarası yollarda ve ayırıcı bariyeri olmayan yollarda standart hız sınırını 90'dan 80 km/s'ye düşürmüştür.

İrlanda:

İrlanda'da 2013-2020 İrlanda Karayolu Trafik Güvenliği Stratejisi kapsamında özellikle hız, alkol ve uyuşturucu kullanımı, cep telefonu kullanımı ve emniyet kemeri takmama gibi riskli davranışlara odaklanan bir 'Temellere dönüş' yaklaşımı üzerinde anlaşmaya varılmıştır. Alkollü araç kullanma cezaları gözden geçirilmiş ve 0,5- 0,8 g/l arasında alkol ile yakalanan alkollü sürücüler için daha önce ceza puanı ihlali uygulanırken 2018'de otomatik diskalifiye uygulaması getirilmiştir.

Hollanda:

Hollanda'da hükümet 2050 Vizyon Sıfır hedefini desteklemektedir. Bu kapsamda 30 yıl içinde beş milyar altyapı güvenliği için en az 12 milyar Euro'ya ihtiyaç duyulmaktadır. Fayda-maliyet analizine göre, altyapı güvenliğine yatırılan her Euro'nun üç veya dört Euro kazanç sağlayacağı değerlendirilmektedir.

İspanya:

İspanya, trafik güvenliğini sağlama konusunda denetime önem vermiş olup son on yılda yapılan denetimler karayolu güvenliğinin iyileştirilmesine önemli bir katkıda bulunmuştur. Alkollü araç kullanımına ilişkin yapılan denetim sayısı 2018'de 5,5 milyondan 2019'da 6,5 milyona çıkmıştır. Aynı zamanda sınırlarındaki değişikliklere odaklanılmış olup 2019 yılında şehirlerarası yollarda yasal hız sınırı 100 km/s'den 90 km/s'ye, 11 Mayıs 2021'de tek ana arteri bulunan şehir içi yollarda 50 km/s'den 30 km/s'ye ve ortak kullanım alanlarında 20 km/s'ye düşürülmüştür. Eylül 2020'de, tüm şehirde 30 km/s hız sınırı uygulayan 300.000'den fazla nüfuslu ilk şehir Bilbao

olmuştur. Madrid, Barselona, Valencia, Sevilla, Zaragoza, Murcia, Pontevedra, Oviedo, Pamplona, Burgos, Soria, Salamanca, Cuenca, Palma, Córdoba, Málaga, Cádiz ve LasPalmas dahil olmak üzere birçok şehirde halihazırda 30 km/s'lik büyük ölçekli projeler hayata geçirilmiştir.

İsveç:

İsveç'te devlet ağında ortalama hız 82 km/s'ten 77 km/s'e düşürülmüştür. 46 km/s hedefini karşılayan belediye ağında ortalama hız 49 km/s'den 46 km/s'ye düşürülmüştür.

Norveç:

Norveç'te Vizyon Sıfır'a dayalı sistematik, uzun vadeli ve kanıta dayalı çalışmalar esas alınmıştır. Norveç, karayolu ölümlerini azaltma hızı açısından PIN (The Road Safety Performance Index) kapsamındaki ülkeler arasında liderdir. Norveç Ulaştırma Ekonomisi Enstitüsü, kara yolunda ölümlerin ve yaralanmaların azalması konusunda katkı sağlayan önemli faktörleri %22,2 ile düşük ortalama seyir hızı, %21,2 oran ile yol altyapısının iyileştirilmesi (yeni otoyollar, refüj bariyerli yeni 2+1 yollar, tırtıklı orta şeritler, yerel yol iyileştirme çalışmaları ve 2001'de hız limitlerinin düşürülmesi) ve %16,5 ile daha güvenli araçlar olarak belirlemiştir. Diğer faktörlerin oranları ise %15,9 oran ile genç ve yaşlı otomobil yolcuları arasında riskin azaltılması, %7,7 oran ile emniyet kemeri takma, %7,6 oran ile mevzuat ve denetimler, %6 oran ile yaralanan çocukların oranında azalma ve %2,8 oran ile bisiklet kaskı kullanımındaki artış yer almaktadır. Çalışmada karayolu güvenliğinde hiçbir faktörün tek başına bir katkı yapmadığı sonucuna varılmış, çoğunlukla küçük veya orta düzeyde katkılarda bulunan çok sayıda faktörün bir araya gelmesi ile uzun vadeli bir iyileşme elde edildiği sonucuna ulaşılmıştır.

Polonya:

AB (Avrupa Birliği) ortalamasında hayatını kaybeden yol kullanıcılarından yayaların ortalaması %21 iken bu oran Polonya'da %29'dur. Bu sebeple Polonya'da 2015, 2017 ve 2018 yıllarında yaya güvenliğini yönetmekten sorumlu kurumlara yönelik rehberler yayınlanmış ve bu kapsamda yaya geçitlerinin güvenlik denetimleri ve belirlenen geçitlerde aydınlatma çalışmaları yapılmıştır. Trafik Kanunu'nda yaya geçidi güvenliğinin artırılmasına ve karşıdan karşıya geçerken cep telefonu kullanımının yasaklanmasına ilişkin düzenlemede Haziran 2021 ile güncelleme yapılmıştır. Güvenli bisiklet altyapısına ilişkin 2019 yılında ulusal yönergeler yayınlanmıştır. Mikro mobilite araçları için sadece bisiklet yollarında kullanılma veya hız sınırı 30 km/s veya daha az olan yollarda maksimum 20 km/s hızda veya yürüme hızında kaldırımlarda kullanılabilme sınırları uygulanmıştır. Avrupa Birliği tarafından ortak finanse edilen bir proje kapsamında, güvenlik kamerası bilgilerini işlemek ve düzenlemek için otomatik bir Trafik Denetim Merkezi oluşturulmuş ve 2011-2015 döneminde 400'ün üzerinde yeni kamera kurulmuştur. Kameraların kurulması ile kara yolu ölümlerinde %52, ağır yaralanmalarda ise %42 oranında azalma meydana geldiği tespit edilmiştir.

Slovenya:

Karayolu güvenliği stratejisinin koordinasyonundan ve uygulanmasından sorumlu olan Slovenya'da Trafik Güvenliği Ajansı (AVP) 2010 yılında kurulmuştur. Bu kapsamda hazırlanan Mevcut Ulusal Karayolu Trafik Güvenliği Programı ile kara yolunda ölümler ile ağır yaralanmalarının sayısının yarıya indirilmesi, tüm araç yolcuları için emniyet kemeri takma oranlarının %98'e çıkarılması, alkole bağlı ölümlerin %50 azaltılması gibi hedef göstergeler belirlenmiştir. Uygulamaların etkinliğinin değerlendirilmesi amacıyla sonuçları takip edilmiş olup en belirgin ilerleme emniyet kemeri takma konusunda gözlenmiştir. Emniyet kemeri kullanımı 2010 yılında %50 iken bu oran 2018 yılında %78'e çıkmıştır. 8 ila 14 yaş arası çocuklar arasındaki çocuk koltuğu kullanımı ise 2010'da %70 iken 2018'de %90'a çıkmıştır. Trafik güvenliğinin artması konusunda önleyici çalışmalar ve eğitim, altyapı iyileştirmeleri, polis denetimleri, alkol ve uyuşturucu etkisinde araç kullanan sürücüler için rehabilitasyon programları ve genç sürücüler için iki aşamalı sürücü belgesi sisteminin getirilmesi katkı sağlamıştır.

Yunanistan:

Yunanistan'da kara yolu güvenliğini sağlamak amacıyla önemli adımlar atılmıştır. Bu kapsamda ülkenin ana karayolu ağının büyük bir kısmı, yüksek sayıda ölüme sebebiyet veren ulusal yolların yerini almış ve yeni yapılmış veya iyileştirilmiş otoyollarla önemli ölçüde iyileştirilmiştir. Yol ağı genişletilmiştir. 2007'de 750 km olan otoyol uzunluğu kıyasla 2018 itibarıyla 2200 km'ye ulaşmıştır. Birkaç yerel makam, altyapıya ve genellikle kampanyalara odaklanan şehir içi mobilite ve güvenlik planları uygulamıştır. 2008 yılından itibaren teknik denetime özel sektör dahil edilmiş, ilgili ihlal ve ihlalcilerin gelirlerinin güvenlik açısından önemine göre 2018'de trafik ihlalleri için yeni bir ceza planı yapılmıştır. 2019'da yeni Ceza Kanunu'nda özellikle alkollü araç kullanmaya getirilen katı cezalar yer almıştır. Yunanistan Karayolu Güvenliği Enstitüsü (RSI) tarafından yapılan 16 yıllık çalışma boyunca, RSI 6 milyondan fazla vatandaşa ulaşmış, 150'den fazla kampanyayı hayata geçirmiş, ilk ve orta okullarda 250.000 çocuk için güvenlik ve mobilite eğitimi derslerini başlatmıştır. Yunan sürücülerin davranışı önemli ölçüde değişmiştir.

Yukarıda trafik güvenliğine ilişkin Avrupa ülkelerinden bazılarının uygulamaları, yaptırımları hakkında bilgi verilmiştir. Bu ülkelerde gerek Covid 19'dan önce, Covid 19 döneminde ve Covid 19 döneminden sonra ölümlü ve

yaralanmalı trafik kazalarında kayda değer azalma görülmüştür. Trafik kaza oranlarının düşük olduğu ülkelerdeki yaptırımlar, uygulamalar dikkate alınarak ulaşım güvenliğine katkı sağlanabilir[27]. Trafik güvenliğini sağlama konusunda birbirlerini örnek alabilen Avrupa ülkeleri[26] gibi Türkiye’nin de bu konuda iyileşme kaydeden ülkeleri örnek alması ve bu doğrultuda tedbirler, denetimler alması önemli bir adımdır trafik güvenliğini sağlama konusunda önemlidir.

3. Materyal ve Metot

Kümeleme analizi inşaatlarda [28], ahşap endüstrisinde [29], kömür madenlerinde [30], tehlikeli kimyasal taşımacılığında [31], denizyolu [32], havayolu [33] gibi ulaşım sistemlerinde meydana gelen kazaların analizinde kullanılan bir yöntemdir. Kümeleme analizinin kullanılarak Avrupa ülkeleri ile Türkiye’nin mesleki [34], çevresel [35], yaşam kalitesi [36], ticaret [37] gibi birbirinden farklı alanlarda karşılaştırıldığı birçok çalışma mevcuttur. Bu çalışmada ise trafikte heterojenliğin bulunması ve bu sayede kazanın meydana gelmesinde etkili olan temel faktörlerin belirlenmesinin kolaylaşmasını sağlayan bir yöntem olan kümeleme analizi [38] ile Avrupa Birliği ülkelerinin ve Türkiye’nin karayollarında meydana gelen trafik kazaları incelenmiştir. Avrupa Birliği ülkelerinde ve Türkiye’de meydana gelen ölümlü ve yaralanmalı trafik kazalarının incelendiği bu çalışmada belirlenen parametrelere göre incelenen ülkelerin gösterdikleri benzer özellikler ve Covid-19’un etkisi araştırılmıştır. Bu kapsamda bu kısımda çalışmada kullanılan veri ve metot hakkında bilgi aşağıda yer almaktadır.

3.1. Materyal

Avrupa ülkelerinde ve Türkiye’de meydana gelen trafik kazalarının incelendiği bu çalışmada SPSS26.0 programı kullanılarak kümeleme analizi yapılmıştır. Çalışmada analiz edilen ülkelerin “Yüz ölçümü”, “Nüfus”, “Trafik kaza sayısı”, “Trafik kazasında ölen kişi sayısı”, “Trafik kazasında ölen kişi sayısının nüfusa oranı” ve “Trafik kazasında ölen kişi sayısının trafik kaza sayısına oranı”, “Trafik kazasında yaralanan kişi sayısı”, “Trafik kazasında yaralanan kişi sayısının nüfusa oranı” ve “Trafik kazasında yaralanan kişi sayısının trafik kaza sayısına oranı” faktörleri kullanılmıştır. Ülkelerin ölümlü ve yaralanmalı trafik kazalarındaki 2018, 2019, 2020 ve 2021 yılları arasında değişim incelenerek Covid 19’un trafik kazalarındaki etkisi araştırılmıştır. Çalışma TÜİK’ten temin edilen veriye göre yapılmıştır. 2019 yılında Avrupa ülkelerine ait veride Güney Kıbrıs Rum Yönetimi (GKRY), Hollanda, Lüksemburg ve Malta’ya tüm veri ve İrlanda’ya ait yaralı sayısı ve yaralı sayısına ait oranlar, 2020 yılında Güney Kıbrıs Rum Yönetimi ve Malta’ya tüm veri ve Danimarka’ya ait yaralı sayısı ve buna bağlı oranlar, 2021 yılında Güney Kıbrıs Rum Yönetimi ve İrlanda, İsveç, Letonya, Malta ve Slovakya’ya ait yaralı sayısı ve yaralı sayısına ait oranlar bulunmamaktadır.

3.2. Metot

Kümeleme analizi, ilk olarak MacQueen tarafından önerilmiştir [39]. Kümeleme analizi ile ortak özelliklere sahip, kavramsal olarak anlamlı nesne gruplarının otomatik olarak bulunması sağlanabilmekte [40] olup aynı küme içinde benzerliğe ve farklı kümeler arasında farklılıklara sahip küme belirlenebilmektedir [41]. Kümeleme analizinde verilerin normalliği varsayımı çok önemli olmayıp, uzaklık değerlerinin normalliği yeterli olarak değerlendirilmektedir [42]. Kümeleme analizi, model oluşturmak, gruplara dayalı tahmin, hipotez testi, hipotez oluşturma, veri araştırma ve veri indirgeme gibi farklı amaçlara göre kullanılmaktadır[43]. Hiyerarşik olmayan kümeleme teknikleri, K-Ortalama tekniği, Ward’s Tekniği, Ortalama bağlantı tekniği, Tam bağlantı tekniği, Tek bağlantı tekniği, Toplama teknikleri olmak üzere Hiyerarşik kümeleme teknikleri analizlerde uygulanmaktadır[44].

Bu çalışmada SPSS26.0 paket programı yardımıyla hiyerarşik kümeleme analizi yapılmıştır. Hiyerarşik kümeleme teknikleri, kümelerin peş peşe birleştirildiği süreç olup birbirine birleştirilen gruplar bir kez birleştirildikten sonra daha sonraki adımlarda kesinlikle ayrılamazlar[45]. Ağaç diyagramları ile gösterilen hiyerarşik tekniklerin sonuçlarına ise dendrogram denmektedir [46]. Çalışmada ülkeler analiz sonucunda elde edilen dendrogram sonucuna göre kümelendirilmiştir.

4. Bulgular

Çalışmada yaralanmalı ve ölümlü trafik kazaları hiyerarşik kümeleme analizine göre ayrı ayrı kategorize edilmiş olup 2018, 2019, 2020 ve 2021 yıllarına ait kümeleme analizi sonuçları sırasıyla Tablo 3 ve Tablo 4’te verilmektedir. Dendrogram grafikleri ise EK’te yer almaktadır. Ölümlü ve yaralanmalı trafik kazaları, dendrogram grafiklerinde olan 0-25 aralığının ölçeklendirmesindeki 5 değeri referans alınarak kümelendirilmiştir. Tablo 3’te 2018-2021 yılları arasında ölümlü kazaların çalışmada belirlenen parametrelere göre kümeleme analizi sonuçları incelendiğinde Almanya tüm kümelerde diğer ülkelerden farklı sınıfta yer almıştır. Trafikte ölüm oranlarının

azalmasında önemli gelişme kaydeden ülkeler ise genelde aynı kümede yer almaktadır. Türkiye'nin ölümlü trafik kazalarında Covid 19'dan önce 2018 yılında Birleşik Krallık, Fransa, İspanya ve İtalya ile benzer özellik göstermiştir. 2019 yılında Bulgaristan, Finlandiya, Fransa, İspanya ve İtalya ile benzer özellik göstermiştir. Covid 19 etkisinin bulunduğu 2020 yılında ise diğer ülkelerden ayrı kümede yer almıştır. Covid 19 kısıtlamalarının devam ettiği 2021 yılının ilk yarısı ve kısıtlamaların tamamen kaldırıldığı 2021 yılının ikinci yarısında ölümlü trafik kazalarda ise İtalya ve Romanya ile aynı kümede yer almıştır. 2020 yılı hariç incelenen tüm yıllarda İtalya ile Türkiye aynı kümede yer almıştır.

Tablo 3. Ölümlü trafik kazalarının kümeleme analizi sonuçları

| 2018 | | | | |
|---------|------------------|------------------|-----------------|------------|
| Küme 1 | Küme 2 | Küme 3 | | |
| Almanya | Birleşik Krallık | Avusturya | Letonya | |
| | Fransa | Bulgaristan | Litvanya | |
| | İspanya | Belçika | Lüksemburg | |
| | İtalya | Çek Cumhuriyeti | Macaristan | |
| | Türkiye | Danimarka | Norveç | |
| | | Estonya | Polonya | |
| | | Finlandiya | Portekiz | |
| | | GKRY | Romanya | |
| | | Hollanda | Slovakya | |
| | | İrlanda | Slovenya | |
| | | İsveç | Yunanistan | |
| 2019 | | | | |
| Küme 1 | Küme 2 | Küme 3 | | |
| Almanya | Bulgaristan | Avusturya | Macaristan | |
| | Finlandiya | Belçika | Norveç | |
| | İspanya | Birleşik Krallık | Polonya | |
| | İtalya | Çek Cumhuriyeti | Portekiz | |
| | Türkiye | Danimarka | Romanya | |
| | | Estonya | Slovakya | |
| | | Fransa | Slovenya | |
| | | İrlanda | Yunanistan | |
| | | İsveç | | |
| | | Letonya | | |
| | | Litvanya | | |
| 2020 | | | | |
| Küme 1 | Küme 2 | Küme 3 | Küme 4 | |
| Almanya | Türkiye | Birleşik Krallık | Avusturya | Litvanya |
| | | Fransa | Belçika | Lüksemburg |
| | | İspanya | Bulgaristan | Macaristan |
| | | İtalya | Çek Cumhuriyeti | Polonya |
| | | Norveç | Danimarka | Portekiz |
| | | | Estonya | Romanya |
| | | | Finlandiya | Slovakya |
| | | | Hollanda | Slovenya |
| | | | İrlanda | Yunanistan |
| | | | İsveç | |
| | | | Letonya | |
| 2021 | | | | |
| Küme 1 | Küme 2 | Küme 3 | Küme 4 | |
| Almanya | İtalya | Birleşik Krallık | Avusturya | Litvanya |
| | Romanya | Fransa | Belçika | Lüksemburg |
| | Türkiye | İspanya | Bulgaristan | Macaristan |
| | | | Çek Cumhuriyeti | Malta |
| | | | Danimarka | Norveç |
| | | | Estonya | Poland |
| | | | Finlandiya | Portekiz |
| | | | Hollanda | Slovakya |
| | | | İrlanda | Slovenya |
| | | | İsveç | Yunanistan |
| | | | Letonya | |

Tablo 4. Yaralanmalı trafik kazalarının kümeleme analizi sonuçları

| 2018 | | | | |
|---------|------------------|-----------------|------------------|------------|
| Küme 1 | Küme 2 | Küme 3 | Küme 4 | |
| Almanya | Birleşik Krallık | İtalya | Avusturya | Letonya |
| | İspanya | Türkiye | Belçika | Litvanya |
| | | | Bulgaristan | Lüksemburg |
| | | | Çek Cumhuriyeti | Macaristan |
| | | | Danimarka | Norveç |
| | | | Estonya | Polonya |
| | | | Finlandiya | Portekiz |
| | | | Fransa | Romanya |
| | | | GKRY | Slovakya |
| | | | Hollanda | Slovenya |
| | | | İrlanda | Yunanistan |
| | | | İsveç | |
| 2019 | | | | |
| Küme 1 | Küme 2 | Küme 3 | Küme 4 | |
| Almanya | Bulgaristan | Finlandiya | Avusturya | Norveç |
| | İtalya | İspanya | Belçika | Polonya |
| | Türkiye | | Birleşik Krallık | Portekiz |
| | | | Bulgaristan | Romanya |
| | | | Çek Cumhuriyeti | Slovakya |
| | | | Danimarka | Slovenya |
| | | | Estonya | Yunanistan |
| | | | Fransa | |
| | | | İsveç | |
| | | | Letonya | |
| | | | Litvanya | |
| | | | Macaristan | |
| 2020 | | | | |
| Küme 1 | Küme 2 | Küme 3 | | |
| Almanya | Birleşik Krallık | Avusturya | Letonya | |
| Norveç | Fransa | Belçika | Litvanya | |
| Türkiye | İspanya | Bulgaristan | Lüksemburg | |
| | İtalya | Çek Cumhuriyeti | Polonya | |
| | | Danimarka | Portekiz | |
| | | Estonya | Romanya | |
| | | Finlandiya | Slovakya | |
| | | İrlanda | Slovenya | |
| | | İsveç | Yunanistan | |
| | | Macaristan | | |
| 2021 | | | | |
| Küme 1 | Küme 2 | Küme 3 | | |
| Almanya | Birleşik Krallık | Avusturya | Litvanya | |
| İtalya | Fransa | Belçika | Lüksemburg | |
| Romanya | İspanya | Bulgaristan | Macaristan | |
| Türkiye | | Çek Cumhuriyeti | Malta | |
| | | Danimarka | Norveç | |
| | | Estonya | Poland | |
| | | Finlandiya | Portekiz | |
| | | Hollanda | Slovakya | |
| | | İrlanda | Slovenya | |
| | | İsveç | Yunanistan | |
| | | Letonya | | |

Tablo 4’te 2018-2021 yılları arasında yaralanmalı kazaların çalışmada belirlenen parametrelere göre kümeleme analizi sonuçları incelendiğinde kümelerde yer alan ülkelerin ölümlü trafik kazalarından farklılık gösterdiği anlaşılmaktadır. Yaralanmalı trafik kazalarında Türkiye, Covid 19 kısıtlamalarının olmadığı 2018 yılında İtalya ile, 2019 yılında ise Türkiye, İtalya ve Bulgaristan ile aynı kümelere yer almıştır. Fakat Covid 19 kısıtlamalarının olduğu 2020 yılına gelince Türkiye Almanya ve Norveç ile aynı kümede yer almıştır. İlk yarısında kısıtlamaların devam ettiği, ikinci yarısında ise kısıtlamaların tamamen kaldırıldığı 2021 yılında ise Türkiye, Almanya, İtalya ve Romanya ile aynı kümede yer almıştır.

5. Sonuç ve Tartışma

AB’de ülke yatırımlarının %40’ı ulaştırma sektörünü oluşturmaktadır. Zaman içinde ulaşımda artan bir talep oluşmuş ve trafikte meydana gelen sıklıkla ulaştırma konusunda yeni düzenlemelere ve politikalara gerek duyulmuştur [47]. Trafik güvenliğine ilişkin Avrupa ülkeleri önemli gelişmeler kaydetmiştir. Yayınlanan son verilerde Avrupa Birliği’nde ölümlü trafik kaza sayısı son 20 yıl içerisinde yarıya düşmüş olup Avrupa Ulaşım Güvenliği Konseyi (ETSC) rakamları 2001 yılında AB (Avrupa Birliği) yollarında 55 binin üzerinde insanın hayatını kaybettiğini gösterirken 2018 yılında tüm AB genelinde 25 binin üzerinde insanın AB yollarında hayatını kaybettiğini belirtmektedir. AB genelinde Baltık ülkelerinin 15-20 yıllık zaman kapsamında karayolu ölümlerini azaltma konusunda büyük iyileşme oranı kaydetmesine rağmen tüm iyileşme göstergelerine sahip olan Letonya ve Macaristan bir milyon kişi başına 77 ölüm ile hala AB’nin bu alandaki en kötü durumdaki ülkeler arasındaki yerlerini korumaktadır. Daha kötü durumda olan sadece iki ülke olup bu ülkeler ise sırasıyla milyon kişi başına 87 ölümlü kaza ile Bulgaristan ve 96 ölümlü kaza ile Romanya’dır. Türkiye’de trafik kazalarında ise bir milyon kişi başına 81 ölümün meydana geldiği bilinmektedir [6].

Tablo 1 ve Tablo 2’de incelenen ülkeler arasında en fazla nüfusa sahip olan Türkiye olup bin kişiye düşen otomobil sayısı sıralamasında ise en alt sırada Türkiye yer almaktadır. Türkiye’de araç sayısı düşük olmasına rağmen trafikte kaza sayısı yüksek bulunmuştur. Ayrıca trafik kazaları sonucunda ölü sayısı ve yaralı sayısı da yüksektir. Nüfus ve otomobil sayısı hem oransal hem de sayı bakımında dikkate alındığında Türkiye’de ulaşım güvenliği diğer ülkelere nazaran dikkat çekici boyuttadır. Kümeleme analizi sonuçları incelendiğinde ise Türkiye genel itibari ile Avrupa ülkelerinde daha fazla trafik kazası meydana gelen ülkelerle aynı grupta yer almıştır. AB ülkelerinde Covid 19 öncesinde, Covid 19 döneminde ve Covid 19 dönemi sonrasında ölümlü ve yaralanmalı trafik kazalarında önemli azalış olmuştur. Bu duruma tedbirlerin, yaptırımların uygulanmasının etkili olduğu düşünülmektedir. Türkiye’de ise ölümlü ve yaralanmalı trafik kazalarında büyük oranda bir artış söz konusudur [6]. Bu sebeple Türkiye’de meydana gelen ölümlü ve yaralanmalı trafik kaza oranlarında artış olması, bu konu ile ilgili yeni çalışmaların, yaptırımların, uygulamaların ve denetimlerin hayata geçmesi için gereklidir.

Çalışmada incelenen ülkeler trafik kazaları bakımından incelendiğinde Türkiye’de bin kişiye düşen araç sayısının düşük olmasına ve Türkiye’nin nüfusunun yüksek olmasına rağmen Türkiye’de daha fazla trafik kazasının meydana gelmesi ve bu kazalarda ölen ve yaralanan kişi sayısının yüksek olması ile Türkiye’nin genel anlamda ulaşım güvenliği konusunda kendini geliştirmesi gerektirdiği sonucuna ulaşılmaktadır. Türkiye’nin ulaşım güvenliğini sağlamaya yönelik bu çalışmada Avrupa ülkelerinde ve Türkiye’de meydana gelen trafik kazaları üzerinde Covid 19 kısıtlamalarının farklı etkilerinin olduğu anlaşılmaktadır. Kümeleme analizi sonuçlarında ölümlü ve yaralanmalı kazalarda farklı yıllarda “Almanya”, “Birleşik Krallık”, “Bulgaristan”, “Fransa”, “Finlandiya”, “İspanya”, “İtalya”, “Norveç” ve “Romanya”, “Türkiye” ile benzer özellik gösteren ülkeler olarak bulunmuştur. Bu ülkeler arasında İtalya sadece 2020 yılında ölümlü ve yaralanmalı trafik kazaların her ikisinde de Türkiye ile aynı kümede yer almamıştır. Diğer yıllarda hem ölümlü hem de yaralanmalı trafik kazalarında Türkiye ile aynı kümede bulunmuştur. Bu sebeple belirlenen faktörlere göre uygulanan kümeleme analizi sonucunda incelenen ülkeler arasında trafik kazaları bakımından en fazla benzerlik İtalya ve Türkiye arasında bulunmuştur. İtalya bin kişiye düşen araç sayısı bakımından Tablo 2’de Lüksemburg’dan sonra ikinci sırada yer almaktadır. Kümeleme analizine bu faktör dahil edilmemiştir. Kümeleme analizi farklı parametreler ile farklı sonuçlar doğurabilir. Bu sebeple bu çalışmanın kısıtlı belirli yıllarda belirli faktörlere göre yapılmış olmasıdır. Çalışmadaki belirlenen zaman aralığı ve faktörler ile elde edilen kümeleme analizi sonucunda en dikkat çekici bulgu yaralanmalı trafik kazalarında Covid 19 kısıtlamalarının olduğu 2020 yılında trafikte güvenli ulaşımda iyi durumda olan Norveç ile Türkiye’nin aynı kümede yer almasıdır. Bu çalışmada elde edilen böyle bir sonuç ile 2020 yılına ait Türkiye’nin trafik özelliklerinin detaylı incelenerek ulaşım güvenliğinin daha iyi seviyeye ulaşmasına katkı sağlanabilir. Çalışmada sunulan Avrupa ülkelerinin yürüttükleri politikalar sonucunda trafik kazalarındaki değişimler bu politikaların ne kadar başarıya ulaştığı konusunda fikir verebilmektedir. Avrupa ülkelerinde 2022-2023 yılları arasında %1 oranında trafik kazalarında ölüm sayısında azalma gözlenmiş ve Finlandiya- 2024 PIN Yol Güvenliği Ödülü sahibi olmuştur [48]. Ulaşım güvenliğini sağlama konusunda doğru uygulamaları örnek alan Finlandiya, kara yolunda elde ettiği bu iyileşme ile Türkiye ve diğer Avrupa ülkeleri için iyi bir örnek olmaktadır. Türkiye’de ulaşım güvenliği konusunun önceliklendirilmesinin, iyileşme kaydeden ülkelerin politikalarının dikkate alınmasının ve bu doğrultuda tedbirlerin hayata geçirilmesinin ve yaptırımların uygulanmasının fayda sağlaması beklenmektedir.

Bu çalışmada kümeleme analizi, ülkelerin yüz ölçümü, nüfus, trafik verisi gibi sadece sayısal veri kullanılarak uygulanmıştır. Fakat uluslararası literatürde konu ile ilgili zamansal-mekânsal analiz yapıldığı [49, 50, 51], yaş, cinsiyet [52] gibi farklı parametrelerin kullanıldığı çalışmalar da mevcuttur. Kümeleme analizinin uygulanmasının yanı sıra zamansal-mekânsal analizlerin yapıldığı, farklı faktörlerin incelendiği çalışmalar ile kazanın meydana geldiği konum, zaman, incelenen faktörlerin ilişkisi tespit edilerek gelecekte farklı çalışmalar hazırlanabilir ve bu çalışmalar doğrultusunda ulaşımda güvenlik daha üst seviyeye çıkabilir.

Kaynakça


- [1] WHO, Road Traffic Injuries. 2023.
- [2] Shafabakhsh, G. A., Famili, A. Bahadori, M. S. 2017. GIS-Based Spatial Analysis of Urban Traffic Accidents: Case Study in Mashhad, Iran. *Journal of Traffic and Transportation Engineering (English edition)*, 4(3): 290-299.
- [3] Sharma, B. R. 2008. Road Traffic Injuries: A Major Global Public Health Crisis. *Public Health*; 122(12): 1399-1406.
- [4] Biondi, B., Mazzocchi, M., 2024. An Empirical Analysis of The Effect of Economic Activity and COVID-19 Restrictions on Road Traffic Accidents in Italy. *Socio-Economic Planning Sciences*, 92, 101846.
- [5] Bucshházy, K., Matuchová, E., Zúvala, R., Moravcová, P., Kostíková, M., Mikulec, R. 2020. Human Factors Contributing to The Road Traffic Accident Occurrence. *Transportation Research Procedia*, 45, 555-56.
- [6] Euronews, 2019. <https://tr.euronews.com/2019/08/21/abde-olumlu-trafik-kazalari-son-20-yilda-yariya-duserken-turkiye-de-yuzde-30-artti> Erişim Tarihi: 18.08.2024
- [7] Islam, S., Huq, A. S., Iqra, S. H. Tomal, R. S. 2023. Impacts of COVID-19 Pandemic Lockdown on Road Safety in Bangladesh. *Sustainability*, 15(3): 2675.
- [8] Kınacı, H., M.G. Ünsal, and R. Kasap, A Closer look at 2019 Novel Coronavirus (COVID 19) Infections in Turkey Using Time Series Analysis & Efficiency Analysis. *Chaos, Solitons & Fractals*, 2021. 143: p. 110583.
- [9] Ndobegang, N. 2022. National Assessment of The Impacts due to COVID-19 Mandates on Roadway Traffic Volumes: State-by-State Analysis and Vehicular Classification Changes in Ohio. Ohio University.
- [10] Barnes, S. R., Beland, L. P., Huh, J., Kim, D. 2020. The Effect Of Covid-19 Lockdown On Mobility and Traffic Accidents: Evidence from Louisiana (Workingpaper). GLO Discussion Paper.
- [11] Karadla, L., Li, W. 2021. Analyzing Effects of The Covid-19 Pandemic on Road Traffic Safety: The Cases of New York City, Los Angeles, and Boston.
- [12] Ferenchak, N. N. 2023. Impacts of COVID-19 on Motor Vehicle Crash Frequency and Severity by Functional Classification and Land Use Context. *Transactions on Transport Sciences*, 14(3).
- [13] Çelik, Ş. 2013. Kümeleme Analizi ile Sağlık Göstergelerine Göre Türkiye'deki İllerin Sınıflandırılması. *Doğuş Üniversitesi Dergisi*, 14(2): 175-194.
- [14] Murat, Y. Ş., Şekerler, A. 2009. Trafik Kaza Verilerinin Kümelene Analizi Yöntemi ile Modellenmesi. *Teknik Dergi*, 20(98): 4759-4777.
- [15] Atalay, A., Tortum, A. 2010. Türkiye'deki İllerin 1997-2006 Yılları Arası Trafik Kazalarına Göre Kümeleme Analizi. *Pamukkale University Journal of Engineering Science*, 16(3).
- [16] Tortum, A., et al., Clustering Analysis of The Districts in Erzurum for Traffic Accidents Between 2002 and 2007. *Scientific Research and Essays*, 2011. 6(13): p. 2850-2857.
- [17] Söylemez, İ., Doğan, A. ve Özcan, U. (2016). Trafik Kazalarında Birliktelik Kuralı Analizi: Ankara İli Örneği. *Ege Academic Review*, 16.
- [18] Atalay, A., Bircik, Ö.F. 2019. Kentiçi Ana Toplu Taşıma Sistemlerinin Kümeleme Analizi Yöntemiyle İncelenmesi: Erzurum Örneği. 13. Ulaştırma Kongresi.
- [19] Yuan, Q., Li, X., Wang, C., Li, Y., Gao, Y. Cluster and Factor Analysis on Data of Fatal Traffic Crashes in China. In 2017 4th International Conference on Transportation Information and Safety (ICTIS) 2017. IEEE.
- [20] Taamneh, M., Taamneh, S. Alkheder, S. 2017. Clustering-Based Classification of Road Traffic Accidents Using Hierarchical Clustering and Artificial Neural Networks. *International Journal of Injury Control and Safety Promotion*, 24(3): 388-395.
- [21] Budiawan, W., Purwanggono, B. 2018. Clustering Analysis of Traffic Accident in Semarang City. In E3S Web of Conferences; EDP Sciences.

- [22] Li, Z., Chen, C., Ci, Y., Zhang, G., Wu, Q., Liu, C., Qian, Z. 2018. Examining Driver Injury Severity in Intersection-Related Crashes Using Cluster Analysis and Hierarchical Bayesian Models. *Accident Analysis & Prevention*, 120: 139-151.
- [23] Bolat, H., Yücesan, M., Utku, A. 2022. Trafik Kazalarının Makine Öğrenmesi Yöntemleriyle Analizi ve Tahmini: Kahramanmaraş İçin Örnek Bir Çalışma. *International Journal of Pure and Applied Sciences*, 8(2): 490-506.
- [24] TUIK, Traffic Accidents. 2024. Erişim Tarihi: 10.08.2024.
- [25] Trafik Dairesi Güvenliği Başkanlığı, Trafik Kazaları Özeti. 2023. <https://www.kgm.gov.tr/sayfalar/kgm/sitetr/trafik/trafikkazalariozeti.aspx> Erişim Tarihi: 15.11.2024
- [26] Council, E.T.S., The Road Safety Performance Index. PIN.
- [27] Lund, I. O., Rundmo, T. 2009. Cross-cultural Comparisons of Traffic Safety, Risk Perception, Attitudes And Behaviour. *Safety Science*; 47(4): 547-553.
- [28] Lombardi, M., M. Fagnoli, and G. Parise, Risk Profiling from The European Statistics on Accidents at Work (ESAW) Accidents' Databases: A Case Study in Construction Sites. *International Journal of Environmental Research and Public Health*, 2019. **16**(23): p. 4748.
- [29] Palamara, F., F. Piglion, and N. Piccinini, Self-Organizing Map and Clustering Algorithms for The Analysis of Occupational Accident Databases. *Safety science*, 2011. **49**(8-9): p. 1215-1230.
- [30] Miao, D., et al., Research on The Classification And Control of Human Factor Characteristics of Coal Mine Accidents Based on K-Means Clustering Analysis. *International Journal of Industrial Ergonomics*, 2023. **97**: p. 103481.
- [31] Deng, F., et al., Hazardous Chemical Accident Prevention Based on K-Means Clustering Analysis of Incident Information. *IEEE Access*, 2020. **8**: P. 180171-180183.
- [32] Le Blanc, L.A. and C.T. Rucks, A Cluster Analysis of Vessel Accidents. 2020.
- [33] Čokorilo, O., M. De Luca, and G. Dell'Acqua, Aircraft Safety Analysis Using Clustering Algorithms. *Journal of Risk Research*, 2014. **17**(10): p. 1325-1340.
- [34] Akay, A.O., et al., Evaluation of Occupational Accidents in Forestry in Europe and Turkey by K-Means Clustering Analysis. *Turkish Journal of Agriculture and Forestry*, 2021. **45**(4): p. 495-509.
- [35] Açar, T.S. and N.A. Öz, The Determination of Optimal Cluster Number by Silhouette Index at Clustering of The European Union Member Countries and Candidate Turkey by Waste Indicators. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 2020. **26**(3): p. 481-487.
- [36] AKTAŞ, M.T., Comparing EU Countries, Turkey and Macedonia via Clustering Analysis for Quality of Life Indicators. *Economic Issues: Crises, Finance and Agriculture*. London IJOPEC Publication, 2017: p. 76-104.
- [37] 20. Gunduz, F.F., S. Gunduz, and C.O. Dolekolu, Cluster Analysis of The EU Countries Which Turkey Has Textile Trade. *International Journal of Economics and Financial Issues*, 2018. **8**(5): p. 332-341.
- [38] De Ona, J., et al., Analysis of Traffic Accidents on Rural Highways Using Latent Class Clustering and Bayesian Networks. *Accident Analysis & Prevention*, 2013. **51**: p. 1-10.
- [39] Taştan, S., Arıç, K. H., Moujahid, S. 2023. APEC Ülkelerinin Ulaştırma Altyapılarının Kümeleme Analizi ile Karşılaştırılması. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 24(3): 393-402.
- [40] Wu, J. 2012. Cluster Analysis and K-means clustering: An introduction. *In Advances in K-Means Clustering: A Data Mining Thinking*: 1-16.
- [41] Sinaga, K. P. Yang, M. S. 2020. Unsupervised K-Means Clustering Algorithm. *IEEE access*; 8:80716-80727.
- [42] Tatlıdil, H. 1992. Uygulamalı Çok Değişkenli İstatistiksel Analiz. Engin Yayınları.
- [43] Ball, G.H. 1970. Classification Analysis, Menlo Park, Calif.: Stanford Research Institute.
- [44] Çakmak, Z., Uzgören, N., Keçek, G. 2005. Kümeleme Analizi Teknikleri ile İllerin Kültürel Yapılarına Göre Sınıflandırılması ve Değişimlerinin İncelenmesi. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (12).
- [45] Fırat, S.Ü. 1997. Kümeleme analizi: İstihdamın Sektörel Yapısı Açısından Avrupa Ülkelerinin Karşılaştırılması. *İÜ Sosyal Bilimler Dergisi*. 3(2): p. 50-59.


- [46] Lorr, M. 1983. Cluster Analysis for Social Scientists.
- [47] Çelik, C. 2007. AB Ulaştırma Politikasına Uyum Sürecinde Türkiye'de Kara Ulaşımı Trafik Güvenliği (Doctoral dissertation, Sosyal Bilimler Enstitüsü).
- [48] Road Deaths in The European Union – Latest Data. <https://etsc.eu/euroadsafetydata/> Erişim Tarihi: 24.12.2024
- [49] Anderson, T.K., Kernel Density Estimation and K-Means Clustering to Profile Road Accident Hotspots. Accident Analysis & Prevention, 2009. **41**(3): p. 359-364.
- [50] Hazaymeh, K., A. Almagbile, and A.H. Alomari, Spatiotemporal Analysis of Traffic Accidents Hotspots Based on Geospatial Techniques. ISPRS International Journal of Geo-Information, 2022. **11**(4): p. 260.
- [51] Le, K.G., P. Liu, and L.-T. Lin, Traffic Accident Hotspot Identification By Integrating Kernel Density Estimation and Spatial Autocorrelation Analysis: A Case Study. International Journal of Crashworthiness, 2022. **27**(2): p. 543-553.
- [52] Hu, L., et al., A Study on Correlation of Traffic Accident Tendency with Driver Characters Using in-Depth Traffic Accident Data. Journal of Advanced Transportation, 2020. **2020**(1): p. 9084245.

EK


2018 YILI ÖLÜMLÜ TRAFİK KAZALARI DENDROGRAM GRAFİĞİ




2018 YILI YARALANMALI TRAFİK KAZALARI DENDROGRAM GRAFİĞİ




2019 YILI ÖLÜMLÜ TRAFİK KAZALARI DENDROGRAM GRAFİĞİ




2019 YARALANMALI TRAFİK KAZALARI DENDROGRAM GRAFİĞİ




2020 YILI ÖLÜMLÜ TRAFİK KAZALARI DENDROGRAM GRAFİĞİ




2020 YILI YARALANMALI TRAFİK KAZALARI DENDROGRAM GRAFİĞİ



2021 YILI ÖLÜMLÜ TRAFİK KAZALARI DENDROGRAM GRAFİĞİ



2021 YILI YARALANMALI TRAFİK KAZALARI DENDROGRAM GRAFİĞİ



Endemik *Lomelosia pseudograminifolia* (Hub.-Mor.) Greuter & Burdet'nin Antioksidan ve Antibakteriyel Aktivite Yönünden İncelenmesi

Ceren Ilgın Koç¹, Sevil Albayrak^{*1}, Ahmet Aksoy²

^{*1}Erciyes Üniversitesi Fen Fakültesi Biyoloji, KAYSERİ

²Akdeniz Üniversitesi Fen Fakültesi Biyoloji, KAYSERİ

(Alınış / Received: 05.11.2024, Kabul / Accepted: 06.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Anahtar Kelimeler

Lomelosia pseudograminifolia,
Antibakteriyel Aktivite,
Antioksidan Aktivite,
Fenolik,
Flavonoid

Öz: Bu çalışmada, *Lomelosia pseudograminifolia* (Hub.-Mor.) Greuter & Burdet (Caprifoliaceae)'dan elde edilen metanollü ekstrenin antioksidan ve antibakteriyel aktivitesinin belirlenmesi amaçlanmıştır. Ekstredeki toplam fenolik ve flavonoid madde miktarları sırasıyla Folin-Ciocalteu ve alüminyum klorür kolorimetrik yöntemleri ile gerçekleştirilmiştir. Metanollü ekstrenin antioksidan aktivitesi fosfomolibdenyum, 2,2-difenil-1-pikrilhidrazil radikal süpürücü (DPPH), ferrik-demir indirgeyici güç (FRAP) ve bakır iyon indirgeyici antioksidan kapasite (CUPRAC) yöntemi olmak üzere dört farklı yöntem kullanılarak test edilmiştir. Metanollü ekstrenin on üç bakteriye karşı antibakteriyel aktivitesi agar difüzyon yöntemi kullanılarak araştırılmıştır. Sonuçlar metanollü ekstrenin yüksek fenolik ve flavonoid madde miktarı ile orta derecede antioksidan aktivite gösterirken, test edilen bakterilere karşı antibakteriyel aktiviteye sahip olmadığını göstermiştir. Çalışma sonuçları, *L. pseudograminifolia* ekstresinin gıda, tıp ve eczacılık endüstrilerinde alternatif doğal antioksidan olarak kullanılabilirliğini ortaya koymaktadır.

Investigation of Antioxidant and Antibacterial Activity of Endemic *Lomelosia pseudograminifolia* (Hub.-Mor.) Greuter & Burdet

Keywords

Lomelosia pseudograminifolia,
Antibacterial Activity,
Antioxidant Activity,
Flavonoid,
Phenolic

Abstract: In the study, determination of the antioxidant and antibacterial activities of methanol extract from *Lomelosia pseudograminifolia* (Hub.-Mor.) Greuter & Burdet (Caprifoliaceae) was aimed. The total phenolic and total flavonoid contents in the extract were determined by Folin-Ciocalteu and aluminum chloride colorimetric assays, respectively. The antioxidant activity of the methanol extract was tested using four different methods including phosphomolybdenum, 2,2-diphenyl-1-picrylhydrazyl radical scavenging (DPPH), ferric-ion reducing power (FRAP) and cupric ions reducing antioxidant capacity (CUPRAC) methods. The antibacterial activity of methanol extract was investigated against thirteen bacteria used agar well-diffusion assay. Results showed that the methanol extract had moderate antioxidant activity with high phenolic and flavonoid content while had no antibacterial activity against all tested bacteria. Our study reveals that *L. pseudograminifolia* extract may be used as alternative natural antioxidant agent in the food, medicine and pharmacy industries.

1. Giriş

Oksidatif stres, antioksidanların etkisiyle karşı konulamayan reaktif oksijen türlerinin aşırı üretimi ve aynı zamanda hücre redoks dengesinin bozulması olarak tanımlanmaktadır [1]. Hidroksil radikal ($\cdot\text{OH}$), hidrojen peroksit (H_2O_2), süperoksit ($\text{O}_2 \cdot^-$), nitrik oksid ($\text{NO}\cdot$) ve peroksinitrit ($\text{ONOO}\cdot$) gibi reaktif oksijen türleri (ROT) ve reaktif nitrojen türleri (RNT) hücrede oksidatif stresin başlıca kaynaklarıdır. Protein, lipid ve DNA'ya zarar verirler. Oksidatif DNA hasarı kanser, yaşlanma, Alzaymır ve Parkinson gibi nörodejeneratif hastalıklar ve arteroskleröz

gibi kardiyovasküler hastalıkların nedeni olarak gösterilmektedir. Ayrıca, kalp krizi ve inme ile sonuçlanan hücre ölümü ve doku hasarının başlıca sebebidir. Bu nedenle, ROT ve RNT'nin neden olduğu oksidatif stresin önlenmesi hastalıkların tedavisi için önemli etkilere sahiptir [2].

Biyolojik antioksidan, oksitlenebilir bir substrata kıyasla daha düşük konsantrasyonda, substratın oksidasyonunu geciktirebilen veya önleyebilen herhangi bir bileşik olarak tanımlanmaktadır [1]. Antioksidanlar hücrelerdeki oksidatif stresi azaltır ve bu nedenle kanser, kardiyovasküler hastalıklar ve enflamatuar hastalıklar dahil olmak üzere birçok hastalığın tedavisinde faydalıdır. Bazı araştırmacılar, dünyadaki bitki türlerinin üçte ikisinin tıbbi değeri olduğunu öne sürmektedir. Özellikle de birçok tıbbi bitki büyük antioksidan potansiyele sahiptir. Bütillenmiş hidroksitoluen (BHT) ve bütillenmiş hidroksilanisol (BHA) gibi sentetik antioksidanlar günümüzde gıda katkı maddesi olarak kullanılmaktadır ve birçok bitki türü bu sentetiklerle benzer antioksidan potansiyele sahiptir. Literatür, bu doğal antioksidanların gıda işleme endüstrisinde ve koruyucu tıpta kullanımı için sentetik antioksidanlara potansiyel olarak yan etkisiz bir alternatif oluşturduğunu ortaya koymaktadır [3].

Gıda kaynaklı hastalıkların çoğu mikrobiyal patojenlerle kontamine olmuş gıdaların tüketilmesinden kaynaklanmaktadır. Gıda zehirlenmesi ve tüketici sağlığı gibi konularla sıkı sıkıya ilişkili olması nedeniyle, gıda ile ilgili bu tür patojenlerin etkisini ortadan kaldırmaya ve işlenmiş gıdaların raf ömrünü uzatmaya yönelik birçok çalışma bulunmaktadır. Ayrıca nitrat, benzoat, sülfat, sorbat, formaldehit gibi sentetik gıda koruyucuları da yaşamı tehdit eden yan etkileriyle bilinmektedir. Bu sağlık riskleri doğal gıda koruyucularının kullanılmasını zorunlu kılmaktadır. Çeşitli bitki ve bitkisel ekstraktların antioksidan, antimikrobiyal, anti-diyabetik, anti-kanserojen, aroma verici ve repellent gibi davranabileceği ve tüm bunların gıda üretiminde çoklu uygulanabilirliğe yol açan özellikler olduğu gösterilmiştir [4].

Lomelosia (Caprifoliaceae) 7'si endemik olmak üzere 22 takson (21 tür) içermektedir. Moleküler filogenetik analizler ve morfolojik çalışmalar sonucu *Scabiosa* L. (Dipsacaceae) cinsine ait bazı türler *Lomelosia* Raf. cinsine ve Caprifoliaceae ailesine aktarılmıştır [5]. *Scabiosa* cins ismi ülkemizde genellikle "uyuzotu" olarak bilinmesine rağmen, son yıllarda "yazı süpürgesi, zivan, kavurotu, puk, gıcıkotu" olarak da anılmaktadır [6,7]. *Scabiosa* cinsi halk arasında çeşitli kullanımları ile dikkat çekmektedir. Bitkinin kökü solunum yolları ile ilgili şiddetli hastalıkların başlangıç devresinde ekspektoran özelliğinden dolayı kullanılır. Gripte, bronşitte sekresyon artırıcı özelliği vardır [8]. *Scabiosa* cinsinin anti-inflamasyon, antioksidan ve immün ve kardiyovasküler sistem güçlendirici özelliklerinin olduğu bildirilmiştir [9].

Daha önceki çalışmalarda çeşitli *Scabiosa* taksonlarının antioksidan aktiviteye sahip olduğu kaydedilmiştir. *S. tschilliensis* ve *S. comosa* [10], *S. arenaria* [11], *S. stellata* [12], *S. tschilliensis* [13], *S. argentea* [14] ve *S. sicula* [15]'nin antioksidan aktiviteye sahip olduğu bildirilmiştir. *S. columbaria* [16], *S. hymettia* [17], *S. arenaria* [18], *S. stellata* [19], *S. olivieri* [20]'den elde edilen ekstraktların antibakteriyel aktiviteye sahip olduğu rapor edilmiştir. Ancak yapılan literatür taramasında, *Lomelosia pseudograminifolia* (Hub.-Mor.) Greuter & Burdet (Caprifoliaceae) türünün antioksidan ve antibakteriyel aktivitesi ile ilgili çalışmaya rastlanılmamıştır. Bu nedenle, bu çalışma ile *L. pseudograminifolia*'nın toprak üstü kısımlarından elde edilen metanollü ekstrenin toplam fenolik ve flavonoid madde miktarının, antioksidan ve antibakteriyel aktivitesinin belirlenmesi amaçlanmaktadır.

2. Materyal ve Metot

2.1. Araştırma Materyalinin Temini

Türkiye'de doğal olarak yayılış gösteren endemik *L. pseudograminifolia* (Hub.-Mor.) Greuter & Burdet (Caprifoliaceae) taksonu 2019 yılı Temmuz ayında Eskişehir ilinin Alpu-Mihalıççık yolundan toplanmıştır (902 m). Toplanan bitkinin tayini Akdeniz Üniversitesi Öğretim Üyesi Prof. Dr. Ahmet AKSOY tarafından gerçekleştirilmiştir. Toplanan bitki örnekleri Akdeniz Üniversitesi, Fen Fakültesi, Biyoloji Bölümü Herbaryumu'nda (AKDU) muhafaza edilmektedir (Toplama no: Aksoy 3065).

2.2. Araştırma Materyalinin Ekstraksiyonu

Çiçeklenme evresinde toplanan *L. pseudograminifolia* örneklerinin toprak üstü kısımları oda sıcaklığında gölgede kurutulduktan sonra öğütülüp toz haline getirilmiştir. Toz halindeki bitki maserasyon yöntemi ile metanol kullanılarak ekstrakte edilmiştir. Daha sonra, solvent-ekstre karışımından Rotary Evaporatör ile 40 °C'de solvent tamamen uzaklaştırılmıştır. Geriye kalan ekstre, hassas terazide tartılarak ekstre verimi hesaplanmıştır. Elde edilen ekstre daha sonraki çalışmalar için renkli ve kapaklı cam şişelerde kullanılmaya kadar buzdolabında saklanmıştır [21].

2.3. Toplam Fenolik Madde Miktarının Belirlenmesi

Toplam fenolik madde miktarı Folin-Ciocalteu kolorimetrik yöntemi ile belirlenmiştir [22]. Hazırlanan ekstre çözeltilerinden 40 µL deney tüplerine aktarılmıştır. Ekstrelerin üzerine sırasıyla 2.4 mL distile su, 200 µL Folin-Ciocalteu ayırıcı, 600 µL sodyum karbonat (%20 Na₂CO₃) ve 760 µL distile su eklenerek vorteks ile karıştırılmıştır. Reaksiyon karışımı oda sıcaklığında 2 saat inkübasyona bırakıldıktan sonra 765 nm dalga boyundaki absorbans değerleri köre karşı okunmuştur. İşlem üç tekrar şeklinde uygulanmıştır. Sonuçlar gallik asitle elde edilen kalibrasyon eğrisinden hesaplanarak, gallik asit eşdeğeri olarak (mg GAE/g ekstre) belirtilmiştir.

2.4. Toplam Flavonoid Madde Miktarının Belirlenmesi

Toplam flavonoid madde miktarı Alüminyum Klorid Kolorimetrik yöntemi ile belirlenmiştir [23]. Ekstre (0.5 mL) sırasıyla 0.1 mL %10 alüminyum klorür ve 0.1 mL 1M potasyum asetat ile karıştırılmıştır. Reaksiyon karışımı oda sıcaklığında 30 dakika inkübasyona bırakıldıktan sonra 415 nm dalga boyundaki absorbans değerleri okunmuştur. İşlem üç tekrar şeklinde uygulanmıştır. Sonuçlar kersetin ile elde edilen kalibrasyon eğrisinden hesaplanarak, kersetin eşdeğeri olarak (mg QE/g ekstre) belirtilmiştir.

2.5. Toplam Antioksidan Aktivitenin Belirlenmesi

Toplam antioksidan aktivite fosfomolibdenyum yöntemi ile değerlendirilmiştir [24]. Bu yöntem ortamda bulunan Mo (VI)'ün ortama konan indirgeyici ajan tarafından Mo (V)'e indirgenmesi sonucu oluşan yeşil rengin spektrofotometrik olarak ölçümü esasına dayanmaktadır. Hazırlanan ekstre çözeltilerinden 0.4 mL deney tüplerine aktarılmıştır. Ekstrelerin üzerine 4 mL belirteç çözeltisi eklenerek vorteks ile karıştırılmıştır. Karışım 95 °C'de 90 dakika inkübasyona bırakılmıştır (Belirteç Çözeltisi: 0.6 M sülfirik asit, 28 mM sodyum fosfat ve 4 mM amonyum molibdat). Oluşan yeşil renkli karışımın absorbans değeri 695 nm dalga boyunda köre karşı okunmuştur. İşlem üç tekrar şeklinde uygulanmıştır. Sonuçlar askorbik asitle elde edilen kalibrasyon eğrisinden hesaplanarak, askorbik asit eşdeğeri (mg AAE/g ekstre) olarak belirlenmiştir.

2.6. Antiradikal Aktivitenin Belirlenmesi

Antiradikal aktivite DPPH (2,2-difenil-1-pikrilhidrazil) yöntemine göre belirlenmiştir [25]. Yöntem radikalın karakteristik mor renginde meydana gelen renk değişikliğinin spektrofotometre ile ölçülmesi esasına dayanmaktadır. Hazırlanan ekstre çözeltilerinden (0.1-2 mg/mL) alınarak deney tüplerine aktarılmıştır. Üzerlerine 0.1mM DPPH radikalının metanol ile hazırlanan çözeltisi eklendikten sonra vorteks ile karıştırılıp oda sıcaklığında 30 dakika bekletilmiştir. Karışımların absorbans değerleri 517 nm dalga boyunda okunmuştur. Ölçümler üç kez tekrarlanmıştır ve sonuçların ortalaması alınmıştır. Serbest radikal temizleyici etki DPPH absorpsiyonunun % inhibisyonu olarak belirtilmiştir. Bu değer aşağıdaki formüle göre hesaplanmıştır:

$$\% \text{Inhibition} = \frac{(\text{Abs}_{\text{control}} - \text{Abs}_{\text{sample}})}{\text{Abs}_{\text{control}}} \times 100 \quad (1)$$

% 50 inhibisyona neden olan konsantrasyon (IC₅₀) belirlenmiştir. Aynı işlemler pozitif kontrol olarak kullanılan sentetik antioksidan olan bütillenmiş hidroksi toluen (BHT) için tekrarlanmıştır.

2.7. Demir İyonu İndirgeyici Antioksidan Potansiyeli (FRAP)

Yöntem [Fe(III)(TPTZ)₂]³⁺'in antioksidan tarafından [Fe(II)(TPTZ)₂]²⁺'ye indirgenmesine dayanmaktadır. FRAP ayırıcı 10 mM TPTZ çözeltisinin 2.5 mL FeCl₃.6H₂O ve 25 mL asetat tamponu'nun karıştırılması ile hazırlanmıştır. FRAP ayırıcı ekstre veya standart olarak kullanılan L-askorbik asit ile karıştırılarak absorbansı 593 nm'de ölçülmüştür. Ekstrenin FRAP değerleri (mM/L Fe²⁺) olarak ifade edilmiştir [26].

2.8. Bakır (II) İyonu İndirgeyici Antioksidan Kapasite Yöntemi (CUPRAC)

CUPRAC yöntemi, Cu²⁺ redüksiyon kapasitesine dayalı bir toplam antioksidan kapasite ölçüm yöntemidir [27]. 10 mM CuCl₂, 7.5 mM neocuproine ve NH₄Ac tampon çözeltilerinin her birini içeren karışım üzerine farklı konsantrasyonlarda hazırlanan ekstre çözeltisi eklenerek karıştırılmıştır. Karışım oda sıcaklığında inkübe edildikten sonra absorbansı 450 nm de okunmuştur. Ekstrelerin ve standartların Cu²⁺-Cu⁺ indirgeyici güç eğrileri, konsantrasyon ve bu konsantrasyonlara karşılık gelen absorbans değerleri arasında çizilmiştir.

2.9. Antibakteriyel Aktivitenin Belirlenmesi

Çalışmada kullanılacak test bakterileri olarak: *Aeromonas hydrophila* ATCC 7965, *Salmonella typhimurium* NRRLE 4463, *Listeria monocytogenes* 1/2B, *Escherichia coli* ATCC 25922, *Pseudomonas aeruginosa* ATCC 27853, Metisilin dirençli *Staphylococcus aureus* ATCC 43300 (MRSA), *Klebsiella pneumoniae* ATCC 13883, *Proteus mirabilis* ATCC 25933, *Bacillus cereus* ATCC 11778, Metisilin duyarlı *Staphylococcus aureus* ATCC 25923 (MSSA), *Streptococcus pneumoniae* ATCC 10015, *Salmonella enteritidis* ATCC 13076, *Mycobacterium smegmatis* RUT kullanılmıştır. Antibakteriyel aktivite denemeleri agar difüzyon yöntemi ile yapılmıştır [28]. Bakteri kültürleri steril nutrient broth ile 10^6 - 10^7 cfu/mL olacak şekilde ayarlanmıştır. Her bir bakteri içeren kültürden 250 µL alınarak 25 mL steril Muller-Hinton içeren besiyerine aktarılmıştır ve petri kaplarına (9 cm) dökülmüştür. Agar donduktan sonra 4 °C'de 1 saat bekletilmiştir. Agarda eşit uzaklıkta 6 mm'lik kuyucuklar mantar delici ile açılmıştır. Hazırlanan ekstre çözeltisinden (60 mg/mL stok) kuyucuklara 40 µL pipetlenmiştir. Ekstre iyice emildikten sonra petri 37 °C'de 18-24 saat ters pozisyonda inkübe edilmiştir. İnkübasyon periyodu sonunda inhibisyon zonu oluşumu (mm) açısından petri kontrol edilip, oluşan inhibisyon zonlarının çapı mm cinsinden ölçülmüştür. Tetrasiklin (10 mg/mL) antibiyotiği pozitif kontrol olarak kullanılmıştır.


3. Bulgular

Yapılan arazi çalışmaları ile Türkiye'de yayılış gösteren endemik *L. pseudograminifolia* bitkisinin toprak üstü kısımları toplanmıştır. Kurutulup öğütülen toprak üstü kısımları maserasyon yöntemi ile metanol kullanarak ekstre edilmiştir. Rotary evaporatörde kurutulan ekstreler hassas terazi de tartularak verimleri % cinsinden (g ekstre/100 g bitki) hesaplanmış ve sonuç Tablo 1'de verilmiştir. Ekstrenin verimi 14.72 (w/w) olarak bulunmuştur. Çalışılan metanollü ekstrenin Folin-Ciocalteu yöntemi ile ölçülen toplam fenolik madde miktarı mg gallik asit eşdeğeri (GAE) olarak belirtilmiş ve elde edilen sonuç Tablo 1'de verilmiştir. Ekstrenin fenolik madde miktarı 50.61 ± 1.0 mg GAE/g ekstre olarak bulunmuştur. Metanollü ekstrenin Alüminyum klorür kolorimetrik yöntemi ile ölçülen toplam flavonoid madde miktarı mg kersetin eşdeğeri (QE) olarak belirtilmiş ve elde edilen sonuç Tablo 1'de verilmiştir. Ekstrenin flavonoid madde miktarı 7.64 ± 0.0 mg QE/g ekstre olarak bulunmuştur. Metanollü ekstrenin fosfomolibdenyum yöntemi ile ölçülen toplam antioksidan aktivitesi mg askorbik eşdeğeri (AAE) olarak belirtilmiş ve elde edilen sonuç Tablo 1'de verilmiştir. Ekstrenin toplam antioksidan aktivitesi 132.53 ± 0.1 mg AAE/g ekstre olarak bulunmuştur.

Tablo 1. *L. pseudograminifolia* metanollü ekstre verimi, toplam fenolik, flavonoid madde miktarı ve antioksidan aktivite sonuçları

| | |
|---|------------------|
| % Ekstre Verimi (w/w) | 14.72 |
| Toplam fenolik madde miktarı (mg GAE/g ekstre) | 50.61 ± 1.0 |
| Toplam flavonoid madde miktarı (mg QE/g ekstre) | 7.64 ± 0.0 |
| Toplam antioksidan aktivite (mg AAE/g ekstre) | 132.53 ± 0.1 |
| DPPH IC ₅₀ (µg/mL) | 41.59 |
| FRAP mM Fe(II)/L | 2.87 |


Metanollü ekstrenin antiradikal aktivitesi DPPH (2,2-difenil-1-pikrilhidrazil) yöntemi ile ölçülmüş ve sonuçlar % inhibisyon olarak verilmiştir. Elde edilen değerler standart antioksidan BHT'nin değeri ile karşılaştırmalı olarak Şekil 1'de gösterilmiştir. Ekstrenin 0.1, 0.25, 0.5, 1 ve 2 mg/mL konsantrasyonlarında belirlenen %inhibisyon değerleri sırası ile %5.08, %11.78, %22.46, %43.21 ve %78.48 olarak belirlenmiştir. BHT için aynı konsantrasyonlarda % inhibisyon değerleri sırasıyla %47.08, %79.28, %81.71, %81.83 ve %81.96 olarak belirlenmiştir. BHT ile karşılaştırıldığında metanollü ekstrenin antiradikal aktivitesinin çok daha düşük olduğu görülmektedir ($p < 0.0$). Metanollü ekstrenin konsantrasyonlara karşı yüzde inhibisyon değerinin yer aldığı grafik çizilerek %50 inhibisyona neden olan konsantrasyon (IC₅₀) belirlenmiş (Tablo 1). Ekstrenin IC₅₀ değeri 41.59 µg/mL olarak bulunmuştur. BHT için IC₅₀ değeri 6.81 µg/mL olarak bulunmuştur. Metanollü ekstrenin DPPH radikal süpürücü aktivitesi BHT'ninkinden çok daha düşüktür.



Şekil 1. *L. pseudograminifolia* metanollü ekstresinin ve BHT'nin % inhibisyon değerleri

FRAP yöntemi antioksidanların varlığında ferik (Fe^{+3}) demirin ferrous (Fe^{+2}) demirine indirgemesi için kullanılmaktadır. Ekstrenin demir indirgeyici antioksidan potansiyeli 2.87 mM/L olarak hesaplanmıştır (Tablo 1). L- askorbik asitin FRAP değeri 4.04 mM/L olarak bulunmuştur. Ekstrenin demir iyonu indirgeyici gücü standart L- askorbik asitin değerinden düşüktür.

Ekstrenin CUPRAC yöntemi ile bakır(II)-neokuproin kompleksini bakır(I)-neokuproin kompleksine indirgeme aktivitesi ölçülmüştür. Sonuçlar standart olarak Troloks'un değeri ile karşılaştırmalı olarak Şekil 2'de gösterilmiştir. Konsantrasyona bağlı olarak absorbans değerleri ve aktivite artmaktadır ($p < 0.0$). 0.2, 0.4, 0.6, 0.8 ve 1 mg/mL konsantrasyonlarında metanollü ekstrenin absorbans değerleri sırasıyla 0.30, 0.64, 0.95, 1.24 ve 1.54 olarak belirlenmiştir. Aynı konsantrasyonlarda Troloks için elde edilen absorbans değerleri ise sırasıyla 0.43, 0.89, 1.18, 1.46 ve 1.76 olarak belirlenmiştir. Çalışılan konsantrasyonlarda metanollü ekstrenin absorbans değerleri Troloks'un değerlerinden düşüktür. Dolayısıyla troloksa kıyasla metanollü ekstrenin daha düşük bakır indirgeyici güce sahip olduğu söylenebilir.



Şekil 2. *L. pseudograminifolia* metanollü ekstresinin bakır iyonu indirgeme gücü

L. pseudograminifolia'dan elde edilen metanollü ekstrenin antibakteriyel aktivitesi agar difüzyon yöntemi ile 13 adet bakteriye karşı denenmiştir. Metanollü ekstrenin çalışılan konsantrasyonda (60 mg/mL) test edilen bakterilerin hiçbirine karşı antibakteriyel aktivite göstermediği belirlenmiştir.

4. Tartışma ve Sonuç

Fenolik bileşikler bitkilerde yaygın olarak bulunurlar. Antioksidan ve serbest radikal süpürücü etkilerinden ve dolayısıyla potansiyel sağlık etkilerinden dolayı fazlaca ilgi görmektedir [29]. Flavonoidler ise doğal bileşiklerin en yaygın, farklı gruplarından ve en önemli doğal fenollerdendir [30]. Bu nedenle, *L. pseudograminifolia*'dan elde edilen metanollü ekstrenin toplam fenolik ve flavonoid madde miktarları belirlenmiştir.

S. arenaria köklerinden elde edilen hidrometanol ekstre ve bunların etilasetat, bütanol ve sulu fraksiyonlarının toplam fenolik ve flavonoid madde miktarları belirlenmiştir. Çözücü polaritesine göre fenolik madde miktarının değiştiği, hidrometanol ekstre ve bunların etilasetat, bütanol ve sulu fraksiyonlarının toplam fenolik madde miktarlarının sırasıyla 33.31, 76.63, 82.36 ve 51 mg GAE/g ekstre olduğu, toplam flavonoid madde miktarlarının ise sırasıyla 3.69, 5.05, 5.86 ve 3.95 olduğu bildirilmiştir [11]. Bizim elde ettiğimiz sonuçlar ile karşılaştırıldığında *L. pseudograminifolia* metanollü ekstresinin toplam fenolik ve flavonoid madde miktarının *S. arenaria* hidrometanol ekstre ekstresi için belirlenen miktardan daha yüksek olduğu görülmektedir. *S. argentea*'nın etil asetat ekstresinin toplam fenolik ve flavonoid madde miktarları 11.10 mg GAE/g ve 23.36 mg Rutin eşiti /g olarak belirlenmiştir [14]. *S. argentea*'nın etil asetat ekstresinin toplam fenolik madde miktarı bizim elde ettiğimiz değerden daha düşüktür. *S. stellata*'dan elde edilen etilasetat, *n*-bütanol ve petrol eteri ekstralarının toplam fenolik madde miktarları sırasıyla 117.66 ± 0.52, 77.12 ± 0.29 ve 30.33 ± 0.15 µg GAE/mg olarak bulunurken ekstraların toplam flavonoid madde miktarları ise sırasıyla 72.90 ± 0.76, 57.83 ± 0.25 ve 13.83 ± 0.45 µg QE/mg olarak belirlenmiştir [31]. Üç farklı büyüme evresinde toplanan *S. tschilliensis*'nin toplam fenolik ve flavonoid madde miktarları sırasıyla 0.00-140.03 mg GAE/g ve 9.10- 460.01 mg RE/g olarak tespit edilmiştir [13]. *S. sicula* metanollü ekstresinin toplam fenolik madde miktarı 2.67 mg of GAE/g ekstre olarak bulunmuştur [15]. Farklı çalışmalarda belirlenen toplam fenolik ve flavonoid madde miktarları arasındaki farklılıklar bitki türlerinin, ekstraksiyon için kullanılan bitki kısımları, çözücü ve ekstraksiyon yönteminin farklılığından kaynaklanmaktadır.

L. pseudograminifolia metanollü ekstresinin antioksidan aktivitesi çeşitli yöntemler ile belirlenmiştir. Benzer şekilde farklı *Scabiosa* türlerine ait ekstraların antioksidan aktivitelerinin belirlendiği çeşitli çalışmalar bulunmaktadır. Bu çalışmalardan birinde, *S. stellata*'dan elde edilen etilasetat, *n*-bütanol ve petrol eteri ekstralarının toplam antioksidan aktiviteleri fosfomolibdenyum yöntemi ile çalışılmış ve sırasıyla 0.0660, 0.03 ve 0.0885 µg AAE/mg ekstre olarak belirlenmiştir [31]. *S. argentea*'nın etil asetat ekstresinin antioksidan aktivitesi fosfomolibdenyum yönteminde 4.16 mg AAE/g olarak tespit edilmiştir [14].

S. tschilliensis %70'lik etanol ekstresinin DPPH yönteminde IC₅₀ değerleri 272.8 µg/mL, *S. comosa* ekstresinin ise 333.1 µg/mL olduğu, *S. tschilliensis*'nin *S. comosa*'dan daha yüksek radikal süpürücü aktiviteye sahip olduğu, her iki ekstrenin de doza bağlı olarak 16.88-270 µg/mL aralığında TPTZFe (III) kompleksini TPTZ-Fe (II)'ye indirgediği bildirilmiştir [10]. *S. stellata*'nın *n*-bütanol fraksiyonunun en yüksek DPPH süpürücü aktivite gösterdiği (IC₅₀ = 64.46 µg/mL) kaydedilmiştir [12]. *S. argentea*'nın etil asetat ekstresinin 0.25, 0.5 ve 1 mg/mL konsantrasyonlarında DPPH yöntemi ile belirlenen % inhibisyon değerleri sırası ile %3.98, %10.78 ve %26.26 olarak bulunmuştur [14]. Bu çalışmalar ile karşılaştırıldığında *L. pseudograminifolia* metanollü ekstresinin daha yüksek DPPH süpürücü aktiviteye sahip olduğu görülmektedir. Çiçeklenme evresi öncesi *S. tschilliensis*'den elde edilen etil asetat fraksiyonunun en yüksek DPPH radikal temizleme aktivitesi (IC₅₀ = 8.47 ± 0.23 µg/mL) gösterdiği bildirilmiştir [13].

L. pseudograminifolia metanollü ekstresinin demir iyonu indirgeyici aktivitesi FRAP yöntemine göre belirlenmiştir. Ekstrenin demir indirgeyici güce sahip olduğu tespit edilmiştir. *S. columbaria* subsp. *columbaria* var. *columbaria*'nın çiçek ve yapraklarından elde edilen metanollü ekstraların DPPH yöntemi ile elde edilen IC₅₀ değerleri sırasıyla 0.01114 ve 0.0138 µg/mL, FRAP yöntemi ile elde edilen antioksidan kapasiteleri sırasıyla 267.381 ve 242.857 µM Trolox eşiti olarak belirlenmiştir [32]. *L. pseudograminifolia* metanollü ekstresinin test edilen konsantrasyonlarda bakır indirgeyici güce sahip olduğu belirlenmiştir. Benzer olarak, *S. argentea*'nın etil asetat ekstresinin bakır indirgeme gücünün konsantrasyona bağlı olarak arttığı bildirilmiştir [14].

Çeşitli çalışmalarda *Scabiosa* cinsine ait farklı türlerden elde edilen ekstraların antibakteriyel aktiviteye sahip olduğu bildirilmiştir. *S. hymettia*'dan elde edilen kloroform ve metanol ekstralarının *S. aureus*, *Staphylococcus epidermidis*, *P. aeruginosa*, *Enterobacter cloacae*, *K. pneumoniae* ve *E. coli*'ye karşı orta derecede antibakteriyel aktiviteye sahip olduğu bildirilmiştir [17]. Diğer bir çalışmada, *S. stellata*'dan elde edilen etanollü ekstre ve izole edilen bileşiklerin *Enterococcus faecalis* ve *Staphylococcus epidermidis*'e karşı antibakteriyel aktivite gösterdiği bildirilmiştir [19]. Bizim sonuçlara benzer olarak, *S. columbaria* subsp. *paphlagonica* yapraklarından elde edilen metanollü ekstrenin *Enterococcus gallinarum*, *Enterococcus faecalis*, *Bacillus subtilis*, *Shigella* sp., *E. coli*, *Streptococcus pyogenes*, *S. aureus*, *L. monocytogenes* ve *P. aeruginosa*'ya karşı hiçbir aktivite göstermediği bildirilmiştir [33].

Sonuç olarak, *L. pseudograminifolia*'dan elde edilen metanollü ekstre yüksek fenolik ve flavonoid madde miktarı ile antioksidan aktivite gösterirken, antibakteriyel aktivite göstermemiştir. Yapılan literatür taramasına göre, *L. pseudograminifolia*'dan elde edilen metanollü ekstrenin toplam fenolik ve flavonoid madde miktarı, antioksidan ve antibakteriyel aktivitesi ilk kez bu çalışma ile belirlenmiştir. Bu çalışmanın sonuçları *L. pseudograminifolia* metanollü ekstresinin tıp ve gıda alanında sentetik antioksidanlara alternatif doğal antioksidanların kaynağı olarak kullanılabileceğini göstermektedir.

Teşekkür

Bu projenin gerçekleşmesinde verdiği maddi destek ve yardımlarından dolayı TÜBİTAK'a teşekkür ederiz. Makale TÜBİTAK 2209-A (No:1919B012318582) ve KBAG-117Z826 no'lu proje sonuçlarından üretilmiştir.

Kaynakça

- [1] Pisoschi, A. M., and Pop, A. 2015. The role of antioxidants in the chemistry of oxidative stress: A review. *European Journal of Medicinal Chemistry*, 97, 55–74. 10.1016/j.ejmech.2015.04.040.
- [2] Perron, N. R., and Brumaghim, J. L. 2009. A review of the antioxidant mechanisms of polyphenol compounds related to iron binding. *Cell Biochemistry and Biophysics*, 53, 75–100. 10.1007/s12013-009-9043-x.
- [3] Krishnaiah, D., Sarbatly, R., Nithyanandam, R. 2011. A review of the antioxidant potential of medicinal plant species. *Food and Bioproducts Processing*, 89, 217–233. 10.1016/j.fbp.2010.04.008.
- [4] Pisoschi, A. M., Pop, A., Georgescu, C., Turcuş, V., Olah, N. K., and Mathe, E. 2018. An overview of natural antimicrobials role in food. *European Journal of Medicinal Chemistry*, 143, 922–935. 10.1016/j.ejmech.2017.11.095.
- [5] Aykut, A., Baran, U., Çelik, J., Ahmet, A. 2022. Anatomical Comparison of *Lomelosia argentea* and *Lomelosia polykratis* (Caprifoliaceae) Species Distributed in Türkiye. *Nevşehir Bilim ve Teknoloji Dergisi*, 11, 31–39. 10.17100/nevbiltek.1141259.
- [6] Baytop, T. 1994. *Dictionary of Turkish Plant Names (Atatürk Kültür Dil ve Tarih Yüksek Kurumu, Ankara: Türk Dil Kurumu Yayınları, Türk Tarih Kurumu Basımevi.)*.
- [7] Göktürk, R. S. 2012. *Scabiosa* L. In *Türkiye Plants List (Vascular Plants)*, M. T. Güner, A., Aslan, S., Vural, M., Babaç, ed. (Nezahat Gökyiğit Botanical Garden and Flora Research Association Publications), pp. 319–322.
- [8] Panayır, T., and Baykal, T. 1996. Pharmacognostical Research on the *Scabiosa rotata* Bieb. XI th Symposium on Plant Originated Crude Drugs, 178–184.
- [9] Wang, J., Liu, K., Xu, D., Wang, Q., Bi, K., Song, Y., Li, J., Zhang, L. 2013. Rapid micropropagation system in vitro and antioxidant activity of *Scabiosa tschiliensis* Grunning. *Plant Growth Regulation*, 69, 305–310. 10.1007/s10725-012-9765-4.
- [10] Ma, J. N., Bolraa, S., Ji, M., He, Q. Q., Ma, C. M. 2016. Quantification and antioxidant and anti-HCV activities of the constituents from the inflorescences of *Scabiosa comosa* and *S. tschiliensis*. *Natural Product Research*, 30, 590–594. 10.1080/14786419.2015.1027701.
- [11] Hlila, M., Mosbah, H., Mssada, K., Jannet, H., Aouni, M., Selmi, B. 2015. Acetylcholinesterase inhibitory and antioxidant properties of roots extracts from the Tunisian *Scabiosa arenaria* Forssk. *Industrial Crops and Products*, 67, 62–69. <https://doi.org/10.1016/j.indcrop.2015.01.009>.
- [12] Rahmouni, N., Pinto, D., Beghidja, N., Benayache, S., and Silva, A. M. S. 2018. *Scabiosa stellata* L. Phenolic Content Clarifies Its Antioxidant Activity. *Molecules*, 23, 1–11. 10.3390/molecules23061285.
- [13] Wang, J., Liu, K., Li, X., Bi, K., Zhang, Y., Huang, J., Zhang, R. 2017. Variation of active constituents and antioxidant activity in *Scabiosa tschiliensis* Grunning from different stages. *Journal of Food Science and Technology*, 54, 2288–2295. 10.1007/s13197-017-2666-9.
- [14] Türkaslan Çoşgun, M. 2016. Investigation of antioxidant properties of ethyl acetate extract from *Scabiosa argentea*. Master Thesis, The Graduate School of Natural And Applied Science, Selçuk University, Konya, p-26.
- [15] Kılınç, H., Masullo, M., D'Urso, G., Karayildirim, T., Alankus, O., Piacente, S. 2020. Phytochemical investigation of *Scabiosa sicula* guided by a preliminary HPLC-ESIMSⁿ profiling. *Phytochemistry*, 174, 112350. 10.1016/j.phytochem.2020.112350.
- [16] Horn, M. M., Drewes, S. E., Brown, N. J., Munro, O. Q., Meyer, J. J. M., Matheka, A. D. M. 2001. Transformation of naturally-occurring 1,9-trans-9,5-cis sweroside to all trans sweroside during acetylation of sweroside

aglycone. *Phytochemistry*, 57, 51–56.

- [17] Christopoulou, C., Graikou, K., Chinou, I. 2008. Chemosystematic value of chemical constituents from *Scabiosa hymettia* (Dipsacaceae). *Chemistry and Biodiversity*, 5, 318–323. 10.1002/cbdv.200890029.
- [18] Hlila, M., Mosbah, H., Majouli, K., Nejma, A., Jannet, H., Mastouri, M., Aouni, M., Selmi, B. 2016. Antimicrobial Activity of *Scabiosa arenaria* Forssk. Extracts and Pure Compounds Using Bioguided Fractionation. *Chemistry and Biodiversity*, 13, 1262–1272. 10.1002/cbdv.201600028.
- [19] Lehbili, M., Magid, A., Hubert, J., Kabouche, A., Voutquenne-Nazabadioko, L., Renault, J. H., Nuzillard, J. M., Morjani, H., Abedini, A., Gangloff, S., Kabouche, Z. 2018. Two new bis-iridoids isolated from *Scabiosa stellata* and their antibacterial, antioxidant, anti-tyrosinase and cytotoxic activities. *Fitoterapia*, 125, 41–48. 10.1016/j.fitote.2017.12.018.
- [20] Alipoor Birgani, A., Sartipnia, N., Hamdi, S., Naghizadeh, M., Arasteh, J. 2019. Antimicrobial Activity of *Scabiosa olivieri* Extract and Its Effect on TNF- α and IL-1 Expression in Human Peripheral Blood Cells (PBMCs). *Journal of Fasa University of Medical Sciences*, 9, 1749–1757.
- [21] Albayrak, S., Aksoy, A., Sagdic, O., Hamzaoglu, E. 2010. Compositions, antioxidant and antimicrobial activities of *Helichrysum* (Asteraceae) species collected from Turkey. *Food Chemistry*, 119, 114–122.
- [22] Singleton, V., and Rossi, Jaj. 1965. Colorimetry of total phenolics with phosphomolybdic-phosphotungstic acid reagents. *American Journal of Enology and Viticulture*, 16, 144–158.
- [23] Pourmorad, F., Hosseinimehr, S. J., Shahabimajid, N. 2006. Antioxidant activity, phenol and flavonoid contents of some selected Iranian medicinal plants. *African Journal of Biotechnology*, 5, 1142–1145. 10.1055/s-2007-987042.
- [24] Prieto, P., Pineda, M., Aguilar, M. 1999. Spectrophotometric quantitation of antioxidant capacity through the formation of a phosphomolybdenum complex: specific application to the determination of vitamin E. *Analytical Biochemistry*, 269, 337–341. 10.1006/abio.1999.4019.
- [25] Lee, S. K., Mbwambo, Z. H., Chung, H., Luyengi, L., Gamez, E. J., Mehta, R. G., Kinghorn, A. D., Pezzuto, J.M. 1998. Evaluation of the antioxidant potential of natural products. *Combinatorial Chemistry & High Throughput Screening*, 1, 35–46.
- [26] Tuberoso, C. I. G., Antonella, R., Ersilia, B., Melis, M. P., Atzeri, A., Pirisi, F. M., Dessi, M. A. 2010. Chemical composition and antioxidant activities of *Myrtus communis* L. berries extracts. *Food Chemistry*, 123, 1242–1251. 10.1016/j.foodchem.2010.05.094.
- [27] Apak, R., Guclu, K., Ozyurek, M., Karademir, E., Ercag, E. 2006. The cupric ion reducing antioxidant capacity and polyphenolic content of some herbal teas. *International Journal of Food Sciences and Nutrition*, 57, 292–304. 10.1080/09637480600798132.
- [28] Albayrak, S., and Aksoy, A. 2013. Essential Oil Composition and in vitro Antioxidant and Antimicrobial Activities of *Thymus cappadocicus* Boiss. *Journal of Food Processing and Preservation*, 37, 605–614. 10.1111/j.1745-4549.2012.00694.x.
- [29] Imeh, U., and Khokhar, S. 2002. Distribution of conjugated and free phenols in fruits: Antioxidant activity and cultivar variations. *Agricultural Food Chemistry*, 50, 6301–6306.
- [30] Prasad, K., Yang, B., Dong, X., GuoXiang, J., Zhang, H., Xie, H., YueMing, J. 2009. Flavonoid contents and antioxidant activities from *Cinnamomum* species. *Innovative Food Science & Emerging Technologies*, 10, 627–632.
- [31] Mouffouk, C., Hambaba, L., Haba, H., Mouffouk, S., Bensouici, C., Mouffouk, S., Hachemi, M., Khadraoui, H. 2018. Acute toxicity and in vivo anti-inflammatory effects and in vitro antioxidant and anti-arthritis potential of *Scabiosa stellata*. *Oriental Pharmacy and Experimental Medicine*, 18, 335–348. 10.1007/s13596-018-0320-3.
- [32] Akar, Z. 2021. Chemical compositions by using LC–MS/MS and GC–MS and antioxidant activities of methanolic extracts from leaf and flower parts of *Scabiosa columbaria* subsp. *columbaria* var. *columbaria* L. *Saudi Journal of Biological Sciences*, 28, 6639–6644. 10.1016/j.sjbs.2021.07.039.
- [33] Benli, M., Bingol, U., Geven, F., Guney, K., Yigit, N. 2008. An Investigation on the antimicrobial activity of some endemic plant species from Turkey. *African Journal of Biotechnology*, 7, 001–005. 10.5897/AJB2008.000-5001.

Application of the MABAC Method for the Selection of Denim Fabrics with Sustainability Framework

Esra Akgül*¹ 

*¹ Erciyes Üniversitesi Mühendislik Fakültesi Endüstriyel Tasarım Mühendisliği, KAYSERİ

(Alınış / Received: 27.11.2024, Kabul / Accepted: 19.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Keywords

Denim
MABAC method
Laser treatment
Sustainability

Abstract: Denim fabrics are known as popular fashion products preferred by all age groups on a global scale. With the growing environmental awareness among consumers, denim fabric manufacturers have increasingly adopted environmentally sustainable production practices. This study aims to evaluate eight different denim fabric samples based on their tearing strength and tensile strength properties using the Multi-Attributive Border Approximation Area Comparison (MABAC) method. The denim fabrics analysed in this study are composed of 100% cotton, 100% organic cotton, 70% cotton with 30% pre-consumer recycled cotton, and 80% cotton with 20% post-consumer recycled cotton. Each denim fabric undergoes laser treatment at varying levels, after which they are subjected to either rinse or 30-minute stone washing processes. The MABAC method ranks the fabrics based on the selected performance criteria. According to the ranking results obtained by the MABAC method, the denim fabric sample produced from 100% organic cotton, processed with 32 dpi laser resolution, 150 pixel duration and then rinsed, was determined as the denim fabric with the best tearing and tensile strength performance.

Sürdürülebilirlik Çerçevesinde Denim Kumaş Seçimi için MABAC Yönteminin Uygulanması

Anahtar Kelimeler

Denim
MABAC yöntemi
Lazer yıkama
Sürdürülebilirlik

Öz: Denim kumaşlar, küresel ölçekte her yaş grubu tarafından tercih edilen popüler moda ürünleri olarak bilinmektedir. Tüketiciler arasında artan çevresel farkındalıkla birlikte, denim kumaş üreticileri de giderek daha çevre dostu üretim uygulamalarını benimsemektedir. Bu çalışmada, Çok Nitelikli Sınır Yaklaşım Alanı Karşılaştırılması (Multi-Attributive Border Approximation Area Comparison/MABAC) yöntemi kullanılarak sekiz farklı denim kumaş örneğinin yırtılma mukavemeti ve kopma mukavemeti özelliklerine göre değerlendirilmesi amaçlanmıştır. Çalışmada analiz edilen denim kumaşlar, %100 pamuk, %100 organik pamuk, %70 pamuk ile %30 üretim öncesi geri dönüştürülmüş pamuk ve %80 pamuk ile %20 kullanım sonrası geri dönüştürülmüş pamuk karışımlarından oluşmaktadır. Kumaşlar, her biri farklı seviyelerde lazer işlemine tabi tutulmuş ve ardından 30 dakikalık taş yıkama veya durulama işlemlerinden geçirilmiştir. Seçilen performans kriterlerine göre kumaşların sıralaması MABAC yöntemi ile yapılmıştır. MABAC yöntemi ile elde edilen sıralama sonuçlarına göre, %100 organik pamuktan üretilen, 32 dpi lazer yoğunluğu, 150 piksel süre ile işlenen ve ardından durulanan denim kumaş numunesi, yırtılma ve kopma mukavemeti performansı en iyi olan denim kumaş olarak tespit edilmiştir.

1. Introduction

Denim fabrics are a significant textile product with a prominent role in the fashion industry. They are typically produced from 100% cotton fabrics. The popularity of this product can be attributed to its ability to meet to a diverse range of age groups and to be styled in a multitude of ways through the use of different industrial washes. However, the production of denim is not environmentally friendly due to the considerable amount of water consumed and the waste generated during the manufacturing process. Alternative production methods have been developed to address these challenges, reduce environmental impact, and support the circular economy. These methods can be addressed through the utilisation of more environmentally friendly raw materials in the production of denim fabric or through the implementation of more sustainable finishing processes throughout the production cycle.

In recent years, cotton fibres have been mechanically recycled and reintroduced into the production cycle. The utilisation of mechanically recycled fibres in denim fabric production, as pre-consumer and post-consumer recycled cotton fibres, serves to diminish the necessity for raw materials, conserve natural resources and reduce waste. Moreover, the life cycle analysis of denim production has revealed that the employment of recycled cotton results in a diminished environmental impact in comparison to conventional cotton [1]. In order to enhance the quality attributes of recycled fibres, they are blended with cotton at varying blend ratios and employed in denim production [2]. At the same time, laser technologies are used to enhance the visual appeal of denim fabric. This environmentally friendly washing technique is more sustainable than traditional physical and chemical processes. It offers several advantages, including reduced pollution, water and chemical consumption, ease of processing and design flexibility [3]. The selection of environmentally friendly denim fabric according to the quality requirements of the consumer can be considered as a complex problem that requires multiple criteria to be considered together.

Multi-Criteria Decision Making (MCDM) methods allow the decision maker to make the best choice among complex and close results in situations where there are more than one alternative. In recent years, multi-criteria decision-making methodologies have been employed with increasing frequency in the context of textile-related problems. These methods facilitate the resolution of complex problems in a manner that is both practical and beneficial to the decision-maker. A variety of MCDM methodologies have been successfully employed in the existing literature for the selection of textile products. Acar et al. [2] used the MCDM methods as the logarithm methodology of additive weights (LMAW) and the double normalization-based multiple aggregation (DNMA) methods for determining the optimal fabric structures of denim fabrics containing recycled cotton. Majumdar et al. [4] used the technique for order preference by similarity to ideal solutions (TOPSIS) and the analytic hierarchy process (AHP) for selection of the most appropriate navel rotor spinning machine. Yildirim et al. [5] investigated the selection of dual-core yarn production parameters for denim fabric with Multi-Objective Optimization on the Basis of Ratio Analysis (MOORA) method. Wanassi et al. [6] investigated the relationship between the cost and quality of yarn from recycled fibre using the analytical hierarchy process (AHP).

The multi-criteria boundary approach area comparison (MABAC) method is a kind of MCDM methodology. Agarwal et al. employed a combination of the decision-making trial and evaluation laboratory (DEMATEL) and the MABAC methods for the assessment of jute fibre batches based on a range of properties, including strength, defects, root content, colour, fineness, and bulk density [7]. Torkayesh et al. [8] analysed the concepts of sustainable development and circular economy with the MABAC method. Dokovic and Doljanica [9] used AHP and MABAC method for selection investment projects. Xu et al. [10] proposed a selection model with MABAC method for green supplier evaluation. The aim of this study is to make sustainable textile production and raw material selection with a multi-criteria decision-making approach. For this purpose, the multi-criteria boundary approach area comparison (MABAC) method was used to evaluate eight different denim fabrics in terms of tearing and tensile strength properties.

The initial section of this study presents a comprehensive literature review. The subsequent section elucidates the characteristics of the denim fabrics utilized, the outcomes of the some quality testing, and the specifics of the MABAC methodology. The third section of the study showcases the outcomes of the methodology's implementation. Ultimately, the findings are subjected to a critical analysis, and in the conclusion, the study offers final evaluations and recommendations for jean manufacturers.

2. Material and Method

2.1. Material

For the production of jeans, the most appropriate selection will be made from denim fabrics with different contents. The eight denim fabrics are composed of a variety of cotton blends, including 100% cotton, 100% organic cotton, 70% cotton+30% pre-consumer recycled cotton, and 80% cotton + 20% post-consumer recycled cotton for this study. In this study, two laser process parameters were used as pixel time and resolution. The pixel time/tpx is expressed in μs and controls the time required to position the laser beam in a given area. Another laser process parameter, resolution, which regulates the intensity of laser beam positioning within a given area, is expressed in dots per inch and is usually represented in dpi [13]. The all fabrics were subjected to laser treatment at varying pixel time (tpx/ μs) and resolution (dpi), and after some were subjected to 30' stone washing or rinse processes. In general, denim fabrics are cleaned with water, softened and discoloured slightly by rinse washing, softer and more discoloured by using pumice stones by stone washing. Tearing and tensile strength tests were conducted on the denim fabrics in both the warp and weft directions. The properties of the denim fabrics are presented in Table 1.

Table 1. The alternative denim fabric properties

| Samples | Fibre type | Washing type | Pixel time (μs) | Density of intense (dpi) |
|---------|---|--------------|-----------------|--------------------------|
| D1 | 100 % cotton | 30' stone | 100 | 32 |
| D2 | 100 % cotton | rinse | 125 | 34 |
| D3 | 100 % organic cotton | 30' stone | 125 | 36 |
| D4 | 100 % organic cotton | Rinse | 150 | 32 |
| D5 | %80 cotton, %20 postconsumer recycle cotton | 30' stone | 150 | 34 |
| D6 | %80 cotton, %20 postconsumer recycle cotton | rinse | 100 | 36 |
| D7 | %70 cotton, %30 pre-consumer recycle cotton | 30' stone | 150 | 34 |
| D8 | %70 cotton, %30 pre-consumer recycle cotton | rinse | 100 | 32 |

2.2. The multi-attributive border approximation area comparison (MABAC) method

The Multi-attributive border approximation area comparison (MABAC) method is firstly introduced by Pamučar and Ćirović in 2015 for solving the real-world problems [11]. The computational simplicity and robustness of the method ensure that the increase in the number of criteria and alternatives in the problem does not result in a complex solution structure. The MABAC method considers the strengths and weaknesses of each alternative compared to the other alternatives for the solution and performs the process according to each criterion evaluated. It provides consistent results in the case of criteria with different measurement units of alternatives. The performance of each criterion function is divided into two separate areas, the upper approximation area consisting of ideal alternatives and the lower approximation area containing non-ideal alternatives. The MABAC method consists of the following process steps [12]:

Step 1. To create decision matrix

The decision matrix was created for the purpose of facilitating the evaluation of alternatives.

$$A = \begin{bmatrix} x_{11} & \dots & x_{1i} \\ \vdots & \ddots & \vdots \\ x_{j1} & \dots & x_{ji} \end{bmatrix}$$

the i represents number of alternatives to be decided and, j represents the number of evaluation criteria. Where x_{ji} is the element of the decision matrix for i_{th} alternative in j_{th} attribute.

Step 2. To normalize of the decision matrix

In order to eliminate the potential for inconsistency in the data set, all results are normalised by reduction to the range [0, 1]. Once the positive and negative attributes of the decision matrix have been identified, the following Equations (1) and (2) are employed to normalise the data, respectively.

$$x_{ij}^* = \frac{x_{ij} - x_i^-}{x_i^+ - x_i^-}; \quad i = 1, \dots, m \quad j = 1, \dots, n \tag{1}$$

$$x_{ij}^* = \frac{x_{ij} - x_i^+}{x_i^- - x_i^+}; \quad i = 1, \dots, m \quad j = 1, \dots, n \tag{2}$$

where x_{ji} indicates the normalized value of the decision matrix of i_{th} alternative in j_{th} attribute. In addition, x_i^+ and x_i^- denotes as $x_i^+ = \max(x_1, x_2, \dots, x_m)$ and $x_i^- = \min(x_1, x_2, \dots, x_m)$.

Step 3. To calculate of the weighted normalized matrix

The normalised values of the decision matrix and the weights of the relevant attributes, represented by $[w_1, w_2, \dots, w_n]$, are calculated using the following equation 3:

$$x'_{ij} = w_j + x_{ij}^* w_j; \quad i = 1, \dots, m \quad j = 1, \dots, n \quad (3)$$

Step 4. To determinate of the border approximation area matrix (G)

The boundary approximation area matrix is obtained by using Equation 4.

$$G = [g_1, g_2, \dots, g_n]$$

$$g_j = (\prod_{i=1}^m x'_{ij})^{1/m}; \quad j = 1, \dots, n \quad (4)$$

Step 5. To calculate of the distance of the alternative from the border approximation area for the matrix elements

The distance of the alternatives to the boundary approximation area is determined based on the quantities of the boundary approximation area matrix and the weighted normalised values of each attribute, as illustrated in Eq. 5

$$q_{ij} = x'_{ij} - g_j; \quad j = 1, \dots, n \quad (5)$$

$$q_{ij} = \begin{bmatrix} x'_{11} - g_1 & \dots & x'_{1n} - g_n \\ x'_{12} - g_1 & \ddots & x'_{2n} - g_n \\ x'_{mn} - g_1 & \dots & x'_{mn} - g_n \end{bmatrix}$$

The position of an alternative D_i is always within the upper approximation domain G^+ , whereas the ideal alternative is situated within the D^+ domain. The position of the anti-ideal alternative D^- , is consistently located within the lower approximation domain G^- . The position of the alternative within the approximation field is contingent upon the following condition;

$$D_i \in \begin{cases} G^+ & \text{if } q_{ij} > 0 \\ G & \text{if } q_{ij} = 0 \\ G^- & \text{if } q_{ij} < 0 \end{cases}$$

For an alternative D_i to be identified as the best in the cluster, it must have the maximum number of criteria belonging to the upper approximation domain G^+ .

Step 6. To calculate of the Total Distances from the Border Approximate Area

The total distance of the alternatives to the approximate boundary zone is calculated using the following Equation 6:

$$S_i = \sum_{j=1}^n q_{ij}; \quad i = 1, \dots, m \quad (6)$$

Step 7. Ranking of Alternatives

The total distances of the alternatives from the borderline approximation area, determined in the previous stage, are ranked in descending order to finalize the prioritization of alternatives. The alternative with the highest S_i value is identified as the most favourable option.

3. Results

The study used the MABAC method to make the right choices in denim fabric production process and raw material preference for environmental sustainability. The results of the performance tests of denim fabrics, as presented in Table 2, were used to create the decision matrix, which represents the initial step of the MABAC method.

Table 2. The tearing and tensile strength results of denim fabric samples

| Samples | Tearing strength | | Tensile strength | |
|------------|------------------|----------------|------------------|----------------|
| | Warp direction | Weft direction | Warp direction | Weft direction |
| D1 | 3830 | 3513.33 | 56.333 | 48.666 |
| D2 | 4883.33 | 4283.33 | 65.333 | 54.333 |
| D3 | 3450 | 4256.66 | 47.666 | 49.666 |
| D4 | 4586.66 | 5346.66 | 60.666 | 59.666 |
| D5 | 3183.33 | 4360 | 44.666 | 49.666 |
| D6 | 5043.33 | 5353.33 | 66.00 | 58.666 |
| D7 | 2866.66 | 2456.66 | 35.33 | 25.66 |
| D8 | 3930 | 2640 | 41.33 | 31.33 |
| <i>max</i> | <i>5043.33</i> | <i>5353.33</i> | <i>65.333</i> | <i>59.666</i> |
| <i>min</i> | <i>2866.66</i> | <i>2456.66</i> | <i>35.33</i> | <i>25.66</i> |

Subsequently, in order to optimise the data, normalisation was performed using Eq. 1 in the second step. The maximum performance criteria was determined by the experts working in the denim sector, and since high tear and tearing strength during use is also desired, the normalisation process was conducted according to the maximum equation. The normalised data are presented in Table 3.

Table 3. The normalized matrix of denim fabric performance

| Samples | Tearing strength | | Tensile strength | |
|---------|------------------|----------------|------------------|----------------|
| | Warp direction | Weft direction | Warp direction | Weft direction |
| | Max | Max | Max | Max |
| D1 | 0.442575 | 0.364788 | 0.86217 | 0.815561 |
| D2 | 0.926493 | 0.63061 | 1 | 0.910581 |
| D3 | 0.267997 | 0.621403 | 0.729439 | 0.832328 |
| D4 | 0.790198 | 0.997697 | 0.928527 | 1 |
| D5 | 0.145484 | 0.657079 | 0.683496 | 0.832328 |
| D6 | 1 | 1 | 0.00047 | 0.983233 |
| D7 | 0 | 0 | 0 | 0 |
| D8 | 0.488517 | 0.063293 | 9.19E-05 | 9.51E-05 |

The weights assigned to the performance criteria of denim fabrics were derived from the collective expert opinion of individuals with a minimum of five years' experience working in the denim sector. The assigned weights for each criterion are presented in Table 4. Subsequently, the weighted normalised data were calculated using Eq. 3, and the results are displayed in Table 5.

Table 4. The weights of denim performance characteristics

| | Tearing strength | | Tensile strength | |
|----------|----------------------|----------------------|----------------------|----------------------|
| | Warp direction (max) | Weft direction (max) | Warp direction (max) | Weft direction (max) |
| w | 0.27 | 0.23 | 0.27 | 0.23 |

Table 5. The weighted normalized matrix

| Samples | Tearing strength | | Tensile strength | |
|---------|----------------------|----------------------|----------------------|----------------------|
| | Warp direction (max) | Weft direction (max) | Warp direction (max) | Weft direction (max) |
| D1 | 0.389495 | 0.313901 | 0.502786 | 0.417579 |
| D2 | 0.520153 | 0.37504 | 0.54 | 0.439434 |
| D3 | 0.342359 | 0.372923 | 0.466949 | 0.421435 |
| D4 | 0.483353 | 0.45947 | 0.520702 | 0.46 |

| | | | | |
|-----------|----------|----------|----------|----------|
| D5 | 0.309281 | 0.381128 | 0.454544 | 0.421435 |
| D6 | 0.54 | 0.46 | 0.270127 | 0.456144 |
| D7 | 0.27 | 0.23 | 0.27 | 0.23 |
| D8 | 0.4019 | 0.244557 | 0.270025 | 0.230022 |

In the MABAC method, the boundary proximity area is calculated using Eq. 4. In other words, each element of the weighted normalised decision matrix is multiplied, and the resulting g_i values are calculated by taking the 1/8th power. These values are presented in Table 6. Subsequently, by subtracting each of the criteria of the weighted normalised decision matrix from the boundary proximity area, the matrix of distances to the boundary proximity area is obtained. This matrix is given in Table 7.

Table 6. The border approximation area matrix

| | Tearing strength | | Tensile strength | |
|-------|----------------------|----------------------|----------------------|----------------------|
| | Warp direction (max) | Weft direction (max) | Warp direction (max) | Weft direction (max) |
| g_i | 0.396233 | 0.344616 | 0.39486 | 0.37137 |

Table 7. The distance matrix for the MABAC method

| Samples | Tearing strength | | Tensile strength | | s_i | Rank |
|-----------|----------------------|----------------------|----------------------|----------------------|----------|----------|
| | Warp direction (max) | Weft direction (max) | Warp direction (max) | Weft direction (max) | | |
| D1 | -0.00674 | -0.03071 | 0.107926 | 0.046209 | 0.116682 | 4 |
| D2 | 0.12392 | 0.030424 | 0.14514 | 0.068064 | 0.367548 | 2 |
| D3 | -0.05387 | 0.028307 | 0.072088 | 0.050066 | 0.096587 | 5 |
| D4 | 0.08712 | 0.114854 | 0.125842 | 0.08863 | 0.416447 | 1 |
| D5 | -0.08695 | 0.036512 | 0.059684 | 0.050066 | 0.059309 | 6 |
| D6 | 0.143767 | 0.115384 | -0.12473 | 0.084774 | 0.219191 | 3 |
| D7 | -0.12623 | -0.11462 | -0.12486 | -0.14137 | -0.50708 | 8 |
| D8 | 0.005666 | -0.10006 | -0.12484 | -0.14135 | -0.36058 | 7 |

In order to ascertain the distance matrix values for each boundary proximity area, the row values of each alternative must be summed. The quality performance test results for denim fabrics are then considered and ranked in relation to the resulting s_i value. The results of the study are shown in Table 8.

Table 8. Ranking of the considered denim fabrics

| Samples | Fibre type | Washing type | Pixel time (µs) | Density of intense (dpi) | s_i | RANK |
|-----------|---|--------------|-----------------|--------------------------|-----------------|----------|
| D1 | 100 % cotton | 30' stone | 100 | 32 | 0.416447 | 4 |
| D2 | 100 % cotton | rinse | 125 | 34 | 0.367548 | 2 |
| D3 | 100 % organic cotton | 30' stone | 125 | 36 | 0.219191 | 6 |
| D4 | 100 % organic cotton | Rinse | 150 | 32 | 0.116682 | 1 |
| D5 | %80 cotton, %20 postconsumer recycle cotton | 30' stone | 150 | 34 | 0.096587 | 3 |
| D6 | %80 cotton, %20 postconsumer recycle cotton | rinse | 100 | 36 | 0.059309 | 5 |
| D7 | %70 cotton, %30 pre-consumer recycle cotton | 30' stone | 150 | 34 | -0.36058 | 8 |
| D8 | %70 cotton, %30 pre-consumer recycle cotton | rinse | 100 | 32 | -0.50708 | 7 |

4. Discussion and Conclusion

In this paper presents the application of the MABAC method in the evaluation of laser-treated denim fabrics produced with different contents in the context of jean production. In the study, the tearing and tensile strength properties of denim fabrics in both the weft and warp directions were considered. In order to ensure greater objectivity in the decision-making process, the weights of four denim fabric performance characteristics were determined through the application of expert opinion. The MABAC method was employed to assign a ranking to the eight denim fabrics in accordance with their quality performance values. The results show that the D4 sample can be selected among the other denim fabric options with the most favourable tear and tensile strength properties. The D4 fabric is composed of 100% organic cotton and has undergone laser processing at a resolution density of 32 dpi, a pixel time of 150 μ , and subsequent rinse washing. The fabric designated D7, among the alternatives, is positioned at the last of the ranking. The fabric designated D7 is composed of 70% cotton and 30% pre-consumer recycled cotton fibre, and was subjected to laser processing at a resolution density of 34 dpi for 150 μ pixel time, followed by 30-minute stone washing. The findings indicated that stone washing resulted in a more pronounced reduction in strength compared to rinse washing. Additionally, it was observed that pre-consumer fibre waste resulted in a reduction in denim strength. The application of high laser intensity to denim fabrics was observed to be effective in terms of strength values. When considered together with the previous observations of denim experts, it can be concluded that this ranking can be effectively used for a more rigorous scientific evaluation of denim fabrics to be selected. In future studies, the MABAC method can be applied in textile studies by combining it with various experimental designs or clustering algorithms in the presence of multiple options and evaluation criteria.

Acknowledgment

I would like to express my sincere thanks to the Research and Development director and to the entire group of development service at the ORTAANADOLU Textile Mill for their support.

Reference

- [1] Yüksel, Y. E., & Korkmaz, Y. 2023. Eco-friendly denim fabric design and life cycle analysis. Kahram. Sütçü İmam Üni. Müh. Bil. Derg, 26, 117-125.
- [2] Acar, E., Tama Birkocak, D., Özdağoğlu, A., Ünal, Z., Özdemir, G., & Josè Abreu, M. 2024. Prioritizing Sustainable Denim Fabric through Integrated Decision-Making Framework. *Materials*, 17(13), 3291.
- [3] Ortiz-Morales, M., Poterasu, M., Acosta-Ortiz, S. E., Compean, I., & Hernandez-Alvarado, M. R. 2003. A comparison between characteristics of various laser-based denim fading processes. *Optics and Lasers in Engineering*, 39(1), 15-24.
- [4] Majumdar, A., Kaplan, S., & Göktepe, Ö. 2010. Navel selection for rotor spinning denim fabrics using a multi-criteria decision-making process. *The Journal of The Textile Institute*, 101(4), 304-309
- [5] Yildirim, N., Akgül, E., & Türksoy, H. G. 2022. Selection of dual-core yarn production parameters for denim fabric by using MULTIMOORA method. *The Journal of The Textile Institute*, 113(6), 1039-1047
- [6] Wanassi, B., Azzouz, B., & Hassen, M. B. 2018. Sustainable denim yarn: quality-cost analysis and analytic hierarchy process (AHP) optimization. *AATCC Journal of Research*, 5(4), 17-24.
- [7] Agarwal, S., Chakraborty, S., & Chakraborty, S. 2020. A DEMATEL-MABAC-based approach for grading and evaluation of jute fibers. *Research Journal of Textile and Apparel*, 24(4), 341-355.
- [8] Torkayesh, A. E., Tirkolae, E. B., Bahrini, A., Pamucar, D., & Khakbaz, A. 2023. A systematic literature review of MABAC method and applications: An outlook for sustainability and circularity. *Informatica*, 34(2), 415-448.
- [9] Doković, L., & Doljanica, D. 2023. Application of AHP and MABAC methods in the framework of multi-criteria decision-making in the selection of investment projects. *Journal of process management and new technologies*, 11(3-4), 105-114.
- [10] Xu, X. G., Shi, H., Zhang, L. J., & Liu, H. C. 2019. Green supplier evaluation and selection with an extended MABAC method under the heterogeneous information environment. *Sustainability*, 11(23), 6616.

- [11] Pamučar, D., & Ćirović, G. 2015. The selection of transport and handling resources in logistics centers using Multi-Attributive Border Approximation area Comparison (MABAC). *Expert systems with applications*, 42(6), 3016-3028.
- [12] Alinezhad, A., Khalili, I., 2019. *International Series in Operations Research & Management Science*. Springer International Publishing, 277s.
- [13] Kan, C. W. 2014. Colour fading effect of indigo-dyed cotton denim fabric by CO₂ laser. *Fibers and Polymers*, 15, 426-429.

A New Hybrid Clover from Türkiye with Evidence From Morphological Data and a New Combination

Mustafa Keskin 

*1 Marmara University, Institute of Pure and Applied Sciences, Biology Program, 34722, Göztepe, İstanbul, Türkiye. <http://orchid.org/0000-0003-2454-1891>

(Alınış / Received: 02.11.2024, Kabul / Accepted: 19.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Keywords

Bursa,
endemism,
hybrid,
systematic,
clover

Abstract: In this article, a hybrid clover species collected from Bursa in the Edinburgh herbarium is introduced to the scientific world as *Trifolium x severoglui*. This hybrid species is morphologically similar to *T. ochroleucon* and *T. elongatum*. Natural hybridization is rare in the genus *Trifolium*. For this reason, this situation is briefly discussed, and the hybrid clover species previously reported in the world are listed. A taxon previously recognized as a subspecies (*Trifolium aureum* subsp. *barbulatum*) was transformed into a variety level.

Morfolojik kanıtları ile Türkiye'den yeni bir melez yonca türü ve yeni bir kombinasyon

Anahtar Kelimeler

Bursa,
endemizm,
melez,
sistematik,
yonca

Öz: Bu makalede, Edinburgh herbaryumunda Bursa'dan toplanan melez bir yonca türü *Trifolium x severoglui* olarak bilim dünyasına tanıtılmaktadır. Bu melez tür, morfolojik olarak *T. ochroleucon* ve *T. elongatum* türlerine benzer. *Trifolium* cinsinde doğal melezleşme nadirdir. Bu nedenle, bu durum kısaca tartışılmış ve dünyada daha önce bildirilen melez yonca türleri listelenmiştir. Daha önce bir alt tür olarak tanınan bir takson (*Trifolium aureum* subsp. *barbulatum*) varyete seviyesine dönüştürülmüştür.

1. Introduction

Trifolium is one of the best-known genera of the Fabaceae family. Its importance is evident in its number of species and economic value. It is a high-quality fodder for livestock and decorates meadows as a good source of honey [1, 2].

The clover species of the Near East were reviewed by Hossain [3]. Although 90 species were reported in this article, there is no record of any hybrid species. When the most comprehensive publication of recent years, the *Trifolium* Monograph [4], is included, no hybrid species is recorded among 239 species. Similarly, Gillet and Taylor [5] did not record hybrid clovers in their study reporting *Trifolium* worldwide. Later, when the Flora of Turkey is examined, we again do not see the term hybrid species among the 94 species reported to exist [6]. Finally, when the Turkish Plant List is examined, there is no record of a hybrid species [7].

Furthermore, there is no information about hybrids in any of the author's articles on clover [8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21]. No hybrid clover species were found in the honey and pollen association studies [2, 22].

Hybrid species are interesting. They can often be confused with the related species they form in nature. It is safe to say that all extant species result from this hybridization.

Hybrid species are usually produced by mating two separate species with similar characteristics. They are naturally sterile and cannot produce a seed or create a new individual. Hybrid species occur in the natural

environment under certain conditions, but the natural mechanisms are not yet understood. If the hybrid individual is not perennial, it may not be possible to see it again in the same environment.

Common characteristics of hybrids are as follows:

- 1) They carry dominant characteristics from two ancestors.
- 2) Hybrids do not form large populations
- 3) Reproductive organs are absent or sterile.
- 4) Seed formation is absent or inefficient.
- 5) Pollen is usually of different types and adherent, and the number of fertile pollen is deficient.

Although clover species are commonly encountered plants worldwide, the number of known natural hybrid species is relatively small. The article by Hendrych [8] mentions all known hybrid species. This article provides information on 12 scientifically named and 10 unnamed hybrid species whose existence has been previously reported. The named hybrid species are summarised in Table 1.

Table 1. Known hybrid clovers worldwide.

| Hybrid species | Parents |
|--|--|
| <i>Trifolium</i> × <i>adulterinum</i> Beyerin in Verh. Bot. Vereins Prov. Brandenburg 1914, lvi. 127 (1915). | <i>T. campestre</i> × <i>T. patens</i> |
| <i>Trifolium</i> × <i>bertrandi</i> Rouy in Fl. France 5: 125 (1899). | <i>T. medium</i> × <i>T. rubens</i> |
| <i>Trifolium</i> × <i>charrieri</i> H.J. Coste in Bull. Acad. Int. Géogr. Bot. 27: 1 (1917). | <i>T. squamosum</i> × <i>T. pratense</i> |
| <i>Trifolium</i> × <i>jankae</i> Soó in Acta Bot. Acad. Sci. Hung. 10: 370 (1964). | = <i>Trifolium</i> × <i>neyrautii</i> Rouy |
| <i>Trifolium</i> × <i>joachini</i> Sennen & Mauricio in Cat. Fl. Rif. Or. 33 (1933). | <i>T. ochroleucum</i> × <i>T. pratense</i> |
| <i>Trifolium</i> × <i>neyrautii</i> Rouy in Fl. France 10: 374 (1908). | <i>T. medium</i> × <i>T. montanum</i> |
| <i>Trifolium</i> × <i>permixtum</i> Neuman in Bot. Not. 1894: 104 (1894). | <i>T. medium</i> × <i>T. pratense</i> |
| <i>Trifolium</i> × <i>prostii</i> Chass in Encycl. Biogeogr. Ecol. 12(2): 130 (1957). | <i>T. pratense</i> × <i>T. rubens</i> |
| <i>Trifolium</i> × <i>retyezaticum</i> Nyár. in Acta Bot. (Szeged) 1: 37 (1942). | <i>T. aureum</i> × <i>T. badium</i> |
| <i>Trifolium</i> × <i>schwarzii</i> Wein in Allg. Bot. Z. Syst. xv. 35 (1909). | <i>T. alpestre</i> × <i>T. medium</i> |
| <i>Trifolium</i> × <i>meduanense</i> Mercier & Lév. in Bull. Acad. Int. Géogr. Bot. sér. 3, 13(177-179): 287 (1904). | <i>T. repens</i> × <i>T. pratense</i> |
| <i>Trifolium</i> × <i>traplii</i> Domin in Klíč Květ. Českoslov. 200 (1928). | <i>T. alpestre</i> × <i>T. pannonicum</i> |

The status of some taxa that have only been reported as hybrids but have not been named is unclear. Some of them are not hybrid species but different ecotypes of a known species [8]. Incidentally, if we look at the publication dates of the hybrid species, we see that the oldest specimen is from 1894, and the latest is from 1957. These species need to be lectotyped. This will undoubtedly lead to more accurate naming of newly identified hybrid species.

This article is the first regarding hybrid clovers worldwide after a long time.

2. Materials and Methods

Herbaria in Türkiye and abroad were visited at different times to provide the basis for the "Illustrated Flora of Türkiye," which is still in progress. In one of the herbaria visited, in the Edinburgh Herbarium, a specimen

that could not be named and had a hybrid character was found. Various drawings were made in the workbook, and a long description was written. The specimen was examined under a microscope and photographed. The data obtained was compared with information from other herbaria visited simultaneously and later over a long period. (E, G, AEF, ANK, ANKO, EGE, ESSE, GAZI, HARRAN, HUB, ISTE, ISTF, ISTO, KNYA, MARE, MUFE, NGBB, and VANF).

3. Results

3.1. A New Hybrid

Trifolium x severoglui M. Keskin, nothosp. nov. (Fig.1-2).

Type: Türkiye: Bithynia, supra Brussa (Bursa), in reg. inferiorie montis Olypi (Uludağ), 300-500 m. s.m., 18 v 1899, J. Bornmüller 4320 (holo.: E 00338757!).

Diagnose: A perennial plant in the form of an intermediate between parents. *T. x severoglui* M. Keskin is close to the *T. elongatum* Willd. species in general appearance, flowering state and the standart 6-8 mm longer than keel and wings. Leaf structure and stipule characteristics are similar to those of *T. ochroleucon* Hudson.

Perennial plants. Stems 25–45 cm long, a few branched from base; spreading hairy in the lower part and adpressed hairy on leaves, stipules, and the upper parts. Stipule tube 10–15 mm long, free part 20–25 mm long. Petiol 10–30 mm. Leaflets 15–25 x 04–08 mm, emarginate. Inflorescence 20–40 x 11–20 mm long, ovoid to oblong, 10–25 mm pedunculated and adpressed hairy. The flowers are probably light yellow. Sepals 12–14 mm long, one tooth is much longer than the others, with spreading hairy, acute; tube 10-nerved, more or less spreading hairy. Petals 18–20 mm long, vexillum 6–8 mm longer than other parts. Ovarium distorted. No fruit and seed formation.

Flowering time: May.

Etymology: This new species is named after Ass. Prof. Dr. Zeki Severoğlu (Marmara University) who is the author's doctoral advisor. The proposed new Turkish scientific name is Zeki Yonca, according to the guidelines of Menemen et al. [23, 24].

Taxonomic Relationship: The parental species of this hybrid is *Trifolium elongatum* Willd. x *T. ochroleucon* Hudson.

Examined parent species from Bursa:

Trifolium elongatum Willd., Sp. Pl., ed. 4, 3(2): 1368 (1802).

Merkez, 05 vi 1889, E. Burnat (G!); Uludağ, 300-500 m, 18 v 1899, J. Bornmüller (E 00338757!); Uludağ, Aras slopes, Karçukuru, 03 vii 1944, M. Başarman (ISTF 3942!); Uludağ, meadow, vi 1874, T. Pichler (G!); Uludağ, Diktekir, 05 vii 1944, M. Başarman (ISTF 4147!); Uludağ, garig vegetation, xi 1964, J.J.F.E. De Wilde (E 00338741!); Uludağ, GB slopes, on main road, *Castanea sativa-Fagus orientalis-Pinus nigra* forest, 840-860 m, 22 v 1990, R. Lampinen 7702 (E 00338748!); Uludağ, Kirazlı yayla, 1450 m, 21 vi 1990, A. Baytop (ISTE 61886!); Uludağ, Kirazlı yayla, 21 vi 1990, A. Baytop and T. Baytop (ISTE 61886!); Uludağ, Soğukpınar, 03 vii 1980, M. Nydegger 15081 (G!); Uludağ, Soğukpınar, 04 vii 1944, M. Başarman (ISTF 4065!); Uludağ, şoşe, 14 v 1955, M. Heilbronn (ISTF 14055!); Uludağ, on road peak, viii 1945, M. Başarman (ISTF 5752!).

Trifolium ochroleucon Huds., Fl. Angl. (283). (1762).

Uludağ, Diktekir, 05 vii 1944, M. Başarman (ISTF 4150!); Uludağ, Elma çukuru, 28 vi 1944, M. Başarman (ISTF 3525!).



Figure 1. The general appearance of the new hybrid species and the ancestral species: A. *Trifolium elongatum* (GAZI 1116); B. *T. x severoglui* (E 00338757, type); C. *T. ochroleucon* (G).




Figure 2. Flower status of new hybrid species and ancestral species: A. *Trifolium elongatum* (G); B. *T. x severoglui* (E 00338757, type); C. *T. ochroleucon* (ISTE 48382) and Uppermost leaves of new hybrid species and ancestral species: D. *Trifolium elongatum* (ANK 8909); E. *T. x severoglui* (E 00338757, type); F. *T. ochroleucon* (ANK 583).

3.2. A New Combination

The taxon *Trifolium aureum* subsp. *barbulatum* differs from the parent species in that the calyx teeth are hairy. Both taxa grow in similar geographical areas and habitats. It is not easy to distinguish them externally; therefore, it does not have the characteristics of a subspecies. Therefore, it would be more correct to analyze it as a variety.

Trifolium aureum Pollich var. *barbulatum* (Freyn & Sint.) M. Keskin, comb. nov. (Fig. 3).

Syn.: *T. aureum* subsp. *barbulatum* Freyn & Sint., Oesterr. Bot. Z. 43: 377 (1893). *T. barbulatum* Freyn & Sint. ex Freyn, Oesterr. Bot. Zeitschr. 43: 377 (1893). *T. barbulatum* (Freyn & Sint.) Zohary, P.H. Davis, Fl. Turkey 3: 404 (1970). *Chrysaspis barbulata* (Freyn & Sint.) Hendrych, Preslia 48: 219 (1976).

Lectotype: [Türkiye], Kastamonu, Tosia in pratiss subalpinis montes Giaurdagh, 29 vii 1892, Sintenis 4835 (P). by Zohary and Heller in Gen. Trif. 336 (1984).

Examined Specimens: **Amasya:** Merzifon, Tavşan mountain, vi 1903, Manissadjian (G!); Merzifon, vi 1903, Manissadjian (E 00339264!). **Ankara:** Beypazarı, Eğriova, meadow, 1600 m, 27 v 1972, Y. Akman (ANK 8894!); Beypazarı, Horhor fountain, Abies, 1700 m, 1 v 1971, Y. Akman (ANK 898!); Beypazarı, Karaşar, *Pinus sylvestris* forest, 1600 m, 1 v 1971, Y. Akman (ANK 6290!); Beypazarı, Mahya, sandy creek, 20 vii 1972, Y. Akman (ANK 6291!); Işık mountain, moist meadows, 28 vi 1975, Y. Akman (ANK 6437!). **Bolu:** Aladağ, Kartalkaya hill, rocky areas, 1750 m, 12 vii 1962, P.H. Davis 37415 and M.J.E. Coode (E 00339260!); Gerede, Aktaş forest, Sarıçam, Aşağı Ovacık, 1600 m, 3 vii 1976, O. Ketenoğlu (E 00339262!); Kale, Tekneci creek, clearing in the forest, creek, roadbreak, 300-1000 m, 12 vii 1950, İ. Kılınc (ANKO 1209!); Köroğlu, black pine, volcanic bedrocks, 27 vi 1975, Y. Akman (E 00339263! and ANK!); Mudurnu to Abant lake, *Fagus-Abies* forest boundary, 1100 m, 9 vii 1962, P.H. Davis 37124 and M.J.E. Coode (E 00027522!); Yedigöller National Park, 11 vii 1977, R. İlarıslan 157 (ISTE 48255!). **Çorum:** Bayat, Yukarılapa Village, Midwife's position, *Pinus sylvestris* and *Abies* forest, 1750 m, 16 ix 1976, M. Kılınc (ANK 6180!); Kuş mountain, Hacıhamza'nın KD, Pine forest, 2000 m, 3 vii 1967, Watson ve ark. 3507 (E 00339266!). **Kastamonu:** Pınarbaşı, Kurtgirmez Mount, forest clearing, 1200 m, 26 vi 2003, M.U. Özbek 1686 (GAZI!); Tosya, Gavur Mount, 1700 m, 25 vii 1988, M. Nydegger 43877 (G 466921!). **Rize:** Çamlıhemşin, Amlakıt Plateau, Kahveden Arkovit through, Büyükbahçe, *Picea* forest and *Rhodendron* thickets, granite rocky terrain, 2000-2400 m, A. Güner 1190 (HUB 13103!); Çamlıhemşin, Hisarcık to Sıraköy, high mountain meadows, 1600-2000 m, 9 viii 1981, A. Güner 4092 and B. Yıldız (HUB!); İkizdere, Gölyayla to Cihantepe, wet meadow, 2500 m, 25 vii 1985, A. Güner 6603, M. Vural (HUB 131101). **Sivas:** Yıldız mountain, alpinic meadows, 1700 m, 14 viii 1967, C. Tobey 2359 (E 00338261!).



Figure 3. *Trifolium aureum* var. *barbulatum* (E 00339260).

4. Discussion and Conclusion

One hundred six species have been reported in the book of Turkish plants, some questionable [7]. *Trifolium elazizense* M. Keskin, Sonay, and Balos species identified from Elazığ province were recently added to this number [20]. Türkiye is like a clover paradise with its net 105 species [21].

This article adds a new hybrid to the genus *Trifolium*, which can be considered quite rare. This article introduced this hybrid species to the botanical community under *Trifolium x severoglui* M. Keskin. This hybrid is derived from the species *T. elongatum* Willd. and *T. ochroleucon* Hudson. It is exciting that no hybrid species have been reported within the borders of Türkiye. A large number of similar species can often coexist. However, hybrid species are scarce in the natural environment. The flower shape is of great importance. In other words, the pollination mechanism is of great importance.

Trifolium aureum is a clover species generally grown in the Black Sea region. The endemic subsp. *barbulatum* taxon, which was previously introduced to the scientific world as a subspecies, was decided to be examined as a variety because it differs from the central taxon by a tiny feature (hairy teeth) and grows in almost the same areas with each other: *T. aureum* subsp. *barbulatum* (Frey & Sint.) M. Keskin.

Acknowledgements

I thank the ANG Foundation for funding the herbarium visits necessary to revise *Trifolium* for the Illustrated Flora of Türkiye.

References

- [1] Altay, V., Karahan, P., Karahan F., Ozturk M. 2018. Pollen analysis of honeys from Hatay/Turkey. *Biological Diversity and Conservation* 11/3: 209–222.
- [2] Koçyiğit, M., Keskin, M., Daştan T. 2013. Pollen morphology of some *Trifolium* species, which are favorite plants. *Journal of Faculty Pharmacy Istanbul* 43(2): 85–94.
- [3] Hossain, M. 1961. A revision of *Trifolium* in the Nearer East. *Notes Royal Botanic Garden, Edinburg* 23: pp. 387–481.
- [4] Zohary, M., Heller, D. 1984. *The Genus Trifolium*, Israel Academy of Science and Humanities Jerusalem, 606 p.
- [5] Gillett, J., Taylor, N. 2001. *The World of Clovers*. Iowa State University Press, Ames, Iowa, USA.
- [6] Zohary, M. 1970. *Trifolium* L. in Davis PH [ed.], *Flora of Turkey and the East Aegean Islands* (vol. 3), 384–448, Edinburg University Press, Edinburg.
- [7] Keskin, M. 2012. *Trifolium* L. p.p. 488–498. Güner, A., Aslan, S., Ekim, T., Vural, M., Babaç, M.T. ed. *Türkiye Bitkileri Listesi (Damarlı Bitkiler)*. Nezahat Gökyiğit Bahçesi ve Flora Araştırmaları Derneği Yayını, İstanbul.
- [8] Hendrych, R. 1990. Dritte Reihe der Ergänzungen zur *Trifolium*-Monographie von Zohary und Heller (plantae hybridae). *Preslia, Praha*, 62 : 43–60.
- [9] Keskin, M. 2001a. A contribution to the genus *Trifolium* in Turkey. *Journal of Faculty Pharmacy Istanbul* 34 (2): 1–8.
- [10] Keskin, M. 2001b. The genus *Trifolium* L. Sect. *Chronosemium* Ser. (Fabaceae) in Turkey. pp. 267–278. Özhatay, N., ed., *The Second Balkan Botanical Congress 1. Proceedings of The Second Balkan Botanical Congress Plants of Balkan Peninsula: into the Next Millennium*, İstanbul.
- [11] Keskin, M. 2002. Türkiye'nin endemik *Trifolium* L. (Fabaceae) türleri. Poster session presented at XVI. Ulusal Biyoloji Kongresi, Malatya.
- [12] Keskin, M. 2003. Fabaceae familyasından yeni kare kayıtları. *OT Sistemantik Botanik Dergisi* 2, 181–187.
- [13] Keskin, M. 2004a. İstanbul'un *Trifolium* L. (Fabaceae) türleri, Kırsal Çevre Yıllığı, Ankara 7–17.
- [14] Keskin, M. 2004b. Türkiye florasındaki *Trifolium* L. cinsi üzerinde incelemeler. Article present at the meeting of the XVII. Ulusal Biyoloji Kongresi. Adana, June 21–24, Turkey.
- [15] Keskin, M. 2005. Türkiye'de *Trifolium* L. cinsinden yeni bir takson kaydı ve bir türün varlığı. *OT Sistemantik Botanik Dergisi* 12(1): 21–24.
- [16] Keskin, M. 2007a. The genus *Trifolium* L. sect. *Micrantheum* (C.Presl) Gib. & Belli (Fabaceae) in Turkey. p.p. 25–27. Poster session presented at the International Symposium 7th Plant Life of South West Asia (7th PLoSWA), June, Eskişehir, Turkey.
- [17] Keskin, M. 2007b. Türkiye'de *Trifolium pratense* L. (Fabaceae) türü ve iki yeni varyete kaydı. *OT Sistemantik Botanik Dergisi* 14(2): 5–8.
- [18] Keskin, M. 2011a. Türkiye'de yayılış gösteren *Trifolium nigrescens* Viv. (Fabaceae) türünün taksonomik durumu. *OT Sistemantik Botanik Dergisi* 18(2): 25–34.
- [19] Keskin, M. 2011b. Yoncalar (*Trifolium* spp.). *Bağbahçe* 33: 2–5.

- [20] Keskin, M., Sonay, V., Balos, M.M. 2023. *Trifolium elazizense* (Fabaceae), a new species from Turkey. *Phytotaxa* 583 (2): 199–206.
- [21] Keskin, M. 2024. Novelities in the genus *Trifolium* in Türkiye. *Front Life Sci RT* 5(2): 140-154. <https://doi.org/10.51753/flsrt.1472552>.
- [22] Koçyiğit, M., Keskin, M. 2012. Balarısı için en cazip İstanbul bitkisi; *Trifolium*. Poster session presented at BİHAT, XX. Bitkisel İlaç Hammaddeleri Toplantısı, October 10-13, Antalya, Turkey.
- [23] Menemen, Y., Aytaç, Z., Kandemir, A. 2016. Türkçe Bilimsel Bitki Adları Yönergesi. *Bağbahçe Bilim Dergisi* 3(3): 1–3.
- [24] Menemen, Y., Aytaç, Z., Kandemir, A. 2021. Türkçe Bilimsel Bitki, Mantar, Suyosunu ve Bakteri Adları Yönergesi. *Bağbahçe Bilim Dergisi*, 8(3), 188-195. <https://doi.org/10.35163/bagbahce.1030948>.

Classification of System and Software Related FDA Medical Device Recalls with a Three-Level Taxonomy Approach: Defibrillator Case

Nazire Merve ÖNDER*^{1,2} , Özden ÖZCAN TOP1 

*¹ Middle East Technical University, Information Systems Dept., ANKARA, TÜRKİYE
² ASELSAN A.Ş., ANKARA, TÜRKİYE

(Alınış / Received: 24.11.2024, Kabul / Accepted: 19.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Keywords

Defect classification,
Defect taxonomy,
Medical device recall,
Defibrillator,
FDA,
SW91.

Abstract: In the healthcare domain, where safety is paramount, medical device recalls are highly critical events that can pose significant risks to health. The U.S. Food and Drug Administration (FDA) maintains a comprehensive database of recall data, including fields such as product description, product type, recall reason, and termination status. However, the recall reason field lacks a predefined taxonomy for root cause classification, which limits the effectiveness of analyzing and preventing recurring issues. In this study, we aim to classify recalls based on their reasons by proposing a three-level taxonomy to improve the classification process. The first level classification approaches to the problem from a broad perspective, including labels such as operational, environmental, electrical, hardware, software, and mechanical. The second level utilizes the FDA root cause options to provide a more detailed classification. The third level uses the SW91 Classification of Defects in Health Software taxonomy specifically for software, which offers a standardized framework for classifying defects in health software. This taxonomy approach would not only aid in more precise recall classification but also lays the groundwork for subsequent research focused on developing predictive models to prevent recurring defects in healthcare software. By improving classification accuracy, this study aims to increase ways for product safety and enhance regulatory oversight in the medical device domain. In this study, we applied this approach to 271 different defibrillator recall cases reported by the FDA and categorized them based on their recall reasons. This enabled us to better understand recurring issues and allow for a more precise classification of recall reasons. This approach not only aims to analyze and address existing problems more effectively but also seeks to provide a foundation for future research focused on predicting and preventing potential defects.

Sistem ve Yazılım Kaynaklı FDA Tıbbi Cihaz Geri Çağrılarının Üç Seviyeli Taksonomi Yaklaşımı ile Sınıflandırılması: Defibrilatör Vakası

Anahtar Kelimeler

Hata sınıflandırma,
Hata taksonomisi,
Tıbbi Cihaz Geri Çağırma,
Defibrilatör,
FDA,
SW91.

Öz: Emniyetin her şeyden önemli olduğu sağlık alanında, tıbbi cihaz geri çağrılarını sağlık için önemli riskler oluşturabilecek son derece kritik olayları tanımlar. ABD Gıda ve İlaç Dairesi (FDA) ürün tanımı, ürün türü, geri çağırma nedeni ve sonlandırma durumu gibi alanları içeren kapsamlı bir geri çağırma veritabanı tutmaktadır. Ancak, geri çağırma nedeni alanı, kök neden sınıflandırması için önceden tanımlanmış bir taksonomiden yoksundur ve bu da tekrar eden sorunların analiz edilmesinin ve önlenmesinin etkinliğini sınırlamaktadır. Bu çalışmada, sınıflandırma sürecini iyileştirmek için üç seviyeli bir taksonomi önererek geri çağrılarını nedenlerine göre sınıflandırmayı amaçladık. Birinci seviye sınıflandırma, soruna operasyonel, çevresel, elektriksel, donanımsal, yazılımsal ve mekanik gibi etiketleri içeren geniş bir perspektiften yaklaşmaktadır. İkinci seviye, daha ayrıntılı bir sınıflandırma sağlamak için FDA kök neden seçeneklerini kullanır. Üçüncü seviye, ise sağlık yazılımlarındaki kusurların sınıflandırılması için standart

bir çerçeve sunan SW91 Sağlık Yazılımları için Hata Sınıflandırma taksonomisini kullanmaktadır. Bu çalışmada, bu yaklaşımı FDA tarafından geri çağırılan 271 farklı defibrilatör vakası için uyguladık ve vakaları geri çağırılma nedenlerine göre kategorize ettik. Bu sayede tekrar eden sorunları ve geri çağırma nedenlerinin daha hassas bir şekilde sınıflandırılmasına olanak tanıdık. Bu yaklaşım, sadece mevcut sorunları daha etkili bir şekilde analiz etmeyi ve çözmeyi değil, aynı zamanda ileride oluşabilecek hataları öngörmeye ve önlemeye yönelik araştırmalar için de bir temel oluşturmayı hedeflemektedir.

1. Introduction

Medical devices are safety critical in nature and their production and sale is governed by strict safety rules. Malfunctioning medical devices can lead to significant injuries and even death. When a company discovers an issue with one of its medical devices, it must propose either a correction or a removal based on the situation to regulatory bodies depending on where the medical device is marketed. Correction involves addressing the issue with the medical device at the location where it is used or sold. Removal addresses taking the medical device out of circulation from where it is used or sold. The Food and Drug Administration (FDA) uses the term “recall” when a manufacturer makes a correction or remove the product to address a problem with a medical device that violates FDA laws. Recalls occur when a medical device manufacturer notifies the FDA of a defect that could be a risk to health, or when it is both defective and a risk to health [1].

The FDA classifies recalls into three categories based on health risks posed by device failure. Safety Class I recalls denote situations in which exposure to a “violative product will cause serious adverse health consequences or death” [2]. While Class II exposure may result in temporary or reversible adverse health conditions, Class III recalls only reflect regulatory violations with minimal or no health risks [3].

The FDA keeps all recall data related to medical devices since 2002, which is publicly accessible on its website [4][10]. Recall reasons can be categorized into several types, including product defects, which involve manufacturing errors or contamination; labeling errors, where there is misleading or incorrect information on the packaging; performance issues, where devices fail to meet safety or efficacy standards; and compliance issues, which involve violations of regulatory requirements. Users can readily access statistics on recalls that are categorized by recall safety class, product type, year, and other relevant criteria. Statistics also shows that medical device recalls are increasing each year [1]. Therefore, recall data can be used as a valuable information for identifying the underlying causes of recalls and implementing preventive measures from the development stage discriminate the potential causes of recalls and take preventive actions during the development process. However, the effectiveness of this approach depends significantly on the level of detail in the defect taxonomy used as it directly affects the accuracy of classification and analysis.

Another challenge arises from the manually entered fields in the recall database. On the FDA website [4], recalls are published based on a predefined template that include structured fields: Date, Brand Names, Product Description, Product Types, Recall Reason Description, Company Name, and Terminated Recall. However, only the Recall Reason Description field is manually written. This reliance on human input introduces variability and inconsistencies, making it difficult to systematically analyze recall reasons. However, examining these human-written descriptions, along with adverse event reports, is essential, as it can uncover underlying safety issues in these devices. Such analysis not only highlights current safety concerns but also offers important insights into potential challenges in the design and development of safety-critical medical devices [5].

In this research, to address the aforementioned issues in defect classification, we introduce a three-level taxonomy designed to provide more precise and systematic recall classification, enabling better identification of safety issues with respect to recall reasons.

We selected defibrillators as the focus of this study because they represent a critical category of medical devices with a high frequency of recalls. Their importance has also been particularly underlined by their extensive use during the COVID-19 pandemic.

Particularly, our aim is to present recall data obtained from the industry, categorized across different levels of defect classification. By examining this data, we present the crucial role of accurate defect classification in ensuring the safety and reliability of medical device development. Additionally, we offer recommendations for improving how recall root causes are described, which can contribute to enhancing safety protocols and supporting the design of safer medical devices in the future.

To achieve these objectives, we first retrieved recall data from the FDA Database, filtering it by device type, specifically defibrillators to create a focused dataset. We then reviewed existing defect classification methods in the literature, selecting those detailed in Section II as the most appropriate for our study. Using these methods, we applied our classification approach to 271 defibrillator recalls, systematically categorizing them to reveal patterns and trends. Finally, we presented the results of this analysis, offering insights that can inform future improvements in defect management and recall prevention strategies.

The rest of the paper is structured as follows: Section 2 describes related works in the field. Section 3 explains the research approach used in this study. Section 4 addresses the results and analysis of defect classification at different levels. Section 5 addresses the discussions. Finally, Section 6 gives the conclusions.

2. Background and Related Work

The FDA is a highly critical regulatory agency in the United States, responsible for ensuring the safety and effectiveness of food products, pharmaceuticals, and medical devices. One of its important functions is to regulate the recall of medical devices, which occurs when a manufacturer takes a correction or removal action to address a problem due to safety concerns or defects that may present health risks to consumers. The FDA keeps all the records of these recalls to facilitate public awareness, enhance consumer safety, and support ongoing surveillance of medical devices, contributing to improved regulatory practices and promoting accountability among manufacturers [4]. FDA keeps the records of all medical device recalls since 2002, data of previous years are partially retained. The database is accessible from FDA Recall Website [4].

There are also other databases from different countries which keep records of medical devices sold in their countries. European Database on Medical Devices (EUDAMED) in Europe [6], Therapeutic Goods Administration (TGA) [7] from Australia, Medical Device Incident Reporting System (MDIRS) [8] again from Australia are a few examples of these databases. However, the most comprehensive database is maintained by the FDA.

Classification is a systematic methodology for organizing entities into categories based on shared characteristics or attributes. This process is pivotal across various disciplines, including taxonomy in biology, data science, and library science, as it aids in the comprehension and retrieval of information.

2.1. Defect Classification based on Industry Guidance Documents

Industry guidance documents in the context of medical devices are comprehensive resources developed by regulatory authorities to assist manufacturers, stakeholders, and researchers in understanding the regulatory requirements and best practices for the design, development, and commercialization of medical devices.

For the classification process, industry guidance documents are examined to find a predefined root cause taxonomy as an initial step in this study. A guidance which proposes a high level taxonomy for sources of hazardous situations is found in *Infusion Pumps Total Product Life Cycle Guidance for Industry and FDA Staff* [9]. These predefined defect sources are given in Table 1.

Table 1. Defect sources based on infusion pump guidance

| No | Defect Source |
|----|-------------------------|
| 1. | Operational |
| 2. | Environmental |
| 3. | Electrical |
| 4. | Hardware |
| 5. | Software |
| 6. | Mechanical |
| 7. | Biological and Chemical |
| 8. | Use |

These labels are further explained with examples of hazards and potential causes in the guidance to help classification [9]. The unintended operation of pump motors, loose connection between delivery parts, broken valves, among other factors, are classified as “Operational” defect sources. Battery leakage, electromagnetic interference related defects, contamination with toxins, temperature/humidity/air pressure level thresholds are taken as “Environmental” sources. Loose connections between devices, cooling defects, overcharged/undercharged battery, exceeding supply limits are considered as “Electrical” sources. Discommunications, sensor failures, noncalibrated devices and sensors, synchronization errors are classified as “Hardware” sources. Memory and buffer problems, runtime errors, errors arise from updates and version control, data storage or retrieval problems, library related problems are regarded as “Software” sources. Broken or damaged devices, power cords, motors are classified as “Mechanical” sources. Sterilization problems, local reactions, material damages, contamination problems are considered as “Biological and Chemical”. User friendliness of softwares, insufficient training,

accidents caused by users, confusing instructions for use are deemed “Use” sources. These labels are assessed as usable for the initial level of classification.

2.2. Defect Classification based on the FDA Defect Root Causes

We also explored the FDA Recall Search Database [10] to specify any existing predefined root cause options. There are predefined root cause labels which are used as dropdown list on the FDA Recall Database [4]. These predefined possible root causes are given in Table 2.

Table 2. FDA root causes retrieved from [10]

| No | Recall Root Cause Types |
|-----|---|
| 1. | Component Change Control |
| 2. | Component Design/Selection |
| 3. | Counterfeit |
| 4. | Device Design |
| 5. | Employee error |
| 6. | Environmental Control |
| 7. | Equipment Maintenance |
| 8. | Error in labeling |
| 9. | Finished Device Change Control |
| 10. | Incorrect or No Expiration Date |
| 11. | Labeling Change Control |
| 12. | Labeling False and Misleading |
| 13. | Labeling Design |
| 14. | Labeling mix-up |
| 15. | Manufacturing material removal |
| 16. | Material/Component Contamination |
| 17. | Mixed up of materials/components |
| 18. | No marketing application |
| 19. | Nonconforming material/component |
| 20. | Vendor Change Control |
| 21. | PMA |
| 22. | Packaging |
| 23. | Package Design/Selection |
| 24. | Packaging Change Control |
| 25. | Packaging Process Control |
| 26. | Pending |
| 27. | Process Change Control |
| 28. | Process control |
| 29. | Process Design |
| 30. | Radiation Control for Health and Safety Act |
| 31. | Release of Component/Material prior to receiving test results |
| 32. | Reprocessing Controls |
| 33. | Software Design Change |
| 34. | Software manufacturing/software deployment |
| 35. | Software change control |
| 36. | Software Design |
| 37. | Software Design (Manufacturing Process) |
| 38. | Software in the use environment |
| 39. | Storage |
| 40. | Under Investigation by Firm |
| 41. | Unknown/undetermined by firm |
| 42. | Use error |
| 43. | Other |

The Root Cause field in the FDA Database is not mandatory when publishing recalls; consequently, there is limited recall data available for this selection. The handwritten recall reason field provides significantly more information regarding root causes; however, it cannot be utilized for automatic classification and/or filtration. Therefore, the possible root causes identified in FDA Recall Search Database [10] are used as labels for the recalls in this study.

According to researches, four out of every ten medical devices incorporating software have failed due to a problem in the software itself, while compared to the total FDA MD recalls this reaches 18.3% of software failures during this period [11]. The current analysis of recalls has revealed a significant increase in software failures over the past decade. Consequently, a taxonomy to classify software-related causes of recalls was examined, leading to the identification of studies that propose a taxonomy known as “SW91- Classification of Defects in Health Software” [12].

2.3. Defect Classification based on Software Defect Classification in Health Software

ANSI/AMMI SW91:2018 A Framework for Taxonomy Based Testing Using Classification of Defects in Health Software [12] is a recognized standard that provides a structured approach for categorizing and managing defects in health software systems. It includes multi-level defect categories such as parent level and child level from planning to maintenance phase of software development process. There are 194 defect category in total, each defect category has a unique defect code which is part of the hierarchical structure [13].

3. Methodology

In this study, we employed a qualitative research methodology that involved a series of steps to analyze and classify FDA recall data for defibrillators. The process began with the collection and filtering of recall data from the FDA database, focusing specifically on defibrillators. The filtered data was then categorized using a three-level classification framework designed to provide a comprehensive understanding of the recall reasons.

The first level of classification was based on the criteria outlined in [9], which provided a broad categorization of defects. The second level refined this classification using more specific guidelines from [10], allowing for a deeper examination of the issues. Finally, the third level applied a detailed classification based on ANSI/AMMI SW91:2018 [12], which aimed to pinpoint the underlying causes of the recalls with greater precision in software components of medical devices.

After completing the classification process, the results were thoroughly evaluated and verified by two academic experts, ensuring accuracy and reliability. Each of these methodological steps is further detailed in the following paragraphs, providing a clear and structured explanation of our approach.

3.1. Case Data Collection Process

To implement this three-level classification method, it was essential to select a specific medical device that aligns with the objectives of the study. This device class should possess the required features and capabilities to permit accurate data collection and analysis applicable to the classification framework. For this assessment, effects of COVID-19 disease were also addressed. The COVID-19 pandemic had harmful effects on prehospital emergency care worldwide, such as decreasing bystander cardiopulmonary resuscitation (CPR), and increasing delays in emergency medical service (EMS) response time [14]. Defibrillators are critical devices detect sudden, dangerous heart rhythms or a cardiac arrest with many types allowing deep analysis of recalls, so defibrillators were chosen to implement this classification method.

To gather the required data, we initially retrieved 495 recall records for defibrillator-type medical devices from the FDA database [15], covering the period from January 2002 to January 2021. Figure 1 below shows the yearly distribution of the recalled 495 defibrillators. The records were exported into an MS Excel sheet. Each record included columns for Date, Brand Names, Product Description, Product Types, Recall Reason Description, Company Name, and Terminated Recall status. Out of these 495 records, 213 records lacked sufficient information and were excluded from the dataset. This resulted in 282 recall records. During a second review of the data, 11 additional recalls were found to have insufficient information for classification and were removed. Ultimately, 271 recall records remained available for applying the three-level classification method.




Figure 1. Yearly Distribution of Defibrillator Recalls from 2002 to 2021

Available defibrillator types are Dc-Defibrillator, High Energy, (Including Paddles), Tester, Defibrillator, Dc-Defibrillator, Low-Energy, (Including Paddles), Implantable Cardioverter Defibrillator (Non-Crt), Automated External Defibrillators (Non-Wearable), Atrial Defibrillator, Auxiliary Power Supply (Ac Or Dc) For Low-Energy Dc-Defibrillator, Defibrillator, Implantable, Dual-Chamber, Wearable Automated External Defibrillator, Automatic Implantable Cardioverter, With Cardiac, Over-The-Counter Automated External Defibrillator, Permanent Defibrillator Electrodes. This broad selection ensured that a wide array of defibrillator-related recalls could be analyzed.

3.2. Classification Steps

To begin the classification process, we used predefined root causes from the “Pumps Total Product Life Cycle Guidance for Industry and FDA Staff” [9]. All 271 defibrillator recalls were analyzed according to the handwritten manufacturer recall reason field. This stage of the study took approximately 10 person-days to complete.

For the second level classification a deeper analysis is needed. Existing predefined root cause options from FDA Recall Search Database [10] were used as the second level classification labels. This study lasted about 10 person-days and noted that there are different classifications of root causes compared to those provided to the FDA.

The third level of classification focused specifically on recalls identified as software-related. For this, we applied a taxonomy known as “SW91 - A Framework for Taxonomy Based Testing Using Classification of Defects in Health Software” [12]. This allowed for a more precise classification of software-related defects, and this stage of the study took about 15 person-days.

After completing the classification process, all data and results were reviewed by two academic experts with over 20 years of experience in software development. Based on their feedback, approximately 7% of the classifications were adjusted, and the results were subsequently updated to ensure accuracy.

3.3. Validation of the Classification

The defect classification process was initially conducted by the first author of this research. To ensure accuracy and reliability, the classification was reviewed and validated by two academic experts in the software field, both with over 15 years of experience. During the validation phase, each expert reviewed a subset of 60 defects out of the total 271 defects classified. This subset included 30 defects that were common to both experts, facilitating a direct comparison of their assessments. Consequently, 90 unique defects and associated classification were reviewed collectively. It was found that there was a 70% agreement in the experts’ classifications. For the remaining 30% where discrepancies occurred, discussions were held among all three individuals until a consensus was reached. Subsequently, the first author revised the classifications for the remaining 180 items based on the insights gained from these discussions. This comprehensive review and revision process ensured refining the classification outcomes and enhanced both the accuracy and reliability of the results.

4. Results and Analysis

4.1. First Level Classification: Insights from the first level classification are summarized in Table 3. The category with the highest number of recalls was “Hardware,” highlighted in bold, which is expected since much of the data was collected during periods when software played a less critical role in device functionality. The second most frequent category was “Software,” also highlighted in bold. Notably, the proportion of recalls attributed to software has shown an increasing trend in recent years, reflecting the growing importance of software in medical devices.

Table 3. Level 1 classification results

| Count of Level 1 FDA | |
|---------------------------------------|------------|
| Level 1 FDA | Counts |
| Biological and Chemical Sources (BCS) | 17 |
| Electrical (ELC) | 20 |
| Environmental (ENV) | 7 |
| Hardware (HW) | 106 |
| Mechanical (MC) | 16 |
| Operational (OP) | 15 |
| Software (SW) | 58 |
| Use | 9 |
| Not Applicable (NA) | 23 |
| Grand Total | 271 |

As seen from the results, the data at this level of classification is not highly detailed but is still crucial for understanding the primary cause of the issues. The counts provide a general overview of where most problems originate, which can help guide further investigation and corrective actions.

4.2. Second Level Classification: The results of the second level classification are presented in Table 4, with the most frequently occurring categories highlighted in bold. During this process, 53 recalls were reclassified differently from the recall reason field listed in the FDA database, indicating inconsistencies in how FDA data is categorized. The “*Software Design*” category accounted for 49 recalls, making it the second most common reason after “*Non-Conforming Material/Component*”, which had the highest count. The third most frequent category was “*Device Design*” which covered various design-related aspects. Due to the prominence of software-related issues, an additional, more detailed classification was conducted for errors categorized under “*Software*” at the third level. The “*Number of Different Root Causes*” column in the table represents the number of errors we identified as distinct from the root cause specified in the FDA database.

Table 4. Level 2 classification results

| Level 2 Classification Types and Their Counts | | Level 1 Classification Types and Counts | | | | | | | | | |
|---|------------|---|-----------|----------|------------|-----------|-----------|-----------|----------|-----------|---------------------------------|
| | | BCS | ELC | ENV | HW | MC | OP | SW | Use | NA | Number of Different Root causes |
| Component Change Control | 1 | - | - | - | 1 | - | - | - | - | - | - |
| Component Design/Selection | 31 | - | 1 | - | 30 | - | - | - | - | - | 4 |
| Device Design | 47 | - | 12 | 3 | 18 | 8 | 2 | - | 2 | 2 | 6 |
| Employee Error | 6 | - | - | - | 5 | 1 | - | - | - | - | 1 |
| Environmental Control | 1 | - | - | 1 | - | - | - | - | - | - | - |
| Environmental Control / Device Design | 1 | - | - | 1 | - | - | - | - | - | - | 1 |
| Environmental Control / Design | 2 | - | - | 2 | - | - | - | - | - | - | 2 |
| Labeling Design | 1 | - | - | - | - | - | - | 1 | - | - | - |
| False and Misleading Labeling | 10 | 2 | - | - | - | - | 8 | - | - | - | 8 |
| Material / Component Contamination | 7 | 7 | - | - | - | - | - | - | - | - | - |
| Mixed-up of Materials / Components | 1 | - | - | - | 1 | - | - | - | - | - | - |
| Nonconforming Material / Component | 58 | 1 | 6 | - | 50 | 1 | - | - | - | - | 11 |
| Other (end of service life) | 1 | - | - | - | - | - | 1 | - | - | - | 1 |
| Other (guide change) | 2 | - | - | - | - | - | 1 | - | 1 | - | 1 |
| Packaging | 2 | 2 | - | - | - | - | - | - | - | - | - |
| Packaging Change Control | 2 | - | - | - | - | - | - | - | 2 | - | - |
| Packaging Process Control | 1 | - | - | - | - | - | - | 1 | - | - | - |
| Premarket Approval | 7 | - | - | - | - | - | - | - | - | 7 | - |
| Process Change Control | 1 | - | - | - | - | - | - | 1 | - | - | - |
| Process Control | 23 | 3 | - | - | 1 | 1 | 2 | - | 2 | 14 | - |
| Process Design | 6 | - | 1 | - | - | 5 | - | - | - | - | - |
| Software Change Control | 3 | - | - | - | - | - | - | 3 | - | - | 2 |
| Software Design | 49 | - | - | - | - | - | - | 49 | - | - | 11 |
| Software Design Change | 3 | - | - | - | - | - | - | 3 | - | - | - |
| Sw Manufacturing / Sw Deployment | 2 | - | - | - | - | - | - | 3 | - | - | 1 |
| Use Error | 1 | - | - | - | - | - | - | - | 2 | - | 1 |
| Vendor Change Control | 2 | 2 | - | - | - | - | - | - | - | - | - |
| (left blank) | - | - | - | - | - | - | - | - | - | - | 50 |
| Grand Total | 271 | 17 | 20 | 7 | 106 | 16 | 15 | 58 | 9 | 23 | 50 |

4.3. Thrid Level Classification: The final classification was applied to the “*Software*” category from the second level classification using the “*SW91 - Classification of Defects in Health Software*” [12]. The results are summarized in Table 5, with the most frequent categories highlighted in bold. Specifically, the categories **Software Change Control**, **Software Design**, **Software Design Change**, and **Software Manufacturing/Deployment**, as outlined in

Table 4, were analyzed at Level 3. Out of 57 identified defects, 50 recalls were successfully classified, as shown in Table 5. However, 7 recalls, although labeled as software defects, lacked sufficient detailed information for Level 3 classification.

The most common category was “Control State”, indicating the importance of managing software state transitions effectively. “Hardware Usage” was another frequently noted category, which is expected for medical devices that rely heavily on hardware integration. The third most prevalent category was “Dead End Code”, highlighting a common issue where developers leave sections of code without proper exit paths or conditions, leading to scenarios where the software cannot proceed. Additional category ratings can be found in the Table below.

Table 5. Level 3 classification results

| SW91 Mapping | Count of SW91 Mapping |
|--|-----------------------|
| 2.2.2 Requirement Scope | 2 |
| 3.10 Algorithm Selection | 3 |
| 3.11.1 Interrupts/exceptions | 1 |
| 3.11.2 Hardware Usage | 9 |
| 3.12 Failure to Capture Design | 2 |
| 4.1.2.1 Scalar Precision | 1 |
| 4.1.4.4 Data Symbolic Value | 1 |
| 4.10.3 Naming, Data definition, declarations | 1 |
| 4.2.2.2 Reference outside declared bounds | 1 |
| 4.2.9 Cleanup | 1 |
| 4.3.1.2 Dead End Code | 6 |
| 4.3.3.2 Loop Iteration Values | 1 |
| 4.3.4 Control State | 14 |
| 4.9 Missed Design Translation | 2 |
| 5.1.2 Test Case Completeness | 1 |
| 5.2.4 Test Result Verification | 1 |
| 6.1 Release Version or Configuration | 2 |
| 7.5.5 Manufacturer does not test change from third party | 1 |
| Not Available for Classification | 7 |
| Grand Total | 50 |

5. Discussion

Previous classification studies [11][13] has highlighted significant gaps in the way recall data is currently categorized, particularly concerning the reasons behind these recalls. The lack of standardization and precision in recall classification hinder the root causes of defects, making it challenging for manufacturers and regulators to fully understand and address recurring issues. The literature includes various studies examining medical device recalls, the decisions leading to them, and their implications for different stakeholders [16]. For instance, Aaliya Parvin, Sudheer, and Kamaraj [16] focus on Class I medical device recalls from 2022 to 2023. While their study does not specifically address software defects, they note that software malfunctions accounted for 3.3% of recalls, underscoring the critical importance of software integrity in medical devices. Similarly Zuckerman, Brown, and Nissen [17] analyzed high-risk medical device recalls from 2005 to 2009 to evaluate the FDA approval processes used. They categorized the medical devices based on medical specialty. The results showed that 78% of recalled devices were cleared through the less rigorous audit process or were exempt from regulatory review, with cardiovascular devices being the most commonly recalled (31%).

By adopting predefined software-related classification labels, organized into two or three levels as proposed in this study, it becomes possible to bring much-needed clarity to the underlying causes of errors reported during recalls. This structured approach provides a consistent framework that allows for more accurate identification of defect patterns, which can be crucial in improving the reliability and safety of medical devices. Additionally, such a system enables manufacturers to use recall data proactively throughout the product development stages, helping to identify potential risks early on and implement corrective measures before the product reaches the market. For instance, Rajaram et al. [13] propose an approach for implementing taxonomy-based testing within a medical device software organization. Their method utilizes SW91 as the source for defect taxonomies. When combined with our three-level approach, it becomes possible to leverage FDA data to offer preventive solutions, addressing potential issues before they escalate into critical recalls.

The multi-level taxonomy developed in this study not only facilitates more precise and comprehensive recall classification but also establishes a robust foundation for future research efforts. By offering a clearer understanding of defect types and their origins, it paves the way for developing predictive models that can anticipate and prevent recurrent issues in medical device development. Enhancing the precision of classification contributes directly to improving product safety, enabling more effective quality control and risk management practices. Moreover, this refined approach can aid regulatory bodies in better monitoring and managing compliance across the industry, strengthening oversight and encouraging higher standards of safety. Ultimately, this study aims to lead to the production of more reliable and effective medical devices, benefiting both manufacturers and end-users by reducing the likelihood of failures and ensuring safer healthcare outcomes.

5.1. Suggestions for Recall Reason Classification

Improving root cause descriptions in recall databases starts with implementing standardized templates and terminology. By defining a set of standard terms and categories, medical device manufacturers can ensure consistency when documenting recall reasons. Instead of relying on free-text fields, the recall database system could use drop-down menus with predefined options, reducing the variability in language and phrasing. Additionally, integrating semantic search tools and Natural Language Processing (NLP) can help address inconsistencies by allowing users to search for recall reasons based on similar meanings rather than exact wording. For instance, a search for “software failure” could also retrieve entries listed as “software malfunction” or “coding error”, making it easier to identify and analyze related recalls across different manufacturers. NLP can further assist by automatically categorizing and suggesting root cause descriptions, streamlining the data entry process.

To enhance data analysis, machine learning can be used to generate reports that highlight common patterns in the recall data, providing manufacturers with insights on frequently observed defects. This feedback loop can help standardize how these issues are described and classified in future entries, leading to clearer and more consistent root cause documentation.

5.2. Limitations of the Study

The results from the 3rd level classification provided a clearer picture of patterns in recall causes. However, it is important to highlight that while the SW91 analysis aimed to provide a detailed classification, it has not captured all possible defect variations because of device limitation. This limitation indicates that the absence of certain defects in the dataset does not imply they do not exist, but not observed within this limited dataset. To address this concern, future research should be performed with similar classification efforts to a wider range of medical devices ensuring a more comprehensive understanding of defect patterns in the medical device domain.

Additionally, the three-level approach may face challenges in practical application. The granular classification of defects requires detailed data, which may not always be available or consistently reported by manufacturers or regulators. Lastly, the effectiveness of this approach for stakeholders depends on their ability to understand and apply the classification results. Differences in expertise and available resources among stakeholders, such as medical device manufacturers and healthcare providers, may limit its impact on improving device safety and reliability. Gathering input from various stakeholders would offer different perspectives and enhance the defect classification process.

6. Conclusions

In this study, we developed a three-level classification approach to address the existing gaps in the categorization of medical device recalls. This methodology was specifically applied to the FDA recall dataset for defibrillators, covering 271 cases. Proper classification is essential, as it provides a clearer understanding of the underlying causes of recalls, enabling the implementation of more effective preventive measures. By accurately identifying and categorizing defects, manufacturers can address root issues more systematically, leading to improved product safety and reliability.

One of the key contributions of this research is the identification of the most frequently observed recall reasons within defibrillator recalls. By highlighting these common causes, our study offers valuable insights that can help guide safety improvements in medical device design and development. Additionally, our research emphasizes the importance of adopting different levels of classification to detect various types of defects. The three-level approach allows for a more nuanced analysis, where no single level is deemed superior to the others; instead, each provides unique insights that contribute to a comprehensive understanding of defect patterns.

This study also suggests new methods for enhancing recall reason classification, including the integration of NLP and machine learning techniques in recall databases. These advanced approaches can streamline and automate the classification process, leading to greater accuracy and efficiency.

As a future direction, we plan to incorporate large language models (LLMs) into the defect classification process, utilizing them for refined defect class verification based on recall data. This step would help further improve the precision of classification, supporting more reliable safety protocols and contributing to the development of safer medical devices. Additionally; future studies could explore the economic impacts of improved recall classifications. By quantifying the potential cost savings and efficiency gains from enhanced classification processes, research could provide valuable insights into the economic benefits that more accurate and systematic recall management could offer to healthcare providers and manufacturers.

Acknowledgement

We would like to thank Assoc. Prof. Dr. Aysu Betin Can for her assistance in verifying the results of defect classifications.

References

- [1] Subhan, Arif. 2022. Medical Device Recalls. *Journal of Clinical Engineering*, 47.2 (2022): 61-62.
- [2] U.S. Food and Drug Administration, Recalls, Corrections and Removals of Devices, FDA, [Online]. Available: <https://www.fda.gov/medical-devices/postmarket-requirements-devices/recalls-corrections-and-removals-devices>. [Accessed: Dec. 15,-2024].
- [3] Institute of Medicine. 2011. *Public Health Effectiveness of the FDA 510(k) Clearance Process: Measuring Postmarket Performance and Other Select Topics: Workshop Report*. Washington, DC: The National Academies Press.
- [4] U.S. Food and Drug Administration, Recalls, Market Withdrawals, & Safety Alerts, Accessed Sep. 27, 2024. [Online]. Available: <https://www.fda.gov/safety/recalls-market-withdrawals-safety-alerts>.
- [5] H. Alemzadeh, R. K. Iyer, Z. Kalbarczyk and J. Raman, 2013. Analysis of Safety-Critical Computer Failures in Medical Devices, in *IEEE Security & Privacy*, vol. 11, no. 4, pp. 14-26, July-Aug. 2013.
- [6] European Commission. EUDAMED, [Online]. Available: https://health.ec.europa.eu/medical-devices-eudamed/overview_en. [Accessed: Oct. 22, 2024].
- [7] Therapeutic Goods Administration, Recall Actions, [Online]. Available: <https://www.tga.gov.au/safety/recall-actions>. [Accessed: Oct. 22, 2024].
- [8] Medical Device Incident Reporting (MDIR) Guide, [Online]. Available: <https://www.tga.gov.au/resources/resource/user-guide/medical-device-incident-reporting-mdir-guide>. [Accessed: Oct. 22, 2024].
- [9] U.S. Food and Drug Administration, "Infusion Pumps Total Product Life Cycle: Guidance for Industry and FDA Staff," 2018. [Online]. Available: <https://www.fda.gov/regulatory-information/search-fda-guidance-documents/infusion-pumps-total-product-life-cycle>. [Accessed: Dec. 15, 2024].
- [10] U.S. Food and Drug Administration, "Device Classification Resources," [Online]. Available: <https://www.accessdata.fda.gov/scripts/cdrh/cfdocs/cfres/res.cfm>. [Accessed: Sep. 27, 2024]
- [11] Z. Bliznakov, K. Stavrianou, and N. Palikarakis, 2014. Medical Devices Recalls Analysis Focusing on Software Failures during the Last Decade, in *XIII Mediterranean Conference on Medical and Biological Engineering and Computing 2013*, L. Roa Romero, Ed. IFMBE Proceedings, vol. 41. Springer, 2014.
- [12] ANSI/AMMI SW91:2018, *Classification of Defects in Health Software*, American National Standards Institute, 2018.
- [13] H. Rajaram, H. Ketheswarasarma, et al., 2019. *A Framework for Taxonomy Based Testing Using Classification of Defects in Health Software—SW91*, European Conference on Software Process Improvement, Cham: Springer International Publishing, 2019.
- [14] T. S. Iwashita, Y. K. Kitamura, and S. W. Nagao, 2020. Influence of COVID-19 pandemic on bystander interventions, emergency medical service activities, and patient outcomes in out-of-hospital cardiac arrest in Osaka City, Japan, *Resuscitation*, vol. 157, pp. 58-64, 2020. doi: 10.1016/j.resuscitation.2020.10.017.
- [15] U.S. Food and Drug Administration, *Classification of Devices*, Accessed Sep. 27, 2024. [Online]. Available: <https://www.accessdata.fda.gov/scripts/cdrh/cfdocs/cfPCD/classification.cfm>.
- [16] M.J. Aaliya. Parvin., & Kamaraj, R. (2024). A Comprehensive Analysis of Class I Medical Device Recalls: Unveiling Patterns, Causes and Global Impacts. *Cureus*, 16(8), e67542.

[17]Zuckerman, D. M., Brown, P., & Nissen, S. E. (2011). Medical device recalls and the FDA approval process. *Archives of internal medicine*, 171(11), 1006-1011.

Investigation of Pilot Reaction Time on Automatic Ground Collision Avoidance System

Birce Boga^{*1}, Zeynep Seda Mor², Nida Kuşku³

^{*1}TUSAŞ, ANKARA

²TUSAŞ, ANKARA

³TUSAŞ, ANKARA

(Alınış / Received: 26.11.2024, Kabul / Accepted: 30.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Keywords

Ground collision,
Pilot interaction,
Reaction time,
Manual GCAS,
Automatic GCAS,
Flight test

Abstract: In this study it is aimed to compare manual pilot recovery behavior and automatic recovery in case of Controlled Flight into Terrain (CFIT) condition. Several test cases are conducted for random initial conditions in a fixed-based simulator environment and obtained test results are compared. Average pilot reaction time is determined from simulation results. Collected data is used to improve GCAS algorithm design for augmented pilot trust and comfort. The duration required to achieve situational awareness has been examined.

Otomatik Yer Çarpmasından Kaçınma Sistemi için Pilot Tepki Süresinin İncelenmesi

Anahtar Kelimeler

Pilot etkileşimi,
Reaksiyon süresi,
Manuel GCAS,
Otomatik GCAS,
Uçuş testi

Öz: Bu çalışmada Araziye Kontrollü Uçuş (CFIT) durumunda manuel pilot kurtarma davranışı ile otomatik kurtarma davranışının karşılaştırılması amaçlanmıştır. Sabit tabanlı bir simülör ortamında rastgele başlangıç koşullarında çeşitli test senaryoları yürütülmüş ve elde edilen test sonuçları karşılaştırılmıştır. Ortalama pilot reaksiyon süresi simülasyon sonuçlarından belirlenmiştir. Toplanan veriler, pilotun güvenini ve konforunu artırmak amacıyla GCAS algoritma tasarımını geliştirmek için kullanılmıştır.

1. Introduction

The development of advanced aviation systems has significantly enhanced the safety and operational capabilities of modern fighter aircraft. Among these innovations, the Ground Collision Avoidance System (GCAS) stands out as a critical life-saving technology. GCAS is designed to prevent catastrophic accidents by warning pilots of potential ground collisions through aural and visual cues. CFIT occurs when a healthy aircraft collides with terrain because the pilot is unaware of or unable to avoid the danger due to his or her spatial disorientation (which is a cognitive precursor to CFIT) or because of g-force-induced loss of consciousness (G-LOC)[1]. GCAS's more advanced counterpart, the Automatic Ground Collision Avoidance System (AGCAS), takes safety a step further by autonomously intervening to execute recovery manoeuvres when a collision is imminent. These systems are indispensable for mitigating risks in high-performance flight scenarios, particularly in fourth, 4.5, and fifth-generation fighter aircraft. However, the design and implementation of such systems are complex and directly influence pilot interaction and mission success.

AGCAS primarily addresses collision scenarios caused by factors such as G-LOC, loss of situational awareness, and spatial disorientation. These factors are especially prevalent in high-G environments, where pilots may be unable to respond promptly or effectively to hazardous situations. AGCAS leverages predictive algorithms and a mathematical model of the aircraft's dynamics to calculate potential trajectories, including recovery manoeuvres. By intervening at the last possible moment, AGCAS ensures that the aircraft avoids terrain while minimizing

disruption to the mission. Despite its proven effectiveness, the system's automation philosophy and interaction design are critical to its success. Poorly configured systems or inadequate pilot-system integration can lead to mistrust, reduced situational awareness, or even unintended mission risks.

The pilot's role remains central in the operation of AGCAS, even as automation levels increase. Unlike fully autonomous systems, AGCAS is designed to act as a safety net, complementing the pilot's actions rather than replacing them. Therefore, the effectiveness of AGCAS is closely tied to how pilots perceive and interact with the system under various operational conditions. Factors such as reaction time, situational awareness, and trust in the system play a pivotal role in determining its success. Understanding and optimizing this interaction is crucial to enhancing the system's performance and ensuring seamless integration into modern fighter aircraft.

This study aims to investigate pilot interactions with AGCAS and their impact on collision avoidance. By examining reaction times and behavioural responses across different simulated flight scenarios, the research seeks to identify design improvements that enhance both safety and usability. A fixed-based simulator environment provides a controlled setting for testing, enabling the collection of detailed feedback from pilots. Test cases are systematically organized using a flight test card, allowing for comprehensive evaluation of the system's algorithms and their effectiveness in real-world conditions.

The findings of this research will contribute to the ongoing development of AGCAS by addressing the critical balance between automation and pilot control. By optimizing design solutions based on pilot feedback, the study aims to reduce the risk of ground collisions while maintaining operational effectiveness. As fighter aircraft continue to evolve, ensuring the reliability and adaptability of collision avoidance systems will remain a cornerstone of aviation safety.

1.1. Literature review

Forward-Looking Terrain Avoidance (FLTA) algorithms aim to predict potential collisions by projecting the UAV's trajectory into the future and evaluating its interaction with terrain or obstacles. These algorithms are critical for UAVs operating in dynamic or unknown environments. Algorithms with different approaches are found in the literature and are used in air vehicles. These algorithms, which require different subsystems and sensors to function, are optimized with great precision for aircraft to be used in military operational environments, ensuring that they are highly classified.

There are four main approaches and methods for FLTA algorithms. Ray-Casting for Flight Path Simulation, Real-Time Terrain Matching, Potential Field-Based Navigation, and Genetic Algorithm-Enhanced Path Planning Ray-Casting for Flight Path Simulation algorithm, projects the UAV's future trajectory using simulated rays to identify potential obstacles along its path. This method is computationally efficient and allows real-time adjustments in navigation systems, making it suitable for low-altitude operations [8].

Real-Time Terrain Matching systems use onboard sensors to compare real-time terrain data with pre-stored Digital Elevation Models (DEMs). This approach is widely used in military-grade systems such as TERPROM, which matches terrain profiles to provide collision alerts and navigation support [9].

Potential Field-Based Navigation algorithms create virtual repulsion forces around obstacles and attraction forces toward targets, guiding UAVs dynamically through complex terrains. These systems are especially effective in avoiding local minima through advanced optimization techniques [10].

Genetic Algorithm-Enhanced Path Planning algorithms, when combined with geometric obstacle avoidance methods, optimize UAV paths while ensuring collision avoidance. These hybrid systems improve computational efficiency and adapt to dynamic flight scenarios [11].

Some FLTA algorithms have the advantage over others in that they do not require a map of the operational area. Therefore, they offer certain advantages in military UAV operations. FLTA algorithms are extensively used in UAV operations requiring real-time decision-making, such as low-altitude military reconnaissance and autonomous delivery drones. Systems like TERPROM are pivotal for enhancing UAV survivability in unknown terrains [8].

Despite their advantageous capabilities, some FLTA algorithms face limitations such as sensor inaccuracies, dependency on high-resolution DEMs, and computational constraints in real-time operations [7, 8]. Better hardware, higher processing capacity, etc., require detailed trade-off studies in aircraft system design, and typically, high capacities cannot be achieved.

There are six main models for collision risk assessment. These are; Monte Carlo Simulations, Bayesian Inference Models, Causal Network Analysis, Ground Risk Modeling, Mixed Integer Programming for Path Planning, Velocity Obstacle Approach. Collision risk assessment models estimate the likelihood of UAV collisions, considering operational uncertainties. These models are essential for high-risk zones and swarm operations, where multiple UAVs operate simultaneously.

Bayesian models incorporate prior probabilities and real-time sensor updates to calculate collision risks. These models effectively handle sensor uncertainties and provide dynamic risk assessments Bayesian modeling provides a strong probabilistic approach for collision avoidance systems in UAVs prior to a collision. It is especially useful in environmental situations with high uncertainty (e.g., movements of other aircraft). However, challenges such as complexity, computational cost, and data accuracy must also be considered. Therefore, an appropriate balance should be achieved in terms of applicability and efficiency. [13].

Monte Carlo simulations can be a powerful tool for automatic collision avoidance systems in UAVs. Its probability-based approach enhances resilience against environmental uncertainties and various scenarios.

Monte Carlo methods evaluate collision probabilities by running numerous simulations with stochastic variables. This approach is particularly beneficial in scenarios with uncertain terrain data or dynamic environmental conditions. However, challenges such as high computational costs and sensitivity of simulation results should also be considered. This method can be effective in improving UAV safety with a proper control and optimization process, but careful balancing is required in the design for real-time, low-latency systems. [12].

Causal Network Analysis (CNA) can be a powerful tool for collision avoidance systems in UAVs. By using cause-and-effect relationships, it can assess the impact of environmental factors on collision risk, thus enabling the development of safer flight strategies.

Causal models analyze the interdependencies of variables influencing collision risks, identifying critical factors and enabling targeted risk mitigation strategies. However, disadvantages such as complexity, computational costs, and the need for accurate data also exist. Therefore, careful control and optimization processes are necessary for CNA to be effectively applied in automatic collision avoidance systems for UAVs. [14].

Ground Risk Modeling (GRM) is an important tool in collision avoidance systems for UAVs, especially for low-altitude flights such as takeoff and landing, where it offers an effective method to minimize interactions with ground obstacles. Advantages include reducing ground collision risks, the ability to perform real-time analysis, and integrating complex environmental factors. Disadvantages include high computational costs and reliance on sensor accuracy.

Ground risk models evaluate potential hazards to people and property in the event of UAV crashes, guiding flight planning and operational safety. Therefore, effective implementation of GRM requires high processing power, accurate sensor data, and careful modeling. [15].

Mixed Integer Programming (MIP) can be a powerful optimization tool for developing Automatic Collision Avoidance Systems (ACAS) for UAVs. It enables safe route planning while minimizing collision risks and adapting to environmental variables. Advantages include precise solutions, flexibility, and the simultaneous optimization of multiple objectives.

Mixed Integer Programming (MIP) techniques allow for the optimization of multi-vehicle path planning in dynamic environments. These methods are highly effective in ensuring collision-free trajectories in complex scenarios involving multiple UAVs. However, disadvantages include high computational costs, solution time, and complexity. When used in dynamic, real-time systems for UAVs, appropriate optimization techniques or heuristic approaches may be needed to overcome these disadvantages. [16].

The Velocity Obstacle Approach (VOA) is an effective tool in the development of Automatic Collision Avoidance Systems for UAVs. By using real-time velocity obstacle analysis, it prevents collisions with moving obstacles in dynamic environments, ensuring the UAV follows a safe flight path. Advantages include real-time collision avoidance, adaptation to dynamic environments, interaction with multiple obstacles, and efficient computation. However, disadvantages such as limited geometric modeling, computational load, and challenges in complex environments must also be considered.

The velocity obstacle method predicts potential collisions by modeling the relative velocities of UAVs and obstacles. It is widely applied in dynamic environments where real-time adjustments are necessary for collision avoidance [16].

These models are used in UAV swarm management, urban air mobility, and risk mitigation in crowded airspace. They are also pivotal in compliance with regulatory standards for UAV safety [12].

The primary challenges in developing collision risk models include acquiring accurate data, computational resource demands, and integrating these systems into real-time operations [13]. These challenges were also felt within the scope of the study. Along with the relevant classification requirements, the high-security demands for accurate data collection, processing, and later simulation created difficult problems to solve in the study.

2. Material and Method

The development of the GCAS algorithm involves a combination of predictive modelling, real-time data analysis, and integration with the aircraft's control systems. The core of the GCAS algorithm is a mathematical model of the aircraft dynamics, which predicts future trajectories based on current flight parameters such as altitude, velocity, pitch, roll, and heading. These predictions consider terrain data, aircraft performance limits, and recovery manoeuvres to identify potential ground collision risks.

The algorithm is structured into two primary phases, the prediction phase and the action phase. In the prediction phase the aircraft's trajectory is continuously evaluated in real-time to detect if it intersects with the terrain. It uses terrain databases and on-board sensors to identify potential hazards. If a collision is imminent in the action phase, the system triggers a response. In manual GCAS, warnings are issued to alert the pilot, while in automatic GCAS (AGCAS), the system autonomously executes recovery manoeuvres.

There are two automation levels; manual GCAS and automatic GCAS (AGCAS). During manual GCAS; the system provides aural and visual warnings, leaving the recovery decision to the pilot. During automatic GCAS (AGCAS); the system assumes control to execute an automatic recovery manoeuvre at the last possible moment. This minimizes disruption to the mission while ensuring safety.

The three algorithm features are; G-LOC Detection, Dynamic Adaptation and Trajectory Recovery Planning. The G-LOC Detection; incorporates physiological monitoring to detect G-force-induced loss of consciousness and automatically activates recovery protocols. The Dynamic Adaptation; adjusts warning and recovery thresholds based on operational contexts, such as low-level flight or combat scenarios. The Trajectory Recovery Planning; computes a safe recovery path that avoids overstressing the aircraft while maximizing terrain clearance.

The algorithm undergoes iterative testing and validation in simulation environments to refine its accuracy, reliability, and interaction with pilots.

2.1. GCAS algorithm design

The manoeuvre type that is frequently used in GCAS design and is considered the optimum rescue manoeuvre is roll to wings level and 5g pull up [2].




Figure-1. Automatic Ground Collision Avoidance Manoeuvre

The GCAS algorithm mainly uses navigation sensor data, navigation database, flight data computer and pilot control inputs. The algorithm creates a dynamic scan pattern using the velocity, turn rate and dive angle of the aircraft and calculates the estimated trajectory of the aircraft for a certain period of time at every moment.




Figure-2. Dynamic Scan Pattern

The region that the relevant sensors will scan and process, depending on the manoeuvre performed by the UAV, is illustrated in Figure-2. In cases of linear flight, scanning is performed only by the forward-facing sensors, and only these data are processed. The scanning distance dynamically increases or decreases based on the vehicle's speed. For manoeuvres made to the sides, the lateral scanning distance of the vehicle dynamically increases according to the radius of the manoeuvre, and sensor data from the relevant areas are processed. In the case of a high dive, sensor data used during the aircraft's downward manoeuvres are processed.

2.2. Automatic and manual GCAS scenarios

To evaluate the system's performance and pilot interaction, specific manual and automatic GCAS scenarios are designed. Each scenario replicates realistic operational conditions where ground collision risks may arise.

Manual GCAS algorithm does not initiate any automatic manoeuvre. The algorithm initiates aural and visual alerts to the pilot on various displays according to cockpit avionics design. Manual GCAS test campaign aims to test visual and aural warnings timing to prevent nuisance alerts based on the test pilots' comments and define the exact manual recovery point for the pilot guidance [3].

There are two manual GCAS scenarios. In Scenario 1; The terrain avoidance in Low-Level Flight is simulated, simulation goes on with a high-speed, and low-altitude navigation over uneven terrain. The system provides visual and aural alerts for upcoming terrain. The pilot must respond with a corrective manoeuvre. In Scenario 2; there is a sudden Loss of Situational Awareness. Scenario introduces distractions, such as simulated system malfunctions, while approaching a ridge. The system warns the pilot, testing reaction time and situational awareness. [4].

AGCAS algorithm initiates the recovery manoeuvre automatically when recovery condition occurs depending on the design criteria. However; initiation time, type of recovery manoeuvre, pilot control criteria and termination of the automatic recovery manoeuvre depend on the design criteria. The main purposes of AGCAS algorithm flight test are; to measure the success of the algorithm in recovering both aircraft and pilot and how closely automatic system converged to the pilot reactions. The main purpose here is to keep pilot comfort at the highest level during the automatic manoeuvring [5].

In Scenario 1; G-LOC Recovery the pilot undergoes simulated high-G turns to induce temporary loss of consciousness. AGCAS autonomously detects the condition and executes a recovery manoeuvre. In Scenario 2; there is a steep dive interception simulates a combat scenario where the aircraft is in a steep dive. AGCAS intervenes when the trajectory intersects with the terrain, recovering the aircraft with minimal impact on mission parameters.

2.3. Manoeuvres

The GCAS algorithm's effectiveness depends on its ability to execute a range of recovery manoeuvres tailored to different flight scenarios. The manoeuvres are preprogrammed and optimized to ensure both safety and performance.

Pull-Up Manoeuvre is a rapid increase in pitch to climb and avoid terrain. It is designed to prevent aerodynamic stall by considering aircraft speed and angle of attack. Roll and Pull Manoeuvre combines a roll to level the wings with a pull-up manoeuvre. It is ideal for situations where the aircraft is in an inverted or steep bank position. Throttle Adjustment Manoeuvre commands an increase or decrease in thrust during recovery. Ensures energy management without exceeding performance limits. Split-S Recovery Manoeuvre is a combination of roll, pitch, and descent used to reverse course when climbing is not feasible. Primarily used in combat scenarios where upward recovery may expose the aircraft to threats [6, 7].

Each manoeuvre is validated in simulation environments to ensure seamless execution under various conditions, including aerodynamic limits and pilot input overrides.

Moreover, this study does not focus on the rescue manoeuvres performed by the AGCAS. After ensuring the system's situational awareness, rescue manoeuvres should be decided by evaluating both the terrain and environmental conditions, as well as potential threats, collectively.

2.4. Flight test cards

Flight test cards are used to organize and standardize the evaluation process for GCAS and AGCAS algorithms. Each test card defines the parameters, objectives, and success criteria for a given test.

The structure of a flight test card contains; objective, flight parameters, test scenario, success criteria, and data collection. Objective, clearly states the purpose of the test (e.g., evaluate pilot reaction to manual GCAS warnings).

Table 1. An example test card for AGCAS

| | |
|-------------------|---|
| Objective: | Test AGCAS recovery from a steep dive. |
| Parameters: | a, b, c |
| Altitude: | 500 feet AGL (Above Ground Level). |
| Airspeed: | 450 knots. |
| Descent Angle: | 30 degrees. |
| Scenario: | The pilot simulates a dive toward a mountain. AGCAS must detect the collision risk and autonomously recover. |
| Success Criteria: | Recovery occurs before terrain impact. Post-recovery altitude is above 800 feet. Minimal loss of airspeed and mission capability. |

Flight Parameters specifies conditions such as altitude, airspeed, and manoeuvres to be performed. Test Scenario describes the simulated situation (e.g., low-level flight, steep dive). Success Criteria defines the metrics for success, such as reaction time, recovery trajectory, and pilot feedback. Data Collection outlines the instruments and methods for recording flight data, including cockpit video, telemetry, and pilot physiological monitoring.

2.5. Flight test scenarios

The flight test campaign to be prepared for such a system is also quite challenging. Main scope of the flight test campaign is to test the algorithm for both manual and automatic manoeuvring cases. Another scope is collecting pilot reaction time data to improve both manual and automatic algorithms. The evaluation campaign involves a

series of flight test scenarios in a fixed-based simulator environment. Each scenario is designed to replicate real-world conditions while allowing controlled data collection and analysis.

Test scenarios are determined based on different initial conditions consisting of flight parameters such as speed, altitude, Flight Path Angle (FPA), roll angle, etc.

In Low-Level Terrain Navigation; pilots navigate a simulated low-altitude route with varying terrain features. GCAS and AGCAS responses are evaluated under manual and automatic modes.

In Combat Engagement Simulation, involves high-G manoeuvres during a simulated dogfight. Tests AGCAS performance in detecting and recovering from unsafe trajectories.

In Weather-Induced Disorientation, simulates poor visibility and turbulence to assess pilot reliance on GCAS.

The G-LOC and Recovery, subjects' pilots to high-G scenarios to evaluate AGCAS's ability to detect and recover from G-LOC events.

Multiple System Failures, simulates scenarios with partial system failures to evaluate GCAS reliability and redundancy.

2.6. Data collection and analysis

The data collected during flight tests include; Pilot Reaction Time, System Response Metrics, Pilot Feedback, and Physiological Data. Pilot Reaction Time is measured from the time a warning is issued to the initiation of a corrective action. System Response Metrics includes time to recovery, trajectory deviations, and altitude gain. Pilot Feedback is gathered through surveys and debriefing sessions capture subjective evaluations of system usability and trustworthiness. Physiological Data, includes tracks of heart rate, G-tolerance, and cognitive load to understand pilot stress and performance.

The collected data are analysed to identify patterns and areas for improvement in GCAS and AGCAS design. The findings inform iterative refinements to algorithms and interface design, ensuring optimal integration into operational aircraft. By systematically evaluating scenarios, manoeuvres, and algorithms, this study provides a comprehensive assessment of GCAS and AGCAS capabilities, contributing to safer and more effective aviation systems.

GCAS processes data received from relevant sensors (such as GPS, altitude, speed, etc.) according to the selected algorithm and provides the pilot with a warning of a potential terrain collision. On the other hand, AGCAS must also collect data from additional sensors (such as terrain maps, etc.) and internal systems (such as avionics systems, etc.) in order to perform rescue manoeuvres. To execute these manoeuvres, AGCAS collects data from all control sensors as well.

3. Results

Aircraft configuration and test cases are defined in the test card for each different test case. In Figure 3 below, Test Points (TP) are defined with different initial conditions to determine the pilot reactions based on the practicability of each manoeuvre.

These TP's are conducted in a fixed-based simulator environment. Test pilots' comments and data collected during flight test campaign assist to compare manual pilot recovery behaviour with automatic recovery manoeuvre in case of CFIT. Furthermore, collected pilot reaction time during flight tests is another valuable parameter to improve GCAS algorithm design. Improved algorithm according to test results and pilot feedbacks, will increase pilot trust and comfort.

The success criterion for the AGCAS, as evaluated in this study, is how closely the system's response time aligns with that of expert pilots. In this context, the system's performance will be considered better the faster its response time is in comparison to human tests.

This study focuses on both the developed AGCAS and the measurement of the pilots' reaction times and situational awareness response times under varying flight conditions. Therefore, the specific rescue manoeuvre executed by either the pilot or the system is outside the scope of this study.

The graph presented here illustrates the response time of pilots solely based on auditory and visual cues in scenarios where situational awareness is absent. To conduct this analysis, 30 different random cases were generated and tested. Randomization was essential to eliminate any cognitive bias that may have influenced response times in previous tests where pilots were aware of the initial cases presented to them. By sending the initial cases randomly, it was ensured that pilots were not mentally prepared for any specific scenario, thus providing a more accurate representation of true response times. The resulting graph was obtained through repeated testing with randomized initial cases, enabling a comprehensive assessment of pilot reaction times.




Figure-3. Pilot Reaction Time Test Demo Graphic

It appears that the reaction times of the pilots range from 0.42s to -0.39s. The mean value of the distribution is 0.128s. The pilots' reactions were positive in 17 tests and negative in 13 tests.

It was observed that in 43.3% of the TP's, the pilots' reaction times were below zero.

4. Discussion and Conclusion

In some tests, it was observed that the pilots' reaction times were below zero. These negative reaction times represent the pilot responses recorded before the system issued a warning. It is believed that this situation is a result of the pilots' years of training, which allows them to almost reflexively recognize and respond to potential emergency situations.

The reflexive responses given by pilots in stressful situations have demonstrated that pilots are able to provide more predictive responses compared to the system. After evaluating this, the safety coefficient in the GCAS was recalibrated according to the data in the table, bringing the system's behavior even closer to that of the pilot. The developed algorithm was thus better aligned with pilot behaviour.

Testing plan with suitable flight test card is as significant as the design and development activities of the systems with high pilot interaction. These activities require an iterative process and as each step is completed, next iteration is proceeded by applying improvements and updates achieved by the previous step, considering the lessons learned. As these iterations are repeated, the design of AGCAS is improved and step by step progress towards the perfect design, which can never be achieved. Thus, the pilots' comments and understanding of their interactions with autonomous functions are critical.

Forward-looking terrain avoidance algorithms and collision risk assessment models play a vital role in advancing UAV safety and reliability. While these systems have significantly improved operational capabilities, challenges such as sensor limitations and computational demands persist. Future research should focus on enhancing data quality, optimizing algorithms for real-time applications, and integrating these systems into broader UAV operational frameworks.

Rescue maneuvers that could be performed are not included within the scope of this study. Therefore, the selection and execution of applicable rescue manoeuvres involve interdisciplinary studies that could be the subject of future research.

Future developments in artificial intelligence, machine learning and reinforcement learning will directly contribute to the improvement of AGCAS algorithms. While examining pilot behaviour models, future studies should be updated considering the changing new generation of pilot behaviours.

References

- [1] Lyons, Joseph & Ho, Nhut & Abel, Anna & Hoffmann, Lauren & Sadler, Garrett & Fergueson, William & Grigsby, Michelle & Wilkins, Mark. (2017). Comparing Trust in Auto-GCAS between Experienced and Novice Air Force Pilots. *Ergonomics in Design: The Quarterly of Human Factors Applications*. 25. 106480461771661. 10.1177/1064804617716612.
- [2] D. E. Swiharta, A. F. (2011). Design, Integration and Flight Test of an Autonomous Ground. *Gyroscopy and Navigation*, 84–91.
- [3] R. Huffman Jr., M. S. (1998). Application of Ground Collision Avoidance System Nuisance Criteria. *ICAS and AIAA*, 76-85.
- [4] Dr. William B. Albery, C. M. (2003). Differences in Pilot Automation Philosophies in the US and Russian Air Forces Ground Collision Avoidance Systems. OH: Defence Technical Information Center.
- [5] Hoffmann, Lauren. (2019). Assisting the Improvement of a Military Safety System: An Application of Rapid Assessment Procedures to the Automatic Ground Collision Avoidance System. *Human organization*. 78. 241-252. 10.17730/0018-7259.78.3.241.
- [6] Kirkendoll, Zack & Hook, Loyd. (2021). Automatic Ground Collision Avoidance System Trajectory Prediction and Control for General Aviation. 1-10. 10.1109/DASC52595.2021.9594506.
- [7] Lyons, Joseph & Ho, Nhut & Fergueson, William & Sadler, Garrett & Cals, Samantha & Richardson, Casey & Wilkins, Mark. (2016). Trust of an Automatic Ground Collision Avoidance Technology: A Fighter Pilot Perspective. *Military Psychology*. 28. 10.1037/mil0000124.
- [8] Griffiths, S., Saunders, J., Curtis, A., McLain, T. W., & Beard, R. W. (2005). Obstacle and terrain avoidance for miniature aerial vehicles. *Advances in Unmanned Aerial Vehicles*, 213–244.
- [9] Curry, I., & Phipps, D. (1997). TERPROM: The terrain referenced navigation, flight path optimisation and mission planning system. *The Aeronautical Journal*, 101(1008), 189–195.
- [10] Sun, J., Tang, J., & Lao, S. (2017). Collision avoidance for cooperative UAVs with optimized artificial potential field algorithm. *IEEE Access*, 5, 18382–18390.
- [11] Zhou, B., & Zhang, H. (2020). An integrated geometric obstacle avoidance and genetic algorithm TSP solution for UAV path planning. *Drones*, 4(3), 42.
- [12] Kuchar, J. K., & Drumm, A. C. (2005). The traffic alert and collision avoidance system. *Lincoln Laboratory Journal*, 16(2), 277–296.
- [13] Banerjee, A., & Gorospe, G. (2020). Risk assessment of obstacle collision for UAVs under off-nominal conditions. In *Proceedings of the Annual Conference of the Prognostics and Health Management Society*.
- [14] Chen, L., & Tomlin, C. J. (2018). Probabilistic collision avoidance for UAVs using Gaussian mixture models. *IEEE Transactions on Robotics*, 34(3), 828–841.
- [15] Zhang, Y., & Zhang, H. (2021). Safety risk modelling and assessment of civil unmanned aircraft system operations: A literature review. *Drones*, 5(1), 1.
- [16] Schouwenaars, T., De Moor, B., Feron, E., & How, J. P. (2001). Mixed integer programming for multi-vehicle path planning. In *Proceedings of the IEEE European Control Conference* (pp. 2603–2608).
- [17] Fiorini, P., & Shiller, Z. (1998). Motion planning in dynamic environments using velocity obstacles. *The International Journal of Robotics Research*, 17(7), 760–772.