



ADIYAMAN ÜNİVERSİTESİ

Mühendislik Bilimleri Dergisi

Journal of Engineering Science
of Adiyaman University



ISSN: 2149-0309

CİLT
VOLUME **11**

SAYI
ISSUE **24**

ARALIK
DECEMBER

2024



ADİYAMAN ÜNİVERSİTESİ

Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi
Journal of Engineering Science of Adıyaman University

ISSN: 2149-0309

Cilt:11 Sayı:24

Volume:11 Issue:24

Yazışma Adresi/Correspondence Address:

Adıyaman Üniversitesi Mühendislik Fakültesi

e-mail: mbd@adiyaman.edu.tr

mfs@adiyaman.edu.tr

tgoksu@adiyaman.edu.tr

BAŞ EDİTÖR/EDITOR-IN-CHIEF

Doç. Dr. M. Fatih ŞAHAN

İnşaat Mühendisliği, İnşaat Mühendisliğinde Sayısal Modelleme, Yapı Dinamiği, Yapı Mühendisliği, Kompozit Malzeme Mekaniği

EDİTÖR YARDIMCILARI/ ASSISTANT EDITORS

Doç. Dr. Sercan YALÇIN

Bilgi ve Bilgi İşleme Bilimleri, Görüntü İşleme, Ağ Oluşturma ve İletişim, Derin Öğrenme, Nöral Ağlar

Dr. Öğr. Üyesi Taha Tuna
GÖKSU

Mühendislik, Akışkan Akışı, Isı ve Kütle Transferinde Deneysel Yöntemler, Akışkan Akışı, Isı ve Kütle Transferinde Hesaplamalı Yöntemler (Hesaplamalı Akışkanlar Dinamiği Dahil)

EDİTÖRLER KURULU/EDITORIAL BOARD

Prof. Dr. Yavuz DEMİRCİ

Çevresel Biyoteknoloji, Çevresel Biyojeokimya, Çevre Mühendisliği, Arıtma Tesisi Tasarımı, Atık Yönetimi, Azaltma, Yeniden Kullanım ve Geri Dönüşüm

Doç. Dr. Abdurrahman
ÖZBEYAZ

Bilgi ve Bilgi İşleme Bilimleri Algoritmalar ve Hesaplama Kuramı Derin Öğrenme Yapay Zeka (Diğer)

Doç. Dr. Miraç UÇKUN

Gıda Bilimleri ve Mühendisliği

Dr. Öğr. Üyesi Ahmad Reshad
NOORI

İnşaat Mühendisliği, İnşaat Mühendisliğinde Sayısal Modelleme

ALAN EDİTÖRLERİ / SECTION EDITORS

Prof. Dr. Yavuz DEMİRCİ	Çevresel Biyoteknoloji, Çevresel Biyojeokimya, Çevre Mühendisliği, Arıtma Tesisi Tasarımı, Atık Yönetimi, Azaltma, Yeniden Kullanım ve Geri Dönüşüm
Doç. Dr. Abdurrahman ÖZBEYAZ	Bilgi ve Bilgi İşleme Bilimleri Algoritmalar ve Hesaplama Kuramı Derin Öğrenme Yapay Zeka (Diğer)
Doç. Dr. Sercan YALÇIN	Bilgi ve Bilgi İşleme Bilimleri, Görüntü İşleme, Ağ Oluşturma ve İletişim, Derin Öğrenme, Nöral Ağlar
Doç. Dr. Miraç UÇKUN	Gıda Bilimleri ve Mühendisliği
Doç. Dr. Musa EŞİT	Atmosfer Bilimleri, Hidroloji
Prof. Dr. Harun TÜRKMENLER	Arıtma Tesisi Tasarımı, Çevre Kimyası, Su ve atıksu arıtma, Toprak Kirliliği ve Kontrolü, Yenilenebilir Enerji Kaynakları
Dr. Öğr. Üyesi Taha Tuna GÖKSU	Mühendislik, Akışkan Akışı, Isı ve Kütle Transferinde Deneysel Yöntemler, Akışkan Akışı, Isı ve Kütle Transferinde Hesaplamalı Yöntemler (Hesaplamalı Akışkanlar Dinamiği Dahil)
Dr. Öğr. Üyesi Sabih OVALI	Lif Teknolojisi
Dr. Öğr. Üyesi Faruk KÜRKER	Elektrik-Elektronik Mühendisliği, Elektrik Enerjisi ve Güç Sistemleri, Elektrik Tesisleri
Dr. Öğr. Üyesi Ahmad Reshad NOORI	İnşaat Mühendisliği, İnşaat Mühendisliğinde Sayısal Modelleme
Dr. Arş. Gör. Timuçin Alp ASLAN	İnşaat Mühendisliği, İnşaat Mühendisliğinde Sayısal Modelleme, Yapı Dinamiği
Arş. Gör. Abuzer DOĞAN	Bilgisayar Mühendisliği

DANIŐMA KURULU / ADVISORY BOARD

Prof. Dr. Beytullah Temel	İnŐaat Mühendisliğinde Sayısal Modelleme Yapı Dinamiđi Katı Mekanik
Prof. Dr. Őemsettin TEMİZ	Katı Mekanik, Kompozit ve Hibrit Malzemeler, CAD/CAM Sistemleri
Prof. Dr. Naki TŪTŪNCŪ	Katı Mekanik, Makine Mühendisliğinde Sayısal Yöntemler
Prof. Dr. Özgür ÖZDEMİR	Arıtma Tesisi Tasarımı, Altyapı Mühendisliği ve Varlık Yönetimi, Su Hasadı, Su Kaynakları ve Su Yapıları, Atıksu Arıtma Süreçleri, Kalite Yönetimi, Hidroloji
Prof. Dr. Adem ERSOY	Madencilik Yöntemleri ve Maden Sistem Analizi, Metalik Madenler
Prof. Dr. Gaye KAYA	Tekstil Bilimleri ve Mühendisliği
Prof. Dr. Mehmet Burhan KARAKOÇ	İnŐaat Mühendisliği, Betonarme Yapılar, Yapı Malzemeleri
Prof. Dr. Selahattin KOCAMAN	Görüntü İşleme, Akışkan Mekaniđi ve Termal Mühendislik, Akışkan Akışı, Isı ve Kütle Transferinde Hesaplamalı Yöntemler (Hesaplamalı Akışkanlar Dinamiđi Dahil), Su Kaynakları ve Su Yapıları
Prof. Dr. Cem ONAT	Akıllı Robotik, Makine Teorisi ve Dinamiđi
Doç. Dr. YaŐar AYZ	Katı Mekanik
Dr. Öğr. Üyesi İsmail Ünsal	Betonarme Yapılar Deprem Mühendisliği İnŐaat Mühendisliğinde Sayısal Modelleme Yapı Malzemeleri Yapı Mühendisliği Mühendislik Tasarımı FRP donatılı betonarme kiriŐler Lif takviyeli beton Betonun darbe davranışı
Dr. Öğr. Üyesi Saadin OYUCU	Bilgisayar Bilimleri ve Mühendisliği, Bilgisayar Sistem Yazılımı, Bilgisayar Yazılımı, Gömülü Sistemler, Veri Tabanları, Yapay Zeka

İÇİNDEKİLER / TABLE OF CONTENTS

	Makale Başlığı	Yazarlar	Sayfa
1	Boya Malzemesinin Kabulü İçin Blokzincir Tabanlı Akıllı Sözleşme Algoritması Geliştirilmesi	Önder Halis Bettemir, Ali Uzunkaya	387-401
2	Real-Time Personal Protective Equipment and Warehouse Safety Detection with Deep Learning-Based Workplace Camera	Abdil Karakan, Yüksel Oğuz	402-414
3	6 Şubat 2023 Kahramanmaraş Merkezli Depremler Sonrasında Adıyaman İlindeki Betonarme Yapılarda Oluşan Hasarların Malzeme ve İşçilik Problemlerine Bağlı Olarak İncelenmesi	Mahmut Başsürücü, Murat Pala	415-427
4	An Analysis of Apache Spark and Gpu Performances on Database SQL Queries for Distributed Networks	Kemal Güner, Mehmet Turan, Emin Tenekeci	428-437
5	Metaheuristic Multi-Objective Optimization Approach for Repetitive Construction Project Scheduling	Gülçağ Albayrak	438-454
6	Toplam Harmonik Bozulma Seviyesinin Reaktif Güç Kompanzasyonuna Bağlı Değişimi	Faruk Kürker	455-474
7	Veri Ön İşleme Tekniklerinin Sağlık Verilerinin Sınıflandırma Başarısına Etkisinin İncelenmesi	Vahit Tongur, Feyza Erdoğan, Betül Uzbaş	475-488
8	Ann Kullanarak Çelik Fiberli Geopolimer Betonların Eğilme Dayanımının Tahmini	Necip Altay Eren	489-501
9	Effect of Glass Industry Waste on the Physical, Mechanical, and Durability Properties of Slag-Based Geopolymer Composites Produced with a Ternary Alkali Activator System	Mahfuz Pekgöz, İlker Tekin	502-515
10	Arazi ve Arsa Düzenlemelerinde Mahkeme Kararlarına Dayalı İptal İşlemlerinde Geri Dönüş Süreçlerinin Analizi: Meram İlçesi Örneği	Yaşar İnceyol	516-532
11	Cost-Benefit Analysis of Pressure Management Practices In Drinking Water Systems	Salih Yılmaz, Merve Akdemir	533-546
12	Derin Öğrenme ile Çevresel Atıkların Sınıflandırılmasına Dayalı Akıllı Çöp Konteyneri Tasarımı ve Prototipinin Geliştirilmesi	Mehmet Umut Salur, Nermin Elmas, Aybuke Nur Koçak, Melike Kaymaz	547-563

BOYA MALZEMESİNİN KABULÜ İÇİN BLOKZİNCİR TABANLI AKILLI SÖZLEŞME ALGORİTMASI ÖNERİSİ

Ali UZUNKAYA¹, Önder Halis BETTEMİR^{2*}

^{1,2}İnönü Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Malatya, 44200, Türkiye

Geliş Tarihi/Received Date: 13.07.2024 Kabul Tarihi/Accepted Date: 29.09.2024 DOI: 10.54365/adyumbd.1515460

ÖZET

Blokzincir tabanlı akıllı sözleşme algoritmalarının yaygınlaşması ile sözleşme koşullarının uygulanması hızlanmakta ve üçüncü taraflara ödenen komisyon maliyetleri önemli ölçüde azalmaktadır. Bu çalışmada blokzincir tabanlı akıllı sözleşme algoritması ile bir inşaatın boya işlerinin gerçekleştirilmesi için maliyet, süre ve kalite hususlarını dikkate alarak süreci yönetebilecek bir çerçeve sistem önerilmiştir. İnşaat öncesi hazırlanan iş programı, metraj değerleri, sözleşmede tanımlanan kalite, renk ve sınıf tariflerini dikkate alan akıllı sözleşme algoritması ne zaman ve ne kadar boya malzemesine ihtiyaç duyulacağını belirlemektedir. Önceden anlaşılan tedarikçinin stok durumu dikkate alınarak zamanında teslimat yapma imkânı değerlendirilip teslimat süreci başlayan malzemenin ön ödemesi gerçekleştirilmektedir. Barkod ve renk kodu okumalarıyla boyanın sözleşmede belirtilen standartlara uygunluğu kontrol edilmektedir. Ödemeler blokzincir aracılığıyla kripto paralarla yapılacağından, üçüncü taraflara ödenecek komisyonlar azalacaktır. Önerilen sistemle, malzeme siparişi ve teslimat süreçlerindeki insan müdahalesi ve hatalar en aza indirilecek, proje paydaşları arasındaki anlaşmazlıklar azalacak, süreç hızlanacak ve maliyetler düşecektir.

Anahtar Kelimeler: Blokzincir, akıllı sözleşme, tedarik yönetimi, kalite kontrol, sözleşme yönetimi

PROPOSAL OF A BLOCKCHAIN-BASED SMART CONTRACT ALGORITHM FOR PAINT MATERIAL ACCEPTANCE

ABSTRACT

Implementation of contract terms is accelerated and commission costs paid to third parties are significantly reduced with the widespread use of blockchain-based smart contract algorithms. In this study, a framework system that can manage the process by taking into account the cost, time and quality issues for the realization of the painting works of a construction with a blockchain-based smart contract algorithm is proposed. Taking into account the work schedule, bill of quantities prepared before construction, as well as the quality, color and class descriptions defined in the contract the smart contract algorithm determines when and how much paint material will be needed. Considering the stock status of the previously agreed supplier, the possibility of timely delivery is evaluated and prepayments are made for the material for which the delivery process has started. The conformity of the paint to the standards specified in the contract is checked through barcode and color code readings. Commissions to be paid to third parties will be reduced, since payments will be made with cryptocurrencies through the blockchain. With the proposed system, human intervention and errors in material ordering and delivery processes will be minimized, disputes between project stakeholders will be reduced, the process will accelerate and costs will decrease.

Keywords: Blockchain, smart contract, supply management, quality control, contract management

* e-posta¹: aliuzunkaya94@gmail.com ORCIDID : <https://orcid.org/0009-0002-4580-2739>

e-posta²: onder.bettemir@inonu.edu.tr ORCIDID: <https://orcid.org/0000-0002-5692-7708> (Sorumlu Yazar)

1. Giriş

İnşaat mühendisliğinin yapım yönetimi bilim dalının önemli bir araştırma alanı sözleşme yönetimidir. Gelişen teknoloji ile ortaya çıkan blokzincir teknolojisi tabanlı akıllı sözleşme yönetimi proje ve sözleşme yönetimi sürecinde taraflar arası iletişimin güçlenmesi, belge işlem sürelerinin ve maliyetlerinin azaltılması, anlaşmazlıkların çözümü ve kalite kontrolünün sağlanmasında önemli faydalar sağlama potansiyeline sahiptir.

Blokzincir teknolojisinin tarihi, Bitcoin'in 2008 yılında Satoshi Nakamoto takma adını kullanan bir kişi veya grup tarafından yayınlanan teknik incelemesi ile başlar. Bu beyaz kitap blokzincirin temellerini ve merkezi olmayan bir defter olarak işlev gören Bitcoin'in çalışma ilkelerini açıklamaktadır. Bitcoin, blokzincir teknolojisinin ilk uygulamasıdır ve kripto para birimleriyle ilgili işlemleri güvence altına almak için blokzincir kullanır. Blokzincir, işlemlerin bağlantılı ve zaman damgalı bir dizi blok halinde saklandığı bir defterdir. Her blok bir önceki bloğun karmasını içerir, bu nedenle veriler geriye dönük olarak değiştirilemez. Söz konusu yapı, merkezi otoritelere güvenmek yerine, dağıtık ağdaki katılımcıların onayına bağlı olarak güvenlik açısından daha güvenilir ve esnek bir veri yönetimi sağlamaktadır [1]. Blokzincir, merkezi olmadığı için verilere erişimde güvenlik ve gizlilik sağlar. Ayrıca veri değişikliklerini izlemek ve veri bütünlüğünü sağlamak için dağıtılmış bir defter kullanır. Blokzincirin şifreleme, izlenebilirlik ve akıllı sözleşmeler gibi özellikleri, hassas verileri korumak ve yetkili erişimi kontrol etmek için etkili bir çözüm sağlar. Blokzincirinin dağıtık yapısı güvenlik, bütünlük, veri paylaşımı ve hassas verilerin korunmasındaki zorlukları giderme potansiyeli sunmaktadır [2].

Blokzincir teknolojisi güvenli, şeffaf ve değişmez bir kayıt sistemi sağladığı için taraflar arasındaki güveni artırır. Verimliliği ve veri güvenliğini artırarak inşaat süreçlerinde tedarik zinciri yönetimi, proje yönetimi, belge yönetimi ve ödemelerin gerçekleştirilmesi aşamalarında kullanılabilir. Tedarik zinciri yönetiminde, malzemelerin başlangıçtan son kullanıcılara kadar teslimatını izlenebilir hale getirilerek malzeme kayıplarının azaltılması, sahte ürünlerin tespit edilmesi ve tedarik zincirinde şeffaflık sağlanabilir [3].

Kripto para, dijital olarak oluşturulan ve şifrelemeyle güvence altına alınan dijital bir varlıktır. İşlemlerini kriptografik algoritmalarla şifreleyerek güvence altına alır ve merkezi bir otoriteye ihtiyaç duymadan çalışır. Çok yaygınlaşmış kripto para birimlerinin bazıları aşağıda sunulmuştur.

- Bitcoin (BTC): İlk ve en popüler kripto para birimi olan Bitcoin, blokzincir teknolojisine dayanır ve diğer kripto para birimlerinin temelini oluşturur.
- Ethereum (ETH): Ethereum, akıllı sözleşmelerin yürütülmesini sağlayan bir platform ve kripto para birimidir. Ethereum ayrıca genellikle diğer projeler için token (ERC-20) oluşturmak için kullanılır.
- Ripple (XRP): Ripple, özellikle finansal kurumlar arasında hızlı ve düşük maliyetli para transferleri için kullanılan bir kripto para birimidir. XRP, Ripple ağının yerel para birimidir.
- Litecoin (LTC): Litecoin, Bitcoin'in bir çatalı olarak bilinir. Litecoin, daha hızlı blok onay süreleri ve farklı bir algoritma kullanarak Bitcoin'e alternatif bir dijital para birimi olarak ortaya çıkmıştır.
- Cardano (ADA): Cardano, akıllı sözleşme ve blokzincir uygulamaları geliştirmek için tasarlanmış bir platform ve kripto para birimidir. Cardano akademik araştırma önceliklidir ve güvenlik, sürdürülebilirlik ve ölçeklenebilirliğe odaklanmaktadır.

Kripto paranın faydaları; Merkezi bir otoriteye ihtiyaç duymadan çalışarak güvenli bir yapı sunması, hızlı ve düşük maliyetli para transferlerine olanak sağlaması, küresel olarak kullanılarak sınır ötesi işlemleri kolaylaştırması, işlemlerin şeffaf bir şekilde izlenebilir ve değişmez olması, akıllı sözleşmeler aracılığıyla otomatik ve programlanabilir işlemler gerçekleştirme olanağı sunması, finansal

erişimi artırarak bankacılık hizmetlerine erişimi olmayan kişiler için alternatif bir ödeme yöntemi olması olarak sıralanabilir [4].

Blokzincirinin varlığı Bitcoin'in ortaya çıkışıyla başlamış olsa da günümüzde blokzinciri kripto para ile sınırlı değildir. Daha yaygın olarak kullanılabilen ve çeşitli sektörlerde inovasyonu teşvik eden bir teknoloji haline gelmiştir. Blokzinciri teknolojisi, merkezi otoritelerin yerini alma ve güvenilir ve şeffaf bir veri tabanı sağlama potansiyeline sahiptir. Blokzincir teknolojisinin temel amacı, merkezi bir otoriteye ihtiyaç duymadan güvenli ve şeffaf bir veri tabanı sağlamaktır. Başta kripto para birimleri olmak üzere birçok farklı sektörde kullanılan Blokzincir işlemlerin güvenliğini, veri bütünlüğünü ve izlenebilirliğini artırırken araçları da ortadan kaldırma potansiyeline sahiptir. Blokzincir, banka veya kamu kurumu gibi üçüncü taraf bir aracıya ihtiyaç duymadan para, mülk, varlık, malzeme ve sözleşmeleri aktarabilir. Verilerin bir blokzincirine kaydedildikten sonra değiştirilmesi çok zordur. Blokzincirinin güvenilirliği, verilerin değişmezliğine ve şeffaflığına dayanır. Bir blok onaylandıktan sonra geri alınamaz hale gelir. Her düğüm ağdaki işlemlerin geçmişini doğrulayabilir ve bunlara erişebilir. Bu şeffaflığı artırır ve veri manipülasyonunu önler. Blokzincir üzerinde çalışan kriptografik algoritmalar ile veriler güvence altına alınır. Her işlem veya blok matematiksel olarak doğrulanır. Blokzincir üzerinde çalışabilen uygulamalar sayesinde işlemler belirli koşullar karşılandığında tetiklenerek blokzincir üzerinde otomatik olarak yürütülebilir.

Kripto cüzdanlar, kullanıcıların dijital varlıkları yönetmelerine, alıp göndermelerine ve saklamalarına olanak tanıyan yazılım veya donanımlardır. Blokzincir cüzdanları, kullanıcıların kripto varlıklarını güvenli bir şekilde saklamasına ve işlem yapmasına olanak tanır. Bu cüzdanlar, bir banka hesap numarasını andıran genel anahtarlar ve varlıklara erişmek için kullanılan bir PIN kodunu temsil eden özel anahtarlar içerir. Cüzdan Türleri aşağıdaki gibi sıralanabilir [5].

Web Tabanlı Cüzdanlar: Bir internet tarayıcısı üzerinden erişilebilen cüzdanlardır. Genellikle kullanıcı dostu arayüze sahiptir ve çevrimiçi olarak saklanırlar. Ancak güvenlik riskleri nedeniyle dikkatli kullanılmalı ve güvenilir platformlar tercih edilmelidir.

Mobil Cüzdanlar: Akıllı telefon uygulaması olarak kullanılabilen cüzdanlardır. Kullanımı kolaydır ve hareket halindeyken erişilebilirlik sağlarlar. Çevrimiçi veya çevrimdışı olarak mevcuttur.

Masaüstü Cüzdanları: Bilgisayarlar için yazılım uygulamaları olarak kullanılan cüzdanlardır. Kullanıcı tarafından kontrol edilen bir ortamda çalıştıkları için daha yüksek güvenlik sağlarlar.

Donanım Cüzdanları: Fiziksel cihaz şeklindeki cüzdanlardır. Özel anahtarları güvenli bir şekilde saklarlar ve çevrimdışı ortamlarda kullanılabilirler. Bu nedenle güvenlik açısından en güvenilir seçenek olarak kabul edilirler.

Blokzincir cüzdanları Cüzdan Adresi olarak tanımlanan, kullanıcının kripto para birimlerini depoladığı adresleri içerir. Her cüzdanın işlemler için kullanılan benzersiz bir adresi vardır. İşlemleri imzalamak ve doğrulamak için Özel Anahtarlar olarak tanımlanan kriptografik anahtarlar kullanılır. Kullanıcının cüzdanındaki kripto varlıklarına erişim sağlayan cüzdanın güvenliği için gereklidir. Bu anahtarlar gizli tutularak güvenli bir şekilde saklanmalıdır. İşlem: Blokzincir cüzdanları aracılığıyla kripto para alma, gönderme ve yönetme işlemleri kullanıcının özel anahtarı kullanılarak imzalanır, ağdaki düğümler tarafından doğrulanır ve blokzincirine eklenir. Varlıklar ilgili hesaplar arasında transfer edilir. Blokzincir cüzdanlarının güvenlik önlemleri aşağıdaki listede sıralanmıştır.

Özel Anahtar Güvenliği: Güvenliği son derece önemli olan özel anahtarların çalınmasını veya kaybolmasını önlemek için güvenli bir depolama yöntemi kullanılmalıdır.

Kimlik Doğrulama: Blokzinciri cüzdanlarına erişim sağlamak için Şifre, PIN veya biyometrik veriler kimlik doğrulama yöntemleri olarak kullanılabilir.


Güvenilir Cüzdan Sağlayıcıları: Güvenilir ve güvenlik önlemleri ile donatılmış cüzdan sağlayıcılarını seçmek, güvenliği iyice araştırmak ve güvenilir platformları kullanmak önemlidir.

Blokszincir cüzdanları kullanıcılara kripto para birimlerini güvenli bir şekilde saklama, yönetme ve işlem yapma olanağı sunar. Kullanıcıların özel anahtarlarını korumaları ve güvenilir cüzdan sağlayıcılarını seçmeleri önemlidir.

Blokszincir teknolojisinin çalışma prensibinde önce müşteri bir işlem talep eder. İşlem kripto para, sözleşmeler, kayıtlar veya diğer bilgileri içerebilir. İstenen işlem düğümler yardımıyla bir P2P ağına yayınlanır. Düğüm ağı, bilinen algoritmalar yardımıyla işlemi ve kullanıcının durumunu doğrular. İşlem tamamlandığında, yeni blok mevcut blokszincirine kalıcı ve değişmez bir şekilde eklenir. Blokszincirinin güvenilirliği, verilerin değişmezliğine ve şeffaflığına dayanır. Bir blok onaylandıktan sonra geri alınamaz hale gelir. Her düğüm ağdaki işlemlerin geçmişine erişip doğrularak şeffaflığı artırır ve veri manipülasyonunu önler [4].

Blokszincirini oluşturan her bir blok, blok içindeki verilerin bir özetini temsil eden ve bloğa özgü bir parmak izi olarak değerlendirilebilecek benzersiz bir hash'e sahiptir. Bir bloğun hash'i, blokta depolanan verileri temsil eden verilerin birleştirilmesi ve hash'lenmesi ile elde edilir. Her blok bir önceki bloğun hash'ini içerir ve blok hashleri bloklar arasında bir zincir oluşturmak için kullanılır. Bu şekilde bloklar birbirine zincirlenir ve her bloğun geçerliliği bir önceki bloğun hash değeri ile ilişkilendirilerek blokszincirini yüksek güvenli hale getirir.

Bir blok bir önceki bloktan gelen işlem verileri, zaman damgaları, hash değeri gibi çok sayıda veri içerir. Bloktaki tüm veriler tek bir veri parçasında birleştirilir. Bu veri parçası bloğun içeriğini temsil eder. Hash Fonksiyonu: Bir veri parçası bir hash fonksiyonuna uygulanır. Hash fonksiyonu bir veri parçasını alır ve belirli bir algoritma kullanarak sabit boyutlu bir hash oluşturur. Hash Değerinin Elde Edilmesi: Hash fonksiyonu blok hash'ini oluşturmak için veri parçasını işler. Bu hash, bloğun benzersiz kimliğini temsil eder.



Şekil 1. Blok hash uygulamasının örnek gösterimi

Şekil 1'de belirtilen adımlar, blokların birbirine zincirlendiği ve her bloğun bir önceki bloğun hash değerine göre doğrulandığı bir blokszinciri oluşturur. Şekil 1'de, blok 1'in ilk blok olduğu 3 blokluk bir zincire sahip bir blokszinciri gösterilmektedir. Bu nedenle, kendinden önce gelen bir blok yoktur ve önceki bloğun hash değerini içeremez. Blok 2, blok 1'in hash'ini içerirken blok 3, blok 2'nin hash değerini içerir. Bir bloğun verileri değiştirilirse, bloğun hash değeri değişir ve bu durum komşu bloğun önceki hash değeri kontrol edilerek tespit edilebilir. Bu, blokszincirinde yapılan herhangi bir değişikliği izlenebilir ve doğrulanabilir hale getirir. Blok karmaları blokların bütünlüğünü ve güvenilirliğini sağlar.

İnşaat projelerinde birçok paydaş arasında imzalanan ve yürütülen sözleşmeler karmaşık olabilir ve çatışmalara yol açabilir. Blokszincir teknolojisi akıllı sözleşmeler yoluyla sözleşme yönetimini de kolaylaştırabilir. Blokszincir teknolojisi üzerinde çalışan ve otomatik olarak yürütülen dijital sözleşmeler akıllı sözleşmeler olarak tanımlanır. Geleneksel sözleşmelerden farklı olarak bir anlaşmanın şartlarını kodlar ve programlar aracılığıyla belirler ve yerine getirirler. Akıllı sözleşmeler, programlanabilir ve otomatik olarak uygulanan sözleşme kuralları sağlayarak güven oluşturur ve taraflar arasındaki çatışmaları azaltmaya yardımcı olur.

Akıllı sözleşmeler finans, tedarik zinciri yönetimi, emlak, sigorta gibi birçok alanda ve çeşitli uygulamalarda kullanılabilir. Koşulların otomatik olarak yerine getirilmesi, işlemleri hızlı ve güvenilir hale getirerek araçların ve maliyetlerin azaltılmasına yardımcı olur. Bununla birlikte, akıllı sözleşmeler kodlama hataları ve çakışma sorunlarından dolayı ortaya çıkabilecek bazı zorluklara sahip olabilir. Bu nedenle dikkatli bir şekilde tasarlanmalı ve kontrol edilmelidirler. Akıllı sözleşmelerin blokzinciri entegrasyonu ile uygulanmasının avantajlarından bazıları aşağıda listelenmiştir.

Sözleşme Koşullarının Tanımlanması: Akıllı sözleşme uygulamalarında kodlama yoluyla anlaşmanın şartları ve kuralları tanımlanır. İki veya daha fazla taraf arasında bir anlaşma yapıldığında, sözleşme şartları bir akıllı sözleşme programına çevrilir. Şartlar, komut dosyası dilleri veya özel akıllı sözleşme platformları kullanılarak belirlenir. Bu nedenle anlaşma sırasında yapılan işlemlerle ilgili tüm koşulların sözleşmede tanımlanmış olması ve ihtilaf oluşturabilecek hiçbir açık koşulun bulunmaması gereklidir.

Blokzincir üzerinde çalışan akıllı sözleşmeler, inşaat projelerinde sözleşme yönetimini kolaylaştırır. Programlanabilir ve otomatik olarak uygulanan sözleşme kuralları sayesinde taraflar arasında güven sağlanır. Akıllı sözleşmeler, ödeme planları, proje tamamlama ve performans dayalı ödemeler gibi konularda otomatik işlem yapabilir [2-3, 6-9].

Dağıtık Yapı: Blokzincir, merkezi bir otoriteye veya aracıya ihtiyaç duymadan işlem yapabilen bir sistemdir. Bu güvenilirlik ve güvenlik sağlarken, katılımcılar arasında doğrudan etkileşimi mümkün kılarak maliyetleri azaltabilir ve işlemleri hızlandırabilir [1, 4, 10]. Akıllı sözleşmeler blokzincirin dağıtık yapısını kullanarak çalışır. Blokzincir ağındaki düğümler tarafından yürütülür ve her düğüm tarafından doğrulanır. Bu, sözleşmenin herhangi bir merkezi otoriteye veya üçüncü bir tarafın güvenilirliğine ihtiyaç duymadan yürütülmesini sağlar.

Otomatik Yürütme: Akıllı sözleşmeler belirli koşullar sağlandığında otomatik olarak yürütülür. Belirli bir tarihe gelindiğinde ya da önceden tanımlanmış belirli bir olay gerçekleştiğinde sözleşmede belirtilen eylemler gerçekleştirilir. Bu, insan müdahalesine gerek kalmadan sözleşme şartlarının yerine getirilmesini sağlar.

Sorunların Hızlı Çözümü: İnşaat projelerinde sıkça karşılaşılan anlaşmazlıklar, tartışmalar ve hataların giderilmesi zaman alabilir. Blokzincir teknolojisi, yapılan değişikliklerin geriye dönük olarak izlenebilmesi ve doğrulanabilmesi sayesinde sorunların hızlı bir şekilde çözülmesine yardımcı olabilir. Bu da projelerin zamanında tamamlanma olasılığını ve müşteri memnuniyetini artırır [1,8,11].

Artan Şeffaflık: Blokzinciri, tüm sözleşmeye dayalı işlemlerin izlenebilirliğini sağlayan değişmez ve şeffaf bir defter görevi görür. Gerekli verilere erişebilen ve projenin ilerlemesi hakkında bilgilenen projenin tüm paydaşları arasında güven oluşur ve inşaat projelerinde şeffaflığı artırır [8,12-15].

Maliyet ve Verimlilik: Geleneksel sistemlerde araçlar güvenilirlik için ek maliyetlere ve zamana neden olur. Blokzincir araçları ortadan kaldırarak doğrudan paydaşlar arası işlemlere olanak sağlayarak işlem maliyetlerini düşürür. Blokzincir teknolojisi inşaat süreçlerinde verimliliği artırabilir ve maliyetleri düşürebilir. Örneğin tedarik zinciri yönetiminde malzeme kayıplarının azaltılması kaynakların daha verimli kullanılmasını sağlar. Ayrıca, otomatikleştirilmiş süreçler, veri paylaşımında kolaylık ve doğruluk sağlayarak zaman ve kaynak tasarrufuna katkıda bulunur. Otomatik tetikleyicilere dayalı akıllı sözleşmeler, manuel iş süreçlerini azaltır ve belirli koşulların yerine getirilmesiyle ilgili işlemleri otomatikleştirerek işgücü, zaman ve kaynak maliyetlerinden tasarruf sağlar [3-4,11-18].

Veri Güvenliği: Blokzinciri teknolojisi güvenlik önlemleriyle desteklenerek verilerin merkezi olmayan bir yapıya kavuşturulmasını ve güvenli bir şekilde saklanmasını sağlar. Veriler kriptografik algoritmalar kullanılarak şifrelenir ve bloklara eklenerek verilerin güvende tutulmasını sağlar. Ayrıca blokzinciri ağları, dağıtık yapısı nedeniyle tek bir noktanın saldırıya uğraması veya veri kaybı riskini azaltır [9-10, 17, 19-21].

Veri Bütünlüğü: Blokzincirindeki her işlem, bloklar arasındaki bağlantı sayesinde geriye dönük olarak doğrulanabilir. Veriler bir kez kaydedildikten sonra değiştirilemez ve silinemez hale getirilerek

veri bütünlüğü sağlanır ve veri manipülasyonu önlenir. Blokzinciri, veri değişikliklerinin izlenebilmesini ve kayıtların geriye doğru takip edilebilmesini sağlar. Her blok, bir önceki bloğun verilerinin kriptografik bir bağlantısına sahiptir. Bu nedenle yapılan tüm değişikliklerin, kim, ne zaman ve nereden yapıldığı bilgilerine kolayca erişilir ve verilerin değişmezliği sağlanır. Blokzinciri teknolojisi, inşaat projelerindeki verilerin güvenilirliğini artırıp verilerin değiştirilemez bir şekilde kaydedilmesini ve izlenmesini sağlayarak veri bütünlüğünü korumaktadır [2, 4, 6-7, 9-10, 17, 19-20].

Tedarik Zinciri Yönetimi: Blokzincir inşaat sektöründe tedarik zinciri yönetimini iyileştirebilir. Malzeme tedarik sürecinde, tedarikçiler ve lojistik şirketleri verileri gerçek zamanlı olarak paylaşabilir ve malzeme tedarikini daha verimli bir şekilde yönetmeyi mümkün kılarak maliyetleri azaltabilir ve projelerin zamanında tamamlanmasına yardımcı olabilir [22].

İş birliği ve Paydaş Yönetimi: İnşaat projeleri genellikle farklı paydaşların iş birliği yapması gereken karmaşık süreçlerdir. Blokzincir, paydaşlar arasında veri paylaşımını ve gerçek zamanlı iş birliğini kolaylaştırarak iletişimi hızlandırır ve projenin ilerleyişinin takibini ve sorunları çözmeyi kolaylaştırır. Proje belgeleri, revizyonlar ve değişiklikler gibi bilgiler paydaşlar arasında anında güncellenir ve yetkili tüm katılımcılar tarafından erişilebilir. Bu da projelerin daha etkin bir şekilde yönetilmesini sağlar ve iletişim hatalarını azaltır. Blokzincir, proje paydaşları arasında veri paylaşımını kolaylaştırır. Merkezi olmayan bir veri tabanı olduğu için projeye dâhil olan tüm taraflar verilere güvenli bir şekilde erişip güncel bilgilere anında ulaşabileceği için iletişimi geliştirir, bilgi akışını hızlandırır ve projenin verimliliğini artırır [3, 8, 14-17].

Akıllı sözleşme ve ürün teslimatı arasındaki ilişki Şekil 2'de gösterilmektedir.



Şekil 2. Örnek bir akıllı sözleşme uygulamasının işlem adımlarının gösterimi

Blokzincir tüm paydaşların gerçek zamanlı olarak ürünlerin menşei, hareketleri ve durumu hakkında bilgi sahibi olmasını sağlayarak tedarik zincirlerinde şeffaflığı önemli ölçüde artırır [23]. Bu sayede sahtecilik, dolandırıcılık ve hataların önlenmesi kolaylaşır. Manuel veri girişlerini ortadan kaldırıp işlemleri otomatikleştirerek blokzincir teknolojisi tedarik zincirlerinde verimliliği artırıp

zamandan ve paradan tasarruf sağlar. Verileri şifrelenmiş bir şekilde dağıttık bir depoda tutarak, siber saldırılara ve veri kayıplarına karşı güvenliği önemli ölçüde artırır. Erişimi yalnızca yetkili kullanıcılara sınırlandırarak yetkisiz erişimi engeller. Blokzincir teknolojisi, tedarik zincirindeki tüm aktörler arasında güven ve iş birliğini teşvik eder. Bu sayede daha sağlam, güvenilir ve sürdürülebilir tedarik zincirleri oluşturulabilir. Blokzincir, işlemleri otomatikleştirerek ve şeffaflığı artırarak tedarik zincirlerindeki maliyetleri düşürerek karlılığı ve rekabet gücünü artırabilir.

Blokzincir, yapay zekâ (YZ) ve nesnelerin interneti (IoT) teknolojilerine entegre edilerek inşaat projelerinde daha fazla otomatikleştirilmiş, veri odaklı ve akıllı karar mekanizmaları oluşturulabilir. Blokzincirin inşaat sektöründe daha yaygın bir şekilde kullanılabilmesi için standartların oluşturulması ve düzenlemelerin geliştirilmesi gerekmektedir. Bu sayede güvenilirlik, güvenlik ve uyumluluk ile ilgili veri standartları oluşturulup söz konusu standartlar sağlanarak sektördeki tüm aktörlerin faydalanması mümkün olacaktır.

Blokzincirin getirdiği yeni teknolojiler, inşaat sektöründe çalışanların yetkinliklerinin geliştirilmesi ve yeni beceriler kazanmaları ihtiyacını ortaya çıkarmaktadır. Bu nedenle eğitim programlarının güncellenmesi ve yeni yeteneklerin kazandırılması önemlidir. Blokzinciri teknolojisinin inşaat mühendisliği ve yapım yönetimi sektöründe sunmuş olduğu potansiyel, şeffaflık, güvenilirlik ve izlenebilirlik gibi temel faydaları sayesinde gelecekte sektörün daha verimli, hesap verebilir ve sürdürülebilir bir şekilde çalışmasına olanak sağlayacaktır. Blokzincir teknolojisi, şeffaflık sağlayarak, malzemelerin kaynağını ve sürdürülebilirlik özelliklerini izlemeyi kolaylaştırabilir.

Blokzincir teknolojisi ve robotik gerçeklik yakalama teknolojisinin inşaat sektöründe ödeme süreçlerini otomatikleştirmek için kullanılabilir [24]. Geleneksel ödeme yöntemlerine kıyasla daha hızlı, daha ucuz ve daha az hata eğilimli olduğu için inşaat sektöründe ödeme süreçlerini önemli ölçüde iyileştirme potansiyeli vardır. Blokzincir teknolojisi veri yönetimi ve paylaşımı için yeni bir paradigma sağlayabilir [25]. Verilerin güvenliğini, şeffaflığını ve erişilebilirliğini önemli ölçüde artırma, sağlık hizmetleri, finans ve kamu gibi çeşitli sektörlerde veri yönetimi uygulamalarında verimlilik artırma potansiyeli vardır.

Hesap verebilirliği artırarak, sürdürülebilirlik taahhütlerinin yerine getirilmesini sağlayabileceği için blokzincir teknolojisinin inşaat sektöründe sürdürülebilirliği geliştirmek için önemli bir araç olabilecektir [26]. Blokzincir teknolojisi, tedarik zincirindeki tüm paydaşların ürünlerin ve malzemelerin menşei, hareketi ve durumu hakkında gerçek zamanlı bilgilere erişmesini sağlayarak şeffaflığı artırabilir. Bu sayede sahtecilik, dolandırıcılık ve hataların önlenmesi kolaylaşır. Otomasyonla veri girişini ortadan kaldırarak zamandan ve paradan tasarruf sağlarken, hata payını da düşürür. Verileri dağıtılmış veri tabanında saklayarak ve erişimi yetkililere sınırlandırarak güvenliği artırıp tedarik zincirinde şeffaflığı sağlar. Tüm paydaşlar arasında güveni ve iş birliğini teşvik ederek daha sağlam ve sürdürülebilir tedarik zincirleri oluşturur. Otomasyon ve şeffaflıkla maliyetleri düşürerek karlılığı ve rekabet gücünü de artırır [27].

Tedarik zinciri yönetimi, proje yönetimi ve yapı bilgi modelleme (YBM) alanlarında blokzincir teknolojisinin yaygın olarak kullanılmaktadır [28]. Bulut bilişimde veri bütünlüğünü korumak ve doğrulamak için blokzincir teknolojisini kullanan Merkle ağacı tabanlı bir akıllı sözleşme algoritması önermiştir [29]. Algoritma bulut sunucularındaki veri bütünlüğünü korumak için geleneksel yöntemlere göre daha güvenli ve sağlam dağıtılmış bir yaklaşım sunar. Deneylede geleneksel yöntemlere kıyasla önemli ölçüde daha iyi performans göstermiştir. Blokzincir teknolojisi sahtecilik, dolandırıcılık ve hataları önleyip, veri paylaşımını ve iş birliğini kolaylaştırdığı ve tedarik zinciri yönetimine destek olmaktadır [30]. Ayrıca şeffaflık, hesap verebilirlik ve izlenebilirlik sağlayarak sözleşme yönetimi, ödemeler ve risk yönetimi gibi alanlarda önemli faydalar sağlamaktadır [31].

İnşaat projelerinde kalite kontrolünü otomatikleştirmek ve geliştirmek için blokzincir ve yapay zekâ teknolojilerini birleştiren bir yöntem önererek üretim süreçlerinde şeffaflık, hesap verebilirlik, verimlilik ve güvenlik sağlayabileceğini ve üretim sektöründe daha geniş bir şekilde benimsenebileceğini göstermiştir [32]. Blokzincir teknolojisinin üretimde kalite kontrolünü otomatikleştirme ve geliştirme potansiyelini inceleyerek, bu alanda inovatif bir yöntemi ortaya

koymuşlardır. Hash fonksiyonları gibi güvenlik protokollerinin, veri bütünlüğünü ve güvenliğini sağlayarak, blokzincir teknolojisinin üretim süreçlerinde şeffaflık, hesap verebilirlik, verimlilik ve güvenlik sağlayabileceğini göstermiştir.

Blokzincir teknolojisinin inşaat sektöründeki mevcut durumu, karşılaşılan zorlukları ve gelecekteki potansiyel uygulamalarını incelenmiş ve tedarik zinciri yönetimini optimize etme, sözleşme yönetimini basitleştirme ve akıllı sözleşmeler gibi alanlarda inşaat sektörüne önemli faydalar sağlayabileceğini ortaya konmuştur [33]. Bu teknolojiye tam fayda sağlanabilmesi için teknik altyapı eksikliği, yasal ve düzenleyici belirsizlikler gibi bazı engellerin ve zorlukların da aşılması gerekmektedir. Blokzincir teknolojisi sözleşme yönetimi, ödemeler ve risk yönetimi gibi alanlarda şeffaflık, hesap verebilirlik ve izlenebilirliği sağlayarak altyapı geliştirme projelerinde verimliliği ve sürdürülebilirliği arttırabilecektir [31]. Blokzinciri teknolojisinin sözleşme yönetimi, ödeme işlemleri, malzeme tedarik zinciri yönetimi, değişiklik yönetimi ve kalite kontrolü gibi alanlarda faydalı olabilecektir [34].

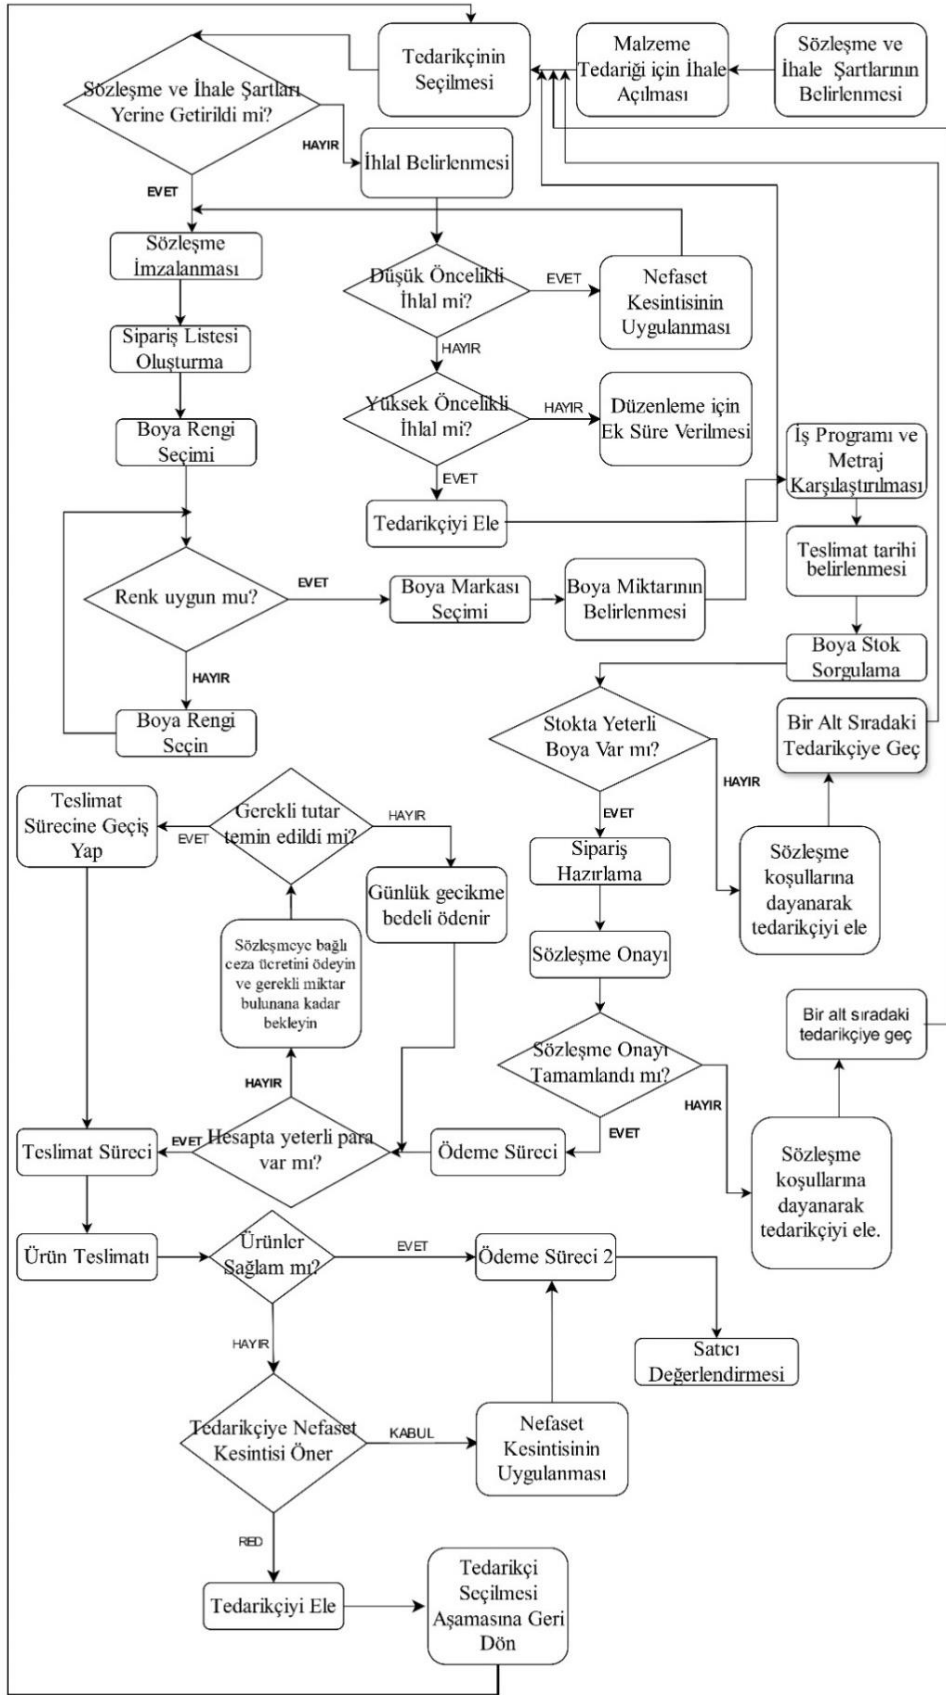
Blokzincir teknolojisi tedarik zinciri yönetiminde şeffaflık ve hesap verebilirlik sağlama, sahteciliği önleme, sözleşme yönetiminde akıllı sözleşmelerle maliyet ve zaman tasarrufu sunma, proje yönetiminde ilerlemeyi izleme ve ödemeleri otomatikleştirme, veri yönetiminde güvenli depolama ve paylaşım, sürdürülebilirlikte ise enerji tasarrufu ve atık yönetimini optimize etme imkanı sunmaktadır [8].

Blokzincir; kalite bilgilerinin merkeziyetsizleştirilmesi, veri bütünlüğünün sağlanması ve izlenebilirlik gibi avantajlar sunmaktadır. İnşaat yaşam döngüsü boyunca verilerin güvenli ve şeffaf bir şekilde kaydedilmesini sağlayarak, veri manipülasyonu ve kaybı sorunlarını çözebilmektedir [35].

Sunulan literatür taraması blokzincir ve akıllı sözleşme uygulamalarının inşaat sektörüne önemli faydalar sağladığını göstermektedir. Fakat inşaat sektörünün blokzincir ve akıllı sözleşme tekniklerinin gerçek anlamda potansiyel faydalarından yararlanamadığı da görülmektedir. Belirtilen potansiyel faydalarından yararlanabilmek ve inşaat sektörüne blokzincir ve akıllı sözleşmelerin uygulama alanlarını derinlemesine inceleyebilmek için bu çalışma gerçekleştirilmiştir. Malzeme tedariki inşaat projelerinde sorunların ortaya çıkabileceği kritik bir süreç olduğu için bu çalışmada blokzincir tabanlı akıllı sözleşme uygulaması ile boya iş kalemine ait malzeme siparişi ve tesliminin gerçekleştirilmesine yönelik bir çerçeve sistem tanımlanması amaçlanmıştır. Akıllı sözleşmelerin kullanımıyla malzeme teslim süreçlerini iyileştirerek gecikmelerin, hatalı teslimatların ve sözleşme şartlarına uymayan ürünlerin teslim edilmesinin önüne geçilmesi hedeflenmektedir. Blokzincir tabanlı akıllı sözleşme algoritması ile sözleşme koşulları tanımlanacak ve teslim edilen malzemelerin bu koşullara uygunluğu denetlenecektir. Sözleşme koşullarına uygun malzemeler kabul edilecek ve ödemeler yapılacaktır. Malzeme talepleri, siparişler, sevkiyatlar ve teslimatlar otomatik olarak izlenecek ve eksiklikler tespit edilecektir. Bu sistem taraflar arasındaki anlaşmazlıkları azaltmayı ve ödemelerin doğru ve zamanında yapılmasının sağlanması da amaçlanmaktadır. Bu sistemle birlikte inşaat sektörünün de blokzincir uygulamalarına bir katkı sağlanması amaçlanmaktadır. Algoritmanın detayları yöntem bölümünde önerilmiş, ardından boya kabul algoritmasının potansiyel faydaları üçüncü bölümde tartışılmıştır. Sonuç bölümünde ise çalışma sonlandırılmıştır.

2. Yöntem

Bu çalışmada, inşaat sürecinin yönetilmesinde işveren, yüklenici, altyükleniciler ve tedarikçilerin eşit şekilde haklarının korunduğu bir akıllı sözleşme algoritmasının geliştirilmesi hedeflenmiştir. İnşaatın tüm iş kalemleri ile ele alınmasının kapsamı çok geniş olacağı için bu çalışma boya işleri ile sınır tutulmuştur. İnşaat projesinde yer alan tarafların boya işi ile ilgili sorumlulukları belirlenerek akıllı sözleşme algoritması oluşturulmuştur. Önerilen algoritmanın akış şeması Şekil 3'te sunulmuştur.



Şekil 3. Akıllı Sözleşme Önerilen akıllı sözleşme algoritmasının akış şeması

2.1. Sorumlulukların Tanımı

İşveren, kullanılacak boyanın kimyasal özelliklerini, kalite standartlarını ve renk kodlarını detaylı bir şekilde tolerans aralığı belirterek tanımlar. İşveren ayrıca finansal kaynakları sağlayarak yürütülen işlerle ilgili ön ödemeleri ve işin tamamlanmasını müteakip yapılması gereken ödemeleri zamanında ve miktarında gerçekleştirmekle sorumludur. İşveren ödemelerin zamanında gerçekleştirilebilmesi için sözleşmede belirtilen banka hesabında gereken tutarı bulundurup ödemeyi yapmakla sorumludur. Akıllı sözleşme ödeme koşulları gerçekleştirildiğinde belirlenen ödeme planına göre tedarikçiye ödemeleri yapar ve işverene ödeme durumunu bildirir. Boya teslimatı sırasında, işverenin tanımladığı koşullara göre kalite kontrolünü yapar. İş programı ve metraja göre teslim edilen boyaların miktar ve zamanının uygun olup olmadığını kontrol eder.

Yüklenici, boya işlerinin işverenin belirlediği teknik detaylara ve kalite standartlarına uygun yürütülmesinden sorumludur. Boyanın tedarik sürecinin sağlıklı yürütülmesinden tedarikçilerle birlikte ortak sorumludur. Ayrıca gerekli işçi ve ekipmanların temininden ve iş güvenliği önlemlerinin alınmasından sorumludur. İnşaat sırasında teslimatı gerçekleşen boyaların uygun depolama koşullarında muhafaza edilerek fiziksel ve kimyasal özelliklerinin korunmasını sağlar. Buna ek olarak yüklenici boya kullanımını ve kalan miktarı düzenli olarak raporlayarak blokzincire bilgi akışını sağlar.

Tedarikçi, sözleşme koşullarını sağlayan kalite ve nitelikteki malzemeyi zamanında istenilen yere teslim etme sorumluluğuna sahiptir. Ayrıca istenilen miktardaki malzemeyi stoklarında bulundurmak veya tedarik edebilecek duruma getirmek için gerekli hazırlıkları yapma yükümlülüğünü taşımaktadır. Hatalı renk veya nitelikteki boya teslimatı sonucu oluşabilecek iş gecikmelerinden sorumlu olacaktır.

Blokzincir tabanlı akıllı sözleşme tedarik sürecinde, akıllı sözleşme, yükleniciye otomatik bildirimler göndererek teslimat tarihlerine ve ödeme aşamalarına dair güncel bilgileri iletir. Akıllı sözleşme algoritması ile süre, miktar ve kalite koşullarına uygunluğun onaylanması ile boyalar teslim alınır ve teslimat onaylandığında, tedarikçiye otomatik ödeme yapar ve teslimatın tamamlandığını taraflara bildirir. Gerçekleştirilen iş miktarını kaydederek iş programının uygun yürütüldüğünü de denetler. Akıllı sözleşme, tüm bu süreçlerin şeffaf, verimli ve otomatik bir şekilde yönetilmesini sağlayarak işveren ve yüklenicinin haklarını korur ve projedeki iş birliğini güçlendirir. Önerilen algoritmanın akış şeması Şekil 3'te sunulmuştur.

2.2. Sözleşme Şartlarının Belirlenmesi

Önerilen algoritma yerel standartların yerine getirilmesini sağlamayı amaçlamaktadır. Bu nedenle boya malzemesi için TSE 14.0.30.4.34.00/TSE 64550, 000917-TSE-28/01, TS 5808/14.06.2012, TS5808/T1/18.06.2014 standartlarının sağlanması gerekmektedir. Sözleşme için ödeme planı oluşturulur ve siparişin kabulü için ödenecek peşinat tutarı, malzeme teslim edildiğinde ödenecek oran, iş tamamlandığında ödenecek tutar ve teminat kesintileri sisteme tanımlanır. Bu çalışmada tüm bedelin %10'u ürün teslim için rezerve edildiğinde, %80'i teslimat gerçekleştiğinde, kalan %10'unun ise teslimattan 30 takvim günü sonra yüklenicinin kalite olurluğunu vermesinin ardından ödenmektedir. Ürün teslimatının gecikmesi; hatalı, kusurlu veya eksik ürün teslimi; belirlenen süre içerisinde teslimatın yapılmaması gibi durumlarda ödenecek cezai bedeller belirlenmiştir. Ürünün teslim edileceği adres sözleşmede belirtilir.

Sözleşme İhlalinin Belirlenmesi: Sözleşmede belirtilen durumlar dışında bir eksiklik ya da sorun olması halinde ihlalin hangi derecede olduğu karar verilir.

Yüksek Öncelikli İhlal: Şartnamede belirtilen kanun maddeleri, deprem yönetmelikleri, imar kanununda ve borçlar kanununda yer alan maddelerde tanımlanan hükümlerin sağlanmaması veya kısmen sağlanması, kullanılan malzemelerin sağlığa zarar verici kimyasallar içerip insan sağlığını tehdit edecek durumda olması yüksek öncelikli ihlal olarak tanımlanmakta ve tedarikçi ile yapılan sözleşmenin fesih edilmesini gerektirir.

Orta Öncelikli İhlal: Yüksek öncelikli ihlalde tanımlanan binanın ruhsat almasına engel olabilecek kritik hususların dışında kalan fakat ödün verilemez durumdaki koşulları içermektedir. Belirtilen ihlal gerçekleştiğinde ek süre verilmeden teslim edilen malın iadesi sağlanır. Tedarikçi ile yapılan sözleşmenin iptali gerçekleşmez. Bu sayede yeni tedarikçi bulmak için zaman harcanmaz ve mevcut tedarikçi gereken uyarıyı almış olur.

Düşük Öncelikli İhlal: Yüksek ve orta öncelikli ihlal gibi kritik ve ödün verilemez noktada olmayıp sadece ödün verilebilir düzeyde renk tonu ihlali gibi işverenin oluru sonrası sadece nefaset kesintisi ile cezalandırılabilir ihlallerdir.

Nefaset Kesintisi: Bir işin sözleşmede öngörülen standartlara uygun bir şekilde yapılmaması halinde işi yaptırmanın işi yapana eksik ödeme yapmasına imkân veren ve cezai şartta benzeyen bir uygulamadır.

Sipariş Listesi Oluşturma: Siparişler bir iş programı ile ilişkilendirilir, depolama sıkıntısı ve ürün dejenerasyonu riski nedeniyle tüm siparişler aynı anda teslim edilmez. İş programına göre gerekli malzeme listesi ve teslimat tarihleri oluşturulur ve sipariş verme işlemi akıllı sözleşme ile gerçekleştirilir.

Boya Rengi Seçimi: Sipariş listesinde yer alan boya malzemeleri renk sensörü tarafından gerçekleştirilen ölçüm sonuçları sözleşmede belirtilen renk skalası ile karşılaştırılır ve uygunluğu tayin edilir. Talep edilen boya stokta yok ise sözleşmede tanımlanan renk aralığındaki renkte boyanın teslimatına izin verilir.

Renk Sensörü ile blokzincir tabanlı akıllı sözleşme algoritması kullanarak boya teslimi yapılır. Mikrodenetleyiciye bağlanan renk sensörü ile akıllı sözleşmede belirtilen rengin seçimi ve kontrolü yapılır. Teslimatı yapılacak malzemenin istenilen renk skalasında olduğunda proje paydaşlarına olumlu kabul bildirimini yapılır. Yapı malzemelerinin teslimatındaki renk kontrolü renk sensörleri kullanılarak yapılır.

Renk sensörleri, kırmızı, yeşil ve mavi renk kanallarını ölçerek renk bilgisini sağlar. İlk olarak mikrodenetleyici kartı (Arduino Leonardo) ve bir renk sensörü (TCS3200) kullanılmıştır. Mikrodenetleyici kütüphane yöneticisinden, renk sensörü kullanımını kolaylaştırmak için gerekli kütüphane eklenir. Mikrodenetleyici IDE arayüzünde yeni bir proje oluşturulur ve renk sensörü ile iletişim kurmak için bir mikrodenetleyiciye renk sensörünü tanıtan ve komutların hangi port üzerinden gireceğini tanımlayan kodu yazılır.

Boya Markası Seçimi: Sipariş listesindeki malzemeler hem kalite, hem de istenilen renk tonu olarak ayarlanır ve marka seçimi yapılır. İstenilen marka bulunamazsa marka öncelik sırasına göre bir sonraki marka aynı teslimat koşulları uygulanarak teslimat uygunluğu test edilir.

Boya Miktarının Belirlenmesi: Boya miktarının belirlenmesinde iş programı ve metraj değerleri kullanılarak gerekli malzeme miktarı ve teslim zamanı insan müdahalesi olmadan hesaplanır. Sözleşmede ve inşaat programında belirtilen ilgili tarih için teslim edilecek marka ve renk aralığındaki boya miktarı ağırlık sensörü ile kontrol edilip belirlenir. Teslimat miktarı, inşaatın metraj teklifi ve inşaat programı ile sağlanır.

Ağırlık sensörü akıllı sözleşmede ve iş programında tanımlanan yapı malzemesinin kütlesini ölçerek siparişe uyumlu olup olmadığını teyit etmektedir. Ağırlık sensörleri, genellikle bir yük hücresi veya strain gauge sensörü kullanılarak tasarlanır. Bu sensörler, üzerine nesne konulduğunda veya bağlandığında meydana gelen deformasyonu ölçer ve bu deformasyonun büyüklüğüne bağlı olarak ağırlığı belirler. Mikrodenetleyici ile ağırlık sensörünü kullanmak için, bir Mikrodenetleyici kartı, ağırlık sensörü (yük hücresi veya strain gauge sensörü) ve HX711 ADC (Analog-to-Digital Converter) kartı, kullanılır. Mikrodenetleyici IDE üzerinden HX711 kütüphanesi eklenir ve bu kütüphane aracılığıyla sensörden gelen analog veri dijital forma çevrilerek ağırlık değerleri belirlenir.

İş Programı ve Metraj Karşılaştırılması: Boya miktarının belirlenmesi için hali hazırda olan iş programına bakarak gereken metrajın çıkarılıp hangi gün ne kadar boya gerekeceğini bilerek gerekli stok takibinin yapılması sağlanır.

Boya Stok Sorgulama: Hazırlanan sipariş listesi tedarikçinin stok durumu ile karşılaştırılır ve sözleşmeye girilir. Stokta yeterli malzeme varsa sepete eklenir, yoksa bildirim oluşturularak müşteri ve tedarikçi bilgilendirilir.

Sipariş Hazırlama: Stok durumunun yeterli olduğu tespit edildikten sonra sipariş hazırlama süreci devreye girer. Talep edilen siparişler en kısa sürede hazırlanarak teslimata hazır hale getirilir.

Sözleşme Onayı: Tedarikçi tarafından tedarik edilen malzemeler sözleşmedeki tüm koşulları yerine getiriyorsa hem müşteri hem de satıcı onay verir ve ürünler stoklanır.

Ödeme Süreci: Ürünler satıcının deposundan transfer edildiğinde ve teslim edilen miktar satıcının stoklarından düştüğünde, sözleşmede belirtilen ödeme tutarı müşterinin hesabından tedarikçinin hesabına aktarılır.

Teslimat Süreci: Siparişin sözleşmede belirtilen teslim süresi içerisinde müşteriye teslim edilmesi gerekmektedir. Nakliye sırasında ürünlerin bozulması veya hasar görmesi durumunda ürünlerin teslimatı gerçekleştirilmeyecek ve stok çıkışında ödenen tutar müşteriye iade edilecektir. Teslimatta gecikilen her gün için sözleşmede belirtilen tutar kadar kesinti yapılacaktır. Ürünün sorunsuz teslim edilmesi halinde sözleşme yöneticisi tarafından teslim onayı oluşturulur. Ürünün tesliminde belirtilen güzergâh takip edilerek ürün getirilmelidir.

Ürün Teslimatı: Ürünün kalite kontrolü şantiye şefinin yetkilendirdiği saha mühendisli tarafından yapılır ve onaylanması halinde ürün teslim edilmiş sayılır. Malzeme kabulünün doğru şekilde yapılabilmesi için sözleşmede tanımlanan koşullara bağlı kalınır.

Ödeme Süreci 2: Siparişin doğru zamanda ve talep edilen liste ile teslim edilmesi halinde sözleşmede belirtilen tutar, herhangi bir ceza ve kesinti olmaması durumunda müşterinin hesabından tedarikçinin hesabına aktarılır.

Satıcı Değerlendirmesi: Sipariş teslimatı ve ödeme sürecinden sonra müşteri, satıcıyı teslimat hızı, teslimat doğruluğu, ürünlerin güvenli teslimatı ve müşteri ilişkileri konularında derecelendirir.

3. Tartışma ve Sonuç

Boya malzemesi teslimatı sürecinin yönetilmesi için önerilen akıllı sözleşme algoritması boya işlerinin yönetimini, süreçlerin iyileştirilmesini ve tanımlanan koşulların yerine getirildiğinde ödemelerin otomatik olarak gerçekleştirilmesini sağlayacaktır. Akıllı sözleşme algoritması sayesinde tüm işlemler blokzincir teknolojisiyle şeffaf bir şekilde yürütülüp kaydedileceğinden, denetim süreci kolaylaşacak bu sayede hatalar, eksiklikler ve usulsüzlükler daha hızlı tespit edilebilecektir. Bununla birlikte süreç boyunca tanımlanacak ve paylaşılacak verilerin güvenliği, bütünlüğü ve gizliliğinin sağlanması için bir blokzincir platformunun oluşturulması gerekmektedir.

Önerilen blokzincir tabanlı akıllı sözleşme algoritması boya siparişinin tedarik zinciri sürecinin yönetilmesinde birçok fayda sağlama potansiyeline sahiptir. İlk olarak akıllı sözleşme belirli koşulların yerine getirilmesi durumunda otomatik olarak ödeme yapacak şekilde programlanabilir. Böylece boya siparişi teslim edildiğinde ve alıcı tarafından onaylandığında, akıllı sözleşme ödemeyi otomatik olarak gerçekleştirecek ve ödeme gecikmeleri ve anlaşmazlıklar ortadan kalkmış olacaktır. Siparişin doğru miktarda ve zamanında verilmesi ve teslim edilmesi süreci blokzincir üzerinde şeffaf bir şekilde izlenebilecektir. Blokzincir üzerindeki veriler, siparişin ne zaman verildiğini ne kadar boya sipariş edildiğini ve teslimatın ne zaman gerçekleştiğini kaydedecek, bu sayede tüm taraflar sipariş süreçlerini anlık şeffaf şekilde takip edebilecektir.

İnşaatin başında oluşturulmuş olan iş programına tedarikçi ve yüklenicilerin koordine bir şekilde uymasını sağlayacaktır. İş programında belirtilen tarihlerde ve belirtilen miktardaki malzeme teslimatının yapılması akıllı sözleşme üzerinden takip edilebilir. İnşaat süresince akış şeması Şekil 3'te sunulan işlemlerin zamanında tamamlanması şart koşulabilir ve bu şartlar yerine getirilmediğinde sözleşmede tanımlanan cezalar uygulanabilir. Belirtilen yaptırımlar tarafların iş programına uymasını teşvik ederek mevcut koordinasyonu artıracaktır.

Önerilen akıllı sözleşme algoritması kapsamında taraflar arası haksız taleplerin ve iddiaların önlenmesi sağlanabilecektir. Akıllı sözleşmeler, tüm işlemleri ve anlaşmaları şeffaf bir şekilde blokzincir üzerinde kaydedip herhangi bir anlaşmazlık durumunda referans alınabilecek güvenilir ve değiştirilemez bir veri kaynağı sağlar. Belirtilen özellik, haksız taleplerin önlenmesine ve anlaşmazlıkların hızlı ve adil bir şekilde çözülmesine yardımcı olabilecektir. Bu sayede gecikmiş teslimat, eksik gelen teslimat veya hatalı renk veya miktarda gelen teslimat tespit edilebilecek ve önlenilecektir. Genel olarak, blokzincir tabanlı akıllı sözleşmeler, ödeme, sipariş verme ve teslimat süreçlerini otomatik hale getirerek insan hatası ve gecikmeleri önler, verilerin güvenliğini ve değiştirilemezliğini sağlar, operasyonel verimliliği artırır ve maliyetleri düşürür, böylece tedarik zincirindeki tüm taraflar için daha etkin ve güvenilir bir yönetim sunar. Ayrıca işverenin gerçekleştirmesi gereken ödemenin miktarı ve zamanı akıllı sözleşme algoritması tarafından belirlenerek ödemenin gerçekleştirilmesi sağlanabilecek aksi halde ilgili tarafın karşılaşılabileceği sözleşmede tanımlanan cezai müeyyideler yürürlüğe konacaktır.

İleri bir çalışma olarak malzemelerin uygun koşullarda saklanması ve uygunsuz kullanımının önlenmesi için IoT cihazları ile entegre edilebilir. Bu cihazlar, sıcaklık, nem gibi depolama koşullarını sürekli olarak izler ve bu verileri blokzincire kaydeder. Böylece, boya gibi malzemelerin uygun koşullarda saklanıp saklanmadığı sürekli takip edilir ve uygunsuz saklama durumlarına ve ağzı açık kalan boyalara karşı gerekli önlemler alınabilir. Çalışma kapsamında önerilen boya malzeme tedarik sürecini yönetmeyi hedefleyen akıllı sözleşme algoritmasından beklenen faydalar özet olarak aşağıdaki gibi listelenebilir.

- Ödemelerin zamanında gerçekleşmesi.
- Siparişin zamanında ve doğru miktarda verilmesi ve teslim edilmesinin sağlanması.
- İş programına yüklenici ve tedarikçilerin koordine biçimde uymasının sağlanması.
- Yüklenicinin malzemesi uygun ortamda saklanması.
- Ağzı açık bırakılıp özelliğini yitirmiş boyanın kullanımının önlenmesi.

Taraflar arasında ortaya çıkabilecek haksız taleplerin önlenmesi

Teşekkür

Bu çalışma İnönü Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimince Desteklenmiştir. Proje Numarası: FYL-2024-3471.

Çıkar Çatışması Beyanı

Makale yazarları herhangi bir kurum, kuruluş, kişi ile kişisel ve finansal çıkar çatışması olmadığını beyan etmektedirler.

Kaynaklar

- [1] Alsadi M, Gülseçen S, Kara S, Özdenizci Köse B, Coşkun V. Blockchain tabanlı bir veri yönetim modeli. *Journal of Information Systems and Management Research*, 2019;1(1): 31-36.
- [2] Mustaoğlu AF. Blockchain-Based Data Sharing and Managing Sensitive Data. *Avrupa Bilim ve Teknoloji Dergisi*, 2018;14:235-240.
- [3] Prakash A, Ambekar, S. Digital transformation using blockchain technology in the construction industry. *Journal of information technology case and application research*, 2020; 22(4):256-278.
- [4] Özyürek H. Blockchain teknolojisinin mevcut ve muhtemel kullanım alanları. *Anadolu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 2021;22(4):31-50.
- [5] Erinle Y, Kethepalli Y, Feng Y, Xu J. SoK: Design, vulnerabilities and defense of cryptocurrency wallets. *arXiv preprint arXiv: 2023;2307.12874*.
- [6] Turk Ž, Klinc R. Potentials of blockchain technology for construction management. *Procedia engineering*, 2017;196:638-645.
- [7] Şimşek MA. A Study of Blockchain in IoT Architecture. *International Journal of Engineering and Innovative Research*, 2021;3(2):163-174.
- [8] Shojaei A. Exploring applications of blockchain technology in the construction industry. *Proceedings of International Structural Engineering and Construction*, 2019;6;CON 31-1-CON 31-6
- [9] Dounas T, Lombardi D, Jabi W. Framework for decentralised architectural design BIM and Blockchain integration. *International journal of architectural computing*, 2021;19(2):157-173.
- [10] Zheng R, Jiang J, Hao X, Ren W, Xiong F, Ren Y. bcBIM: A Blockchain-Based Big Data Model for BIM Modification Audit and Provenance in Mobile Cloud. *Mathematical problems in engineering*, 2019;1:5349538.
- [11] Polat, M., Özyürek, H., & Baysal, Z. Blockchain Technologies: A Light On Future Works. *EJOSTIMTECH International Electronic Journal of OSTIMTECH*, 2022;1(1):35-50.
- [12] Osunsanmi TO, Aigbavboa C, Oke A. Construction 4.0: the future of the construction industry in South Africa. *International Journal of Civil and Environmental Engineering*, 2018;12(3): 206-212.
- [13] Alaloul WS, Liew MS, Zawawi NAWA, Mohammed BS. Industry revolution IR 4.0: future opportunities and challenges in construction industry. In *MATEC web of conferences 2018;203:02010*. EDP Sciences.
- [14] Leviäkangas P, Paik SM, Moon S. Keeping up with the pace of digitization: The case of the Australian construction industry. *Technology in Society*, 2017;50:33-43.
- [15] Chowdhury T, Adafin J, Wilkinson S. Review of digital technologies to improve productivity of New Zealand construction industry, *Journal of Information Technology in Construction*, 2019;24:569-587.
- [16] Nawari NO, Ravindran, S. Blockchain technology and BIM process: review and potential applications. *Journal of Information Technology in Construction*, 2019;24;209-238
- [17] Liu Z, Jiang L, Osmani M, Demian P. Building information management (BIM) and blockchain (BC) for sustainable building design information management framework. *Electronics*, 2019;8(7):724.
- [18] Maskuriy R, Selamat A, Ali KN, Maresova P, Krejcar O. Industry 4.0 for the construction industry—how ready is the industry?. *Applied Sciences*, 2019;9(14):2819.
- [19] Ünal G, Uluçay Ç. Blokzinciri teknolojisi. *Bilişim Teknolojileri Dergisi*, 2020;13(2):167-175.
- [20] Das M, Tao X, Cheng JC. BIM security: A critical review and recommendations using encryption strategy and blockchain. *Automation in construction*, 2021;126:103682.
- [21] Erbaş, S. Reklamcılıkta ve Pazarlamada Yeni Nesil Teknoloji: Blockchain. *Gümüşhane Üniversitesi İletişim Fakültesi Elektronik Dergisi*, 2019;7(2):712-729.
- [22] Salman S, Alaswad S. Vehicles emissions consideration in transportation network design using Markov chain traffic assignment. In *Proceedings of the International Conference on Industrial Engineering and Operations Management*, Dubai, UAE, 2020.
- [23] Nirantar K, Karmakar R, Hiremath P, Chaudhari D. Blockchain based supply chain management. In *2022 3rd international conference for emerging technology (INCET) 1-8*. IEEE, 2022, May.

- [24] Hamledari H, Fischer M. Construction payment automation using blockchain-enabled smart contracts and robotic reality capture technologies. *Automation in Construction*, 2021;132: 103926.
- [25] Kumi S, Lomotey RK, Deters R. A Blockchain-based platform for data management and sharing. *Procedia Computer Science*, 2022;203:95-102.
- [26] Figueiredo K, Hammad AW, Haddad A, Tam VW. Assessing the usability of blockchain for sustainability: Extending key themes to the construction industry. *Journal of Cleaner Production*, 2022;343:131047.
- [27] Yang Z, Zhu C, Zhu Y, Li X. Blockchain technology in building environmental sustainability: A systematic literature review and future perspectives. *Building and Environment*, 2023;245: 110970.
- [28] Shishehgarkhaneh MB, Moehler RC, Moradinia SF. Blockchain in the construction industry between 2016 and 2022: a review, bibliometric, and network analysis. *Smart Cities*, 2023; 6(2):819-845.
- [29] Wei P, Wang D, Zhao Y, Tyagi SKS, Kumar N. Blockchain data-based cloud data integrity protection mechanism. *Future Generation Computer Systems*, 2020;102:902-911.
- [30] Agarwal U, Rishiwal V, Tanwar S, Chaudhary R, Sharma G, Bokoro PN, Sharma R. Blockchain technology for secure supply chain management: A comprehensive review. *Ieee Access*, 2022;10;85493-85517.
- [31] Waqar A, Khan AM, Othman I. Blockchain empowerment in construction supply chains: Enhancing efficiency and sustainability for an infrastructure development. *Journal of Infrastructure Intelligence and Resilience*, 2024;3(1):100065.
- [32] Wong PM, Sinha RKS, Chui CK. Blockchain in manufacturing quality control: A computer simulation study. *Plos one*, 2021;16(3):e0247925.
- [33] Wu H, Zhang P, Li H, Zhong B, Fung IW, Lee YYR. Blockchain technology in the construction industry: Current status, challenges, and future directions. *Journal of construction engineering and management*, 2022;148(10):03122007.
- [34] Mahmudnia D, Arashpour M, Yang R. Blockchain in construction management: Applications, advantages and limitations. *Automation in construction*, 2022;140:104379.
- [35] Sheng D, Ding L, Zhong B, Love PE, Luo H, Chen J. Construction quality information management with blockchains. *Automation in construction*, 2020;120:103373.

REAL-TIME PERSONAL PROTECTIVE EQUIPMENT AND WAREHOUSE SAFETY DETECTION WITH DEEP LEARNING-BASED WORKPLACE CAMERA

Abdil KARAKAN^{1*}, Yüksel OĞUZ²

¹Afyonkocatepe Universty, Dazkırı Vocational Scholl, Depermant of Electrical, Afonkarahisar, 03050, Türkiye

² Afyonkocatepe Universty, Faculty of Technology, Depermant of Electrical and Electronic Engineering, Afonkarahisar, 03050, Türkiye

Geliş Tarihi/Received Date: 27.04.2024 Kabul Tarihi/Accepted Date: 30.09.2024 DOI:10.54365/adyumbd.1470598

ABSTRACT

The majority of work accidents can be prevented with simple precautions. The most important of these is the personal protective equipment that employees must use. In the study, personal protective equipment and warehouse security were detected in real time with images taken from a workplace camera. For this purpose, a data set was created from images taken from the workplace camera. This data set consists of 6125 photographs. Additionally, grayscale, tilt addition, blurring, variability addition, noise addition, image brightness change, color vibrancy change, perspective change, resizing and position change have been added to the photographs. With these additions, the error that may occur due to any distortion that may occur from the camera is minimized. With the changes made to the photographs, the number of photographs forming the data set increased to 21079. The created data set was run on YOLOv8 architecture. In the study, 9 types of personal protective equipment and warehouse safety were determined: helmet, shoes, vest, on the road, not on the road, without vest, without shoes, apron and without helmet. As a result of the study, average stability was 97.30%, mean average precision (mAP) was 93.80% and recall was 91.70%.

Keywords: Deep learning, Personal protective equipment, Real-time object detection, YOLO architecture, Warehouse security.

DERİN ÖĞRENME TABANLI İŞ YERİ KAMERASI İLE GERÇEK ZAMANLI KİŞİSEL KORUYUCU EKİPMAN VE DEPO GÜVENLİĞİ TESPİTİ

ÖZET

İş kazalarının büyük bir çoğunluğu basit tedbirlerle önlenilecek seviyededir. Bunların başında çalışanların kullanması gereken kişisel koruyucu ekipmanları gelmektedir. Yapılan çalışmada bir iş yeri kamerasından alınan görüntüler ile gerçek zamanlı olarak kişisel koruyucu ekipmanlarının tespiti gerçekleştirilmiştir. Bunun için iş yeri kamerasından alınan görüntülerden bir veri seti oluşturulmuştur. Bu veri seti 6125 tane fotoğraftan oluşmaktadır. Ayrıca fotoğraflar üzerinde gri tonlama, eğim eklenmesi, bulanıklaştırma, değişkenlik eklenmesi, gürültü eklenmesi, görüntü parlaklığı değişikliği, renk canlılığı değişikliği, perspektif değişikliği, boyutlandırma ve konum değişikliği eklenmiştir. Bu eklemeler ile kameradan meydana gelebilecek herhangi bir bozulmaya karşı oluşacak hata en aza indirilmiştir. Fotoğraflar üzerinde yapılan değişiklikler ile veri setini oluşturan fotoğraf sayısı 21079'a yükselmiştir. Oluşturulan veri seti YOLOv8 mimarisinde çalıştırılmıştır. Çalışmada kask, ayakkabı, yelek, yolda, yolda değil, yeleksiz, ayakkabısız, apron ve kasksız olmak üzere 9 çeşit kişisel koruyucu ekipmanın tespiti gerçekleştirilmiştir. Çalışma sonucunda ortalama doğruluk %97.30, kesinlik %93.80 ve duyarlılık %91.70'dir.

Anahtar Kelimeler: Derin öğrenme; Kişisel koruyucu ekipman; Gerçek zamanlı nesne algılama; YOLO mimarisi; Depo güvenliği.

* e-posta¹ : akarakan@aku.edu.tr ORCID ID: <https://orcid.org/0000-0003-1651-7568> (Sorumlu Yazar)

e-posta²: yukseloguz@aku.edu.tr ORCID ID: <https://orcid.org/0000-0002-5233-151XY>

1. Introduction

There are many and different hazards in work environments. Employers and employees must act together to maintain a safe and healthy work environment. For this to happen, the employer must ensure the supply of personal protective equipment. The worker must use personal protective equipment [1].

The foundation of personal protective equipment dates back to the works of Hippocrates, who lived between 460-370 BC. Hippocrates revealed the harmful effects of lead in his studies. The studies carried out to avoid being affected by this have formed the basis of personal protective equipment studies. The most accepted approach in national and international research is considered to be the scientific studies on work and disease conducted by the Italian researcher Bernardino Ramazzini 1633-1714 in the 17th century. Agricola 1494-1555 was the first person in history to talk about personal protective equipment. He came up with the idea of protective equipment for mouth and nose. He explained that employees should protect their mouths and noses with cloths in the form of dust masks. Agricola has taken modern measures regarding worker health and protective equipment [2].

Work performance of employees cannot be increased by providing occupational health and protective equipment. In order for employees to increase their job performance, there must be appropriate working conditions [3]. Having a healthy, hygienic and safe environment in workplaces has a great impact on work quality [4, 5]. Laws on occupational health and safety are made in many countries around the world [6]. Regulations are being made on these laws every day [7]. Personal protective equipment forms the basis of occupational safety in workplaces. With the development of technology, personal protective equipment used is updated or changed.

Personal protective equipment provides a significant degree of safety in case of work accidents. For this reason, employees must wear it [8]. Employees do not pay attention to the use of personal protective equipment with various excuses. There is a lack of awareness of these in the press. In addition, personal protective equipment is not used during work due to discomfort and itching [9].

The control of personal protective equipment is mostly done by people. Observations made with people cause huge errors in very large workplaces and places with a large number of workers. There are studies on different methods to control the use of personal protective equipment by workers.

Helmet is one of the most important personal protective equipment [10, 11]. They used a mobile Radio Frequency Identification (RFID) card for helmet detection. They placed an RFID card inside the helmet. Entrance to the construction site is from a single point and through a turnstile. RFID card readers have been placed at the entrance point to the construction site. In this way, everyone was ensured to wear a helmet when entering the construction site [12]. Helmet detection method with RFID card has been developed. In this method, they placed an RFID card, RFID card reader, zigbee transmitter and a speaker on the construction worker. When the helmet is not worn, the signal received from the RFID card reader is transferred to the centre via a zigbee transmitter. Transactions are made on the control card at the centre. The result is transferred again via the zigbee transmitter. Then, information is given via loudspeaker [13, 14]. These studies are insufficient for continuous monitoring. At the same time, carrying devices on people is both costly and undesirable. For this reason, studies have been conducted on non-device methods to detect personal protective equipment. The most important of these are camera-based methods.

Wuand and Zhao used convolutional neural networks (CNN) for helmet detection. First, it scans whether there are people in the photo. In case of a human, it works to detect the head area. After detecting the head area, it is determined whether there is a helmet or not. In their study, they achieved an accuracy of 98.80% [15]. Li and his colleagues used the SSD-MobileNet architecture in the CNN algorithm in their study. The dataset was created from images taken from the internet and videos at work. The data set was created from 3261 helmet images. As a result of the study, an accuracy of 78% was obtained [16]. The accuracy rates of studies conducted with machine learning have not increased to very high

levels. At the same time, the detection process takes a lot of time. For real-time detection, the frame rate per second (FPS) must be very high. Otherwise, the image disappears from the screen before detection can be done. For this reason, detection cannot be made. Since machine learning processes are done one by one, FPS rates remain very low.

Fangbo and his colleagues used the YOLOv5 architecture, a deep learning network, for helmet detection. They prepared a data set consisting of 6045 photographs for helmet detection. As a result of the study, the highest accuracy of 94.70% was achieved [19]. Fan and his colleagues used YOLOv3 and YOLO-Dense backbone architectures in their studies on caste detection. They detected helmets in two different studies. In their study, they achieved an accuracy of 95.15% with YOLOv3 and 97.59% with YOLO-Dense backbone architecture. Accuracy was increased by 2.44% in the YOLO-Dense backbone architecture [20]. Madhuchhanda and his friends worked on determining whether a helmet was worn on a motorcycle. They used YOLOv3 architecture in their work. As a result of their study, an accuracy of 96.23% was achieved [21]. Wei and colleagues used YOLOv5 architecture for helmet detection. They preferred to use the ready data set as the data set. They tried to increase efficiency by using soft Non-Maximum Suppression (NMS) instead of NMS in the YOLOv5 architecture. As a result of their studies, they increased the accuracy rate to 97.70% [22]. Shilei and colleagues have made fundamental improvements to the YOLOv5 architecture for helmet detection. In the YOLOv5 architecture, they added functionality that tries to find small targets such as helmets. They also used DIoU-NMS instead of NMS in the YOLOv5 architecture. An accuracy of 92.12% was achieved in the YOLOv5 architecture. In the improved YOLOv5 architecture, the accuracy rate was increased by 3.56% to 95.68% [23]. Rui and his colleagues investigated the effects of data preparation on accuracy in helmet detection. They used the Gaussian fuzzy method in the data set. Thanks to this method, the accuracy rate improved by 0.01-0.02 [24]. The leading causes of construction fatalities include falling, electrocution, or being struck by objects. As a preventative step, it is highly preventative that workers always wear appropriate personal protective equipment such as hard hats and vests. Nath and his colleagues studied whether workers were wearing hats and vests. In their study, they presented three deep learning models based on YOLO architecture on the image in real time. 1500 labels were made in the data set used in their study. They used CNN-based architectures such as VGG-16, ResNet-50 and Xception in his studies. When applied to real life in their studies, the highest accuracy rate of 72.30% was achieved in the ResNet-50 architecture. The frame per second rate remained at 11 frames. For this reason, the detection speed remained very low. When the FPS rate is increased to 13 frames, accuracy rates decrease. The highest accuracy rate was 67.93% when the FPS rate was 13 frames [25].

The study determined whether employees in a warehouse use personal protective equipment. The study also determined whether employees use walking paths for warehouse safety. Normally, people are assigned to detect this. In this method, huge human errors occur. In the literature studies, mostly helmet detection has been studied. RFID card readers and extra electronic circuits were used in these studies. These are also very costly. Detection is only done at the entrance of the workplace. Very high accuracy rates could not be achieved in detection processes made with machine learning. High accuracy rates were achieved in deep learning detection processes. It is made only for helmet detection among personal protective equipment. In this study, a total of 6 pieces of personal protective equipment were identified: helmet, shoes, vest, without vest, without shoes and without helmet. At the same time, 3 different situations of the employee have been determined for warehouse security: on the apron, on the road, and not on the road. A total of 9 different situation determinations were carried out in the study. A data set consisting of 6125 photographs was prepared for this detection process. In this data, greyscale, slope addition, blurring, variability addition, noise addition, image brightness change, colour vividness change, perspective change, sizing and position changes have been made. With these changes, the error that may occur due to any distortion that may occur from the camera has been minimized. With the changes made to the photographs, the number of photographs forming the data set increased to 21079. The created data set was run on YOLOv8 architecture. As a result of the study, average stability was 97.30%, mAP was 93.80% and recall was 91.70%.

2. Materials and Methods

The majority of work accidents can be prevented with simple precautions. The most important of these is the personal protective equipment that employees must use. In the study, a model was developed for personal protective equipment and warehouse security. The study was carried out in three stages. First stage; data set was prepared. For this purpose, the security camera in the warehouse was used. Thus, when the study was implemented, a higher rate of compliance was achieved in real life. In the second stage; Data set duplication was applied. As the data set increased, the accuracy of the system also increased. The highest accuracy was achieved by using the created data set in YOLOv8 architecture. Since the work will be real-time, the FPS rate must also be very good. In the last stage; applied in real life. Figure 1 shows the general structure of the study carried out for the determination of personal protective equipment.




Figure 1 General structure of the study carried out for the determination of personal protective equipment.

2.1. Dataset

In the study, a total of 6 personal protection equipment were identified: helmet, shoes, vest, without vest, without shoes and without helmet. At the same time, 3 different situations of the employee have been determined for warehouse security: on the apron, on the road, and not on the road. Security camera footage was used to detect these. The data set consists of 6125 photographs. The data set consists of photographs collected from real environments and websites. Figure 2 shows examples of the photographs that created the data set.

For the detection process, first the data set is labelled. Labelling is done for 9 different situations in the photographs that generated the data set. For this reason, a different number of tags are applied to each photo. In the study, approximately one hundred thousand tags were made. Figure 3 shows the number of labels made for each case in the data set.




Figure 2. Some sample photos from the dataset.

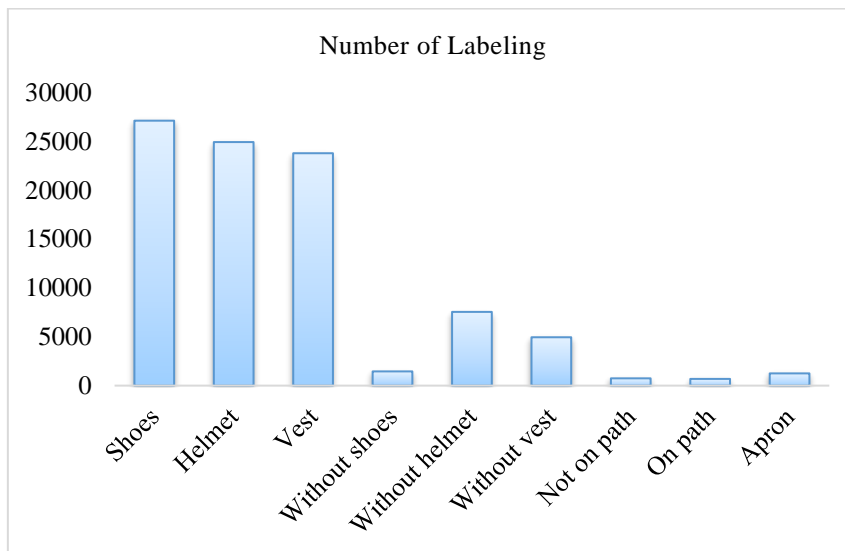


Figure 3. Labelling numbers used from the data set.

Personal protective equipment such as shoes, helmet and vest are used for each worker. For this reason, the number of labels for shoes, helmets and vests is very high. In particular, tagging without shoes is very rare. Because it is very difficult to find an employee without shoes.

Real-time detection will be made in the study. This will be done with images taken from the security camera. Errors that may occur in the camera will either greatly reduce the accuracy rate in the detection process or the detection process will not occur. For this reason, changes were made to the data

set to prevent errors that may occur from the camera. Figure 4 shows the changes made to the samples used in the data set. A computer was used to prepare the data set. The computer used in the study has an AMD Ryzen 1500X 3.5 GHz processor. The graphics card is NVIDIA GeForce GTX 1050 Ti 4GB GDDR5. Memory speed is 16 GB 3000 MHz.




Figure 4 a) Sizing and position change, b) Grayscale, c) Adding slope, d) Blurring, e) Adding variability, f) Adding noise, g) Image brightness change, h) Color vividness change, i) Perspective change.

In Figure 4a, 25% variability has been added to the positioning and sizing of the images that created the database. Thus, this process was done with the help of the model being more durable depending on the camera position. In Figure 4b, the images in the database are grayscale. In Figure 4c, +15% and -15% slope has been added to the images. In Figure 4d, random Gaussian blurring was performed to be more resistant to camera focus. In Figure 4e, +15% and -15% variability has been added to the rotations to be more resistant to camera roll. In Figure 4f, noise has been added to make it more robust to camera artifacts. In order for the Figure 4 model to be resistant to lighting and camera changes, the image brightness was changed by +15% and -15%. In Figure 4h, the vividness of the colours in the images is randomly adjusted. In Figure 4i, variability has been added to the perspective to be more robust to camera, subject pitch, and aberration. With these changes made from the photographs that generate the data set, the error rate in real-time helmet detection has been minimized.

2.2. YOLOv8

YOLO was first introduced in 2015 in the article “You Only Look Once: Unified, Real-Time Object Detection,” published by Joseph Redmon. The YOLO algorithm has shown more successful results than many object detection algorithms used in real-time object tracking. Many different models of YOLO have been released since 2015. The YOLOv1 model was first released in 2015. YOLOv2 was released in 2016, YOLOv3 in 2018, YOLOv4 and YOLOv5 in 2020, YOLOX in 2021, YOLOv6 and YOLOv7 in 2022, and finally YOLOv8 in 2023. As of January 2023, Ultralytics has released perhaps the best YOLO model to date, YOLOv8, under the ultralytics repository.

YOLOv8 is an open source object detection algorithm based on deep learning, specifically Convolutional Neural Networks (CNNs). It is part of the YOLO (You Only Look Only Once) family of object detection algorithms, known for their speed and accuracy in detecting objects in real time.

Leveraging previous YOLO versions, the YOLOv8 model is faster and more accurate while providing a unified framework for training models for performance.

YOLOv8 is a state-of-the-art object detection algorithm that outperforms many other object detection algorithms in terms of both speed and accuracy. It is an improvement over previous YOLO versions such as YOLOv3 by incorporating new techniques in deep learning and computer vision. Figure 5 shows the general structure of the YOLOv8 architecture.

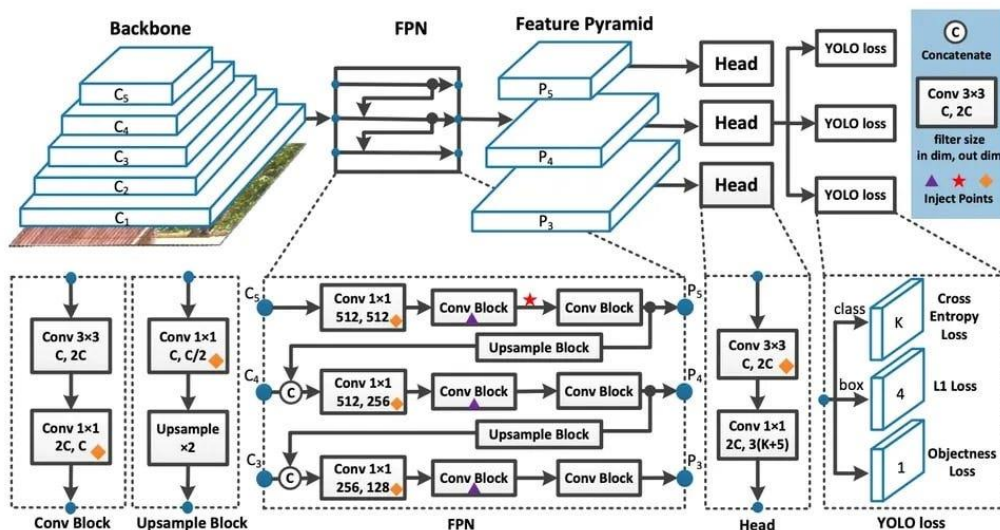


Figure 5. General structure of YOLOv8 architecture

3. Results and Discussion

YOLOv8 dataset architecture was used in the study. In the YOLOv8 architecture study, a total of 6 personal protective equipment was identified: helmet, shoes, vest, without vest, without shoes and without helmet. At the same time, 3 different situations of the employee have been determined for warehouse security: on the apron, on the road, and not on the road. A total of 9 different situation determinations were carried out in the study. Figure 6 shows the ROC curve resulting from the study.




Figure 6. ROC curve

In the study, the training period for determining personal protective equipment and warehouse security lasted 87 hours, 25 minutes and 13 seconds. As a result of the study, the average accuracy rate was 97.30%, mAP@5 was 93.80% and recall was 91.70%. Figure 7 shows the experimental study analysis graphically.




Figure 7. Graphical Representation of Experimental Study Analysis.

9 different detection procedures were performed in the study. But the sampling numbers used for each detection process were different. For this reason, accuracy rates were different for each group. Figure 8 shows the accuracy rates for each group.




Figure 8. In the detection process, the accuracy rates of each group are determined.

In the study, 9 different detection processes were performed. A different number of photographs and tags were taken for each detection process. As a result of the study, accuracy rate of 95% with shoes, 96% with a helmet, 97% with a vest, 94% without shoes, 96% without a helmet, 98% without a vest, 98% off the road, 98% on the road and 97% on the apron were obtained. As a result of the study, the average accuracy rate was 97.30%. The study was run from the workplace camera located in the warehouse. Figure 9 shows the detection processes carried out by the study at different times.




Figure 9. Detection processes carried out by the study at different times.

K-Fold Cross Validation method; It divides the data set into “k” equal parts and creates validation data for each part one by one. Thus, each data point is used as validation data at least once. In this way, the overall performance of the model is evaluated more accurately. There are 21709 samples in the data set of the study. Here, the number k is determined as 5. In other words, the data set is divided into 5. There are 4216 samples in each dataset. Their distribution is distributed in the same proportions as in the general data set. Table 1 shows the results after the K-Fold Cross Validation method.

Table 1: Results after K-Fold Cross Validation method

Model	Precision %	Accuracy %
k1	97.30	97.40
k2	97.10	97.25
k3	97.35	97.10
k4	97.25	97.50
k5	97.40	97.15

The average accuracy rate of the results obtained after the K-Fold Cross Validation method was 97.30. With this result, the overall result of the system is equal to the two results checked. Thus, it is understood that the overall performance of the model is good.

When the literature studies are examined, many studies have been done on helmet detection. Different methods, algorithms and architectures were used in the studies. Table 2 shows the comparative results of the studies conducted on the detection of personal protective equipment.

Table 2: Literature study

Author	Model	Precision
Huand et all.2021 [25]	YOLOv3, Improved YOLOv3, Faster R-CNN	0.93
Li et all. 2020 [26]	SSD	0.36
Kamboj et all [27]	SSD	0.96
Long et all 2019 [28]	SSD	0.69
Zhou et all 2021 [29]	YOLOv5s, YOLOv5m and YOLOv5l	0.95
Tan et all 2021 [30]	YOLOv5 and Improved YOLOv5	0.96
Yung et all 2022 [31]	YOLOv5s, YOLOv6s and YOLOv7	0.90
Korkmaz et all [32]	YOLOv8	0.97
Türkdamar et all 2023 [33]	YOLOv4, YOLOv5 and Faster R-CNN	0.98
Wu et all 2019 [34]	YOLOv3 and YOLO-Dense backbone	0.98
Jia et all 2021 [35]	YOLOv5	0.98
Nath et all 2020 [36]	VGG16, ResNet-50	0.67

The data sets and algorithms used in literature studies are different. For these reasons, the accuracy rates obtained as a result of the studies are different. In literature studies, architectures from YOLOv3 to YOLOv8 have been used in many studies. There is an increase in accuracy rates in studies from YOLOv3 to YOLOv8 architecture. The highest accuracy rate was in the YOLOv8 architecture. It is understood that the other results of the YOLOv8 architecture, especially the accuracy rates, are better than other models of the YOLO architecture.

As a result of the literature review, it is understood that the use of previous systems in daily life is quite difficult. These difficulties are that they have low FPS. For this reason, the systems cannot be used in real time. YOLOv8, the latest version of the YOLO architecture, was used in the study. In this way, the highest accuracy rate and FPS rate were determined by comparison. Since YOLO architectures perceive the image with a single glance, FPS rates are very good. A speed of 60 FPS was achieved in the YOLOv8 algorithm. In this way, detection can be carried out very easily in real time.

4. Conclusion

Many accidents occur in workplaces. If protective equipment is used, the vast majority of these accidents will cause little or no harm. Employees do not want to wear personal protective equipment for various excuses. In workplaces, control of these is left to people. This is costly and always very difficult to do. With the developing technology, RFID card, machine learning and most recently deep learning methods have been used for personal protectors. The controls made with the RFID card were insufficient because they were made only from a single point at the entrances. Very high accuracy has not been achieved in machine learning. Different architectures have been used in deep learning. The study must achieve very high accuracy as well as a fast detection time. In literature studies, studies have mostly focused on the detection of a single protective equipment. In this study, a total of 6 pieces of personal protective equipment were identified: helmet, shoes, vest, without vest, without shoes and without helmet. At the same time, 3 different situations of the employee have been determined for warehouse security: on the apron, on the road, and not on the road. A total of 9 different situation determinations were carried out in the study. In the study, YOLOv8 architecture, the latest YOLO architecture, was used. With this architecture, an accuracy rate of 97.3% was achieved. At the same time the land speed per second (FPS) increased to 60. In this way, real-time detection takes place on the screen. A large data set was prepared for the study to yield such good results. A data set consisting of 6125 photographs was prepared for this detection process. In this data, greyscale, slope addition, blurring, variability addition, noise addition, image brightness change, color vividness change, perspective change, sizing and position changes have been made. With these changes, the error that may occur due to any distortion that may occur from the camera has been minimized.

A high level of accuracy is achieved in detecting protective equipment. But during detection, the person's identity information cannot be determined. Adding facial recognition to the system will take the work one step further. If a mobile application is added to the system, people who do not wear protective equipment can receive instant warnings.

References

- [1] Ammad S, Alaloul WS, Saad S, Qureshi AH. Personal protective equipment (PPE) usage in construction projects: A scientometric approach. *Journal of Building Engineering* 2021; 35: 1-44.
- [2] MacFalane E, Chapman A, Benke G, Meaklim J, Sim M, MacNeil J. Training and other predictors of personal protective equipment use in Australian grain farmers using pesticides. *Occup Environ Med.* 2008; 65: 141-146.
- [3] Davidescu AA. Work flexibility, job satisfaction, and job performance among Romanian employees—implications for sustainable human resource management. *Sustainability* 2020; 12: 6086.
- [4] Greubel J. Higher risks when working unusual times? A cross-validation of the effects on safety, health, and work–life balance. *International Archives of Occupational and Environmental Health* 2016; 89: 8.
- [5] Haar JM. Outcomes of work-life balance on job satisfaction, life satisfaction and mental health: A study across seven cultures. *Journal of Vocational Behavior* 2014; 85: 361–373.

- [6] Delhi VSK, Sankarlal R, Thomas A. Detection of personal protective equipment (PPE) compliance on construction site using computer vision based deep learning techniques. *Frontiers in Built Environment* 2020; 6: 1-10.
- [7] Tutak M. Evaluating differences in the level of working conditions between the European Union member states using topsis and k-means methods. *Decision Making Applications in Management and Engineering* 2020; 5: 2-10.
- [8] Ludwika AS, Rifai AP. Deep Learning for Detection of Proper Utilization and Adequacy of Personal Protective Equipment in Manufacturing Teaching Laboratories. *Safety*. 2024; 10: 26-56.
- [9] Li H, Luo X, Siebert J. Investigation of the causality patterns of non-helmet use behavior of construction workers. *Automation in Construction* 2017; 80: 95-103.
- [10] Goodrum PM, McLaren MA, Durfee A. The application of active radio frequency identification technology for tool tracking on construction job sites. *Autom. Constr.* 2006; 15: 292–302.
- [11] Jaselskis E, Haas CT, Goodrum PM. Construction transportation-related RFID research and applications. *Transportation Research Circular Research Opportunities in Radio Frequency Identification Transportation Applications* 2007; 9–24.
- [12] Kelm A, Meins-Becker LA, Platz D, Khazaee MJ, Costin A, Helmus M, Teizer J. Mobile passive Radio Frequency Identification (RFID) portal for automated and rapid control of Personal Protective Equipment (PPE) on construction sites. *Automation in Construction* 2013; 36: 38–52.
- [13] Barro-Torres S, Fernandez-Carames TM, Perez-Iglesias HJ, Escudero CJ. Real-time personal protective equipment monitoring system. *Computer Communications* 2022; 36: 42–50.
- [14] Hayward S, Lopik K, West A. A holistic approach to health and safety monitoring: Framework and technology perspective. *Internet of Things* 2022; 20.
- [15] Wuand MH, Zhao J. Automated visual helmet identification based on deep convolutional neural networks. *Proceedings of the 13th International Symposium on Process Systems Engineering* 2018; 1-5.
- [16] Rubaiyat AHM, Toma TT, Kalantari-Khandani M, Rahman SA, Chen L, Pan CS. Automatic detection of helmet uses for construction safety. *Proceedings of the 2016 IEEE ACM International Conference on Web Intelligence Workshops* 2016; 1-8.
- [17] Fangbo Z, Huailin Z, Zhen N. Safety helmet detection based on YOLOv5. *2021 IEEE International Conference on Power Electronics. Computer Applications* 2021; 6-11.
- [18] Fan W, Guoqing J, Mingyu G, Zhiwei HE, Yuxiang Y. Helmet detection based on improved YOLO V3 deep model. *2019 IEEE 16th International Conference on Networking, Sensing and Control* 2019; 363-368.
- [19] Madhuchhanda D, Oishila B. Sanjay Automated helmet detection for multiple motorcycle riders using CNN. *2019 IEEE Conference on Information and Communication Technology* 2019; 1-4.
- [20] Wei J, Shiquan X, Zhen L, Yang Z, Hai M, Shujie L, Ye Y. Real-time automatic helmet detection of motorcyclists in urban traffic using improved YOLOv5 detector. *IET Image Processing* 2021; 15: 3623-3637.
- [21] Shilei T, Gonglin L, Ziqiang J, Li H. Improved YOLOv5 network model and application in safety helmet detection. *2021 IEEE International Conference on Intelligence and Safety for Robotics* 2021; 1-4.
- [22] Rui G, Yixuan M, Wanhong H. An improved helmet detection method for YOLOv3 on an unbalanced dataset. *2021 3rd International Conference on Advances in Computer Technology, Information Science and Communication* 2021; 22-35.
- [23] Yange L, Han W, Zheng H, Jianling H, Weidong W. Deep learning-based safety helmet detection in engineering management based on convolutional neural networks. *Hindawi Advances in Civil Engineering* 2020; 1-10.
- [24] Chang X, Liu M. Fault tree analysis of unreasonably wearing helmets for builders. *Journal of Jilin Jianzhu University* 2018; 35: 67–71.
- [25] Huang L, Fu M, He D, Jiang Z. Detection algorithm of safety helmet wearing based on deep learning. *Concurr. Comput* 2021; 33: 13-20.
- [26] Li Y, Wei H, Han Z, Huang J, Wang W. Deep learning-based safety helmet detection in engineering management based on convolutional neural networks. *Advances in Civil Engineering* 2020; 1–10.

- [27] Kamboj N, Powar N. Safety helmet detection in industrial environment using deep learning. 9th International Conference on Information Technology Convergence and Services 2017; 5-12.
- [28] Long X, Cui W, Zheng Z. Safety helmet wearing detection based on deep learning. 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference 2019; 2495-3000.
- [29] Zhou F, Zhao H, Nie Z. Safety helmet detection based on YOLOv5. 2021 IEEE International Conference on Power Electronics, Computer Applications 2021; 6-13.
- [30] Tan S, Lu G, Jiang Z, Huang L. Improved YOLOv5 network model and application in safety helmet detection. 2021 IEEE International Conference on Intelligence and Safety for Robotics 2021; 330-334.
- [31] Yung NDT, Wong WK, Juwono FH, Sim ZA. Safety helmet detection using deep learning: Implementation and comparative study using YOLOv5, YOLOv6, and YOLOv7. International Conference on Green Energy, Computing and Sustainable Technology 2022; 77-85.
- [32] Korkmaz A, Ağdaş T. Deep learning-based automatic helmet detection system in construction site cameras. Bitlis Eren University Journal of Science 2023; 12: 773-782.
- [33] Türkdamar MU, Taşyürek M, Öztürk C. Helmet detection on the construction site transfer learning and without transfer learning deep networks. Niğde Ömer Halisdemir Journal of Engineering Science 2023; 12: 039-051.
- [34] Wu F, Guoqing J, Mingyu G, Yuxiang Y. Helmet detection based on improved YOLOv3 Deep Model. 2019 IEEE 16th International Conference on Networking, Sensing and Control 2019; 363-462.
- [35] Jia W, Xu S, Liang Z, Zhao Y, Min H, Li S, Yu Y. Real-time automatic helmet detection of motorcyclists in urban traffic using improved YOLOv5 detector. IET Image Processing 2021; 15: 3623-3637.
- [36] Natha DN, Behzadan AH, Stephanie G. Deep learning for site safety: Real-time detection of personal protective equipment. Automation in Constructio 2020; 112: 103085.

6 ŞUBAT 2023 KAHRAMANMARAŞ MERKEZLİ DEPREMLER SONRASINDA ADIYAMAN İLİNDEKİ BETONARME YAPILARDA OLUŞAN HASARLARIN MALZEME VE İŞÇİLİK PROBLEMLERİNE BAĞLI OLARAK İNCELENMESİ

Murat PALA¹, Mahmut BAŞSÜRÜCÜ^{2*}

¹Adiyaman Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Adiyaman, 02040, Türkiye

²Malatya Turgut Özal Üniversitesi, Darende Bekir Ilıcak MYO, İnşaat Bölümü, Malatya, 44900, Türkiye

Geliş Tarihi/Received Date: 15.09.2024 Kabul Tarihi/Accepted Date: 02.10.2024 DOI: 10.54365/adyumbd.1550346

ÖZET

6 Şubat 2023 tarihinde meydana gelen Mw=7.7 ve Mw=7.6 büyüklüklerindeki Kahramanmaraş merkezli depremler Adiyaman’ın da aralarında bulunduğu 11 ili önemli ölçüde etkilemiştir. Adiyaman ilindeki betonarme yapılarda bulunan yapısal sorunlar, depremlerde felaketin boyutlarını önemli ölçüde arttırmıştır. Bu nedenle, betonarme yapılarda yapısal elemanlar açısından önemli hasarlar ve toptan göçmeler gözlemlenmiştir. Bu çalışmada, Adiyaman il merkezindeki betonarme yapılar için yapım uygulamalarının değerlendirilmesi amacıyla saha araştırmaları gerçekleştirilmiştir. Bulgular, birçok betonarme yapının yapısal ve/veya işçilik hataları nedeniyle hasar aldığı veya toptan göçtüğünü göstermiştir. Sonuç olarak, Adiyaman ilindeki betonarme yapıların deprem performansını iyileştirmek için gelecekte yapılacak yapım ve güçlendirme çalışmaları açısından bazı kritik öneriler yapılmıştır.

Anahtar Kelimeler: Betonarme yapılar, Yapısal hasarlar, Saha araştırması, Yapı göçmesi, Kahramanmaraş depremleri

INVESTIGATION OF RC STRUCTURES DAMAGES IN ADIYAMAN PROVINCE DUE TO MATERIAL AND WORKMANSHIP PROBLEMS AFTER THE FEBRUARY 6, 2023, KAHRAMANMARAŞ-CENTERED EARTHQUAKES

ABSTRACT

The Mw=7.7 and Mw=7.6 earthquakes on February 6, 2023, centered in Kahramanmaraş, significantly affected 11 provinces, including Adiyaman. The structural problems in the reinforced concrete structures in Adiyaman province significantly increased the dimensions of the disaster during the earthquakes. Therefore, significant damages and total collapses were observed in reinforced concrete structures in terms of structural elements. This study conducted site investigations to evaluate the construction applications for reinforced concrete structures in Adiyaman province center. The findings showed that many reinforced concrete structures were damaged or total collapsed due to structural and/or workmanship defects. In conclusion, some critical recommendations were made for future construction and strengthening works to improve the earthquake performance of reinforced concrete structures in Adiyaman province.


Keywords: Reinforced concrete structures, Structural damages, Site research, Structure collapse, Kahramanmaraş earthquakes

e-posta¹ : pala@adiyaman.edu.tr ORCID ID: <https://orcid.org/0000-0002-3684-9976>

* e-posta² : mahmut.bassurucu@ozal.edu.tr ORCID ID: <https://orcid.org/0000-0001-7465-5286> (Sorumlu Yazar)

1. Giriş

6 Şubat 2023 tarihinde Kahramanmaraş merkezli büyüklükleri $M_w=7.7$ ve $M_w=7.6$ olan iki büyük deprem meydana gelmiştir. Depremler, oldukça geniş bir coğrafyada hissedilmiş, önemli yapısal hasar ve göçmelere sebep olmuştur. Her iki depremin etki alanındaki yerleşim yerleri Doğu Anadolu Fay Zonu (DAFZ) içerisinde yer almaktadır (Şekil 1). Depremler içerisinde Adıyaman’ında bulunduğu 11 il merkezi ve ilçelerinde farklı düzeylerde hasar ve göçmeler ile birlikte can kayıpları ve yaralanmalara neden olmuştur. Kahramanmaraş merkezli depremler sonucunda Adıyaman il merkezi ve ilçelerinde önemli hasar ve toptan göçmeler gözlemlenmiştir. Türkiye Cumhuriyeti Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı tarafından hazırlanan raporda, Çevre Şehircilik ve İklim Değişikliği Bakanlığınca yürütülen hasar tespit çalışmaları sonucunda Adıyaman ili için acil yıkılacak, yıkık veya ağır hasarlı konut sayısı 56.256, orta hasarlı konut sayısı ise 18.715 olarak tespit edilmiştir [1].



Şekil 1. Türkiye deprem tehlike haritası [2]

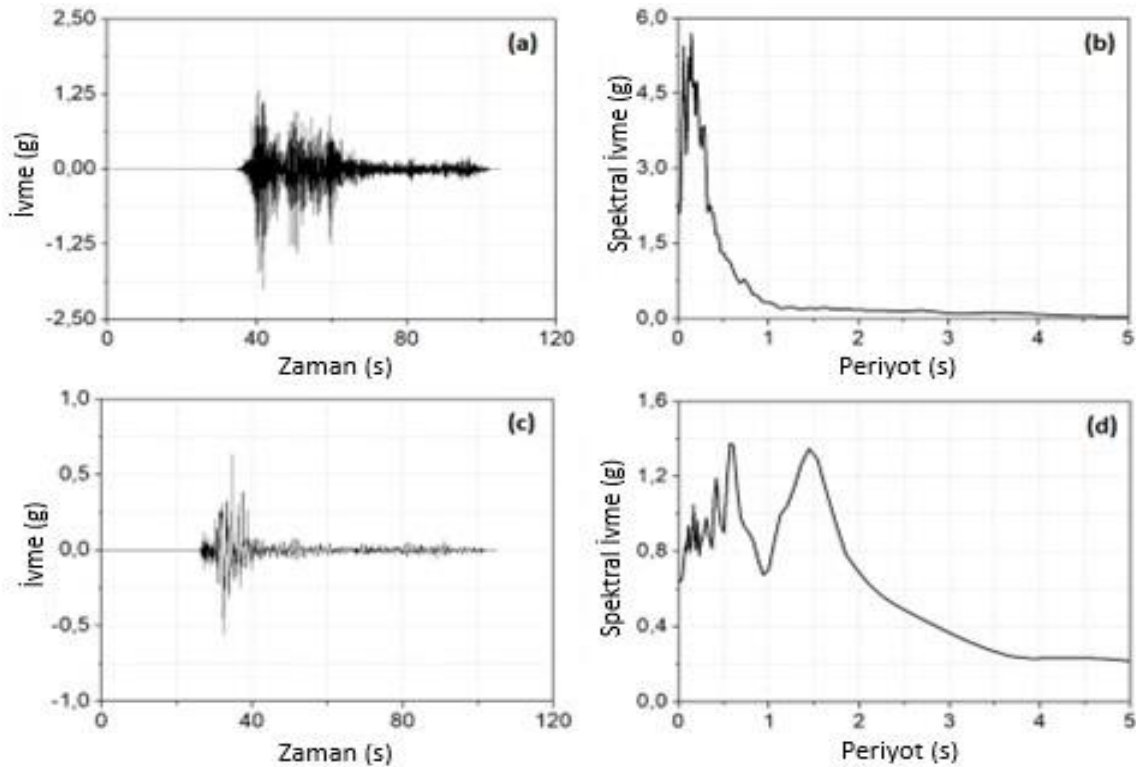
Depremler çok çeşitli alanları etkileyebilir ve farklı yapı türlerinde farklı düzeylerde hasarlara neden olabilir. Depremlerin yapılar üzerindeki etkileri, kuvvetli yer hareketinin özellikleri ile frekans içeriklerine, yerel zemin koşullarına ve yapısal özelliklere bağlı olarak değişebilir. Dünyanın farklı bölgelerinde meydana gelen depremler sonrasında bu özelliklerin ve etkileşimlerinin araştırılması, deprem ve inşaat mühendisliği açısından büyük önem taşımaktadır. Yerel zemin koşulları, diğer büyük depremlerde olduğu gibi Kahramanmaraş merkezli depremlerde de binaların deprem performansını ve yapısal hasar seviyelerini doğrudan etkilemiştir.

Ülkemizde 1939 yılında meydana gelen Erzincan depremi ($M_w=7.8$) sonrasında yapıların depreme karşı dayanıklılığının artırılmasına yönelik çalışmalar başlamıştır [3]. Yapıların depreme karşı dayanıklılığını artırmak için 1940 yılında ilk yönetmelik yayınlanmış ve deprem yönetmelikleri birkaç kez revize edilerek 2018 yılında yayınlanan ve 2019 yılında yürürlüğe giren Türkiye Bina Deprem Yönetmeliği (TBDY-2018) ile son halini almıştır.

Literatürde farklı zamanlarda meydana gelen depremlerin yapılarda oluşturduğu hasarlarla ilgili birçok çalışma bulunmaktadır. Yıldız ve Kına [4] tarafından yürütülen çalışmada Kahramanmaraş merkezli depremlerden etkilenen şehirlerden biri olan Malatya ilinde detaylı bir saha araştırması yürütülerek, yapısal, tasarım ve imalat hataları incelenmiştir. Saha araştırmasında, yapıların tasarım ve yapım hataları nedeniyle ağır hasar aldığı veya göçtüğü tespit edilmiştir. Kahramanmaraş merkezli depremlerden en fazla etkilenen yerleşim yerleri arasında yer alan Adıyaman'ın Gölbaşı ilçesinde geoteknik ve yapısal hasarlar Akar ve ark. [5] tarafından değerlendirilmiştir. İlçe merkezinde gözlenen

hasarların genellikle yapı-zemin etkileşim problemlerinden kaynaklandığı vurgulanmıştır. Ayrıca, 6 Şubat 2023 tarihinde meydana gelen depremlere maruz kalan okul binalarında oluşan hasar türleri, Ozturk ve ark. [6] tarafından değerlendirilmiş ve performansa dayalı analitik çalışmalar yürütülmüştür. Okul binalarında tasarım hataları, beton kalitesinin düşük olması, düz yüzeyli donatı kullanımı ve donatı teşkilindeki sorunlardan dolayı hasarlar oluştuğu söylenmiştir. Ivanov ve Chow [7] tarafından gerçekleştirilen başka bir çalışmada, 6 Şubat 2023 Kahramanmaraş depremlerinden sonra Adıyaman ili bölgesindeki betonarme yapılarda oluşan hasarlar incelenmiştir. Oluşan hasarların, yetersiz donatı detayı, depreme dayanıklı inşaat tekniklerine uyulmaması, düşük beton kalitesi ve kötü işçilik gibi faktörlere dayandığı vurgulanmıştır. Depremlerin merkez üssü olan Kahramanmaraş ili ve ilçelerinde deprem kaynaklı oluşan hasarların değerlendirildiği çalışmada kırsal kesimde bulunan yığma yapıların mühendislik hizmeti almadığı için önemli hasarlar aldığı belirtilmiştir [8]. Kahramanmaraş merkezli depremlerden en fazla etkilenen şehirlerden biri olan Hatay'da betonarme, çelik ve yığma yapılarda oluşan hasarların yetersiz donatı detayı, korozyon, düşük kaliteli beton kullanımı ve donatı teşkili sorunlarına bağlı olarak oluştuğu sonucuna varılmıştır [9]. Tüm bunlara ilaveten, Çağlar ve ark. [10] ve Sayın ve ark. [11] tarafından 24 Ocak 2020'de meydana gelen Elazığ-Sivrice depreminden sonra yapılarda oluşan farklı yapısal hasarlar incelenmiştir. Yapıların hasar almasındaki faktörler ise donatı detaylandırmasındaki sorunlar, düşük dayanımlı beton, donatı korozyonu ve işçilik hataları olarak belirlenmiştir. Sonuçta, önceki depremlerden yeterli ders çıkarılmadığı belirtilerek, denetim ve yapım süreci ile ilgili önerilerde bulunulmuştur.

Bu çalışmada, Adıyaman il merkezinde bulunan betonarme yapılarda 6 Şubat 2023 Kahramanmaraş merkezli depremlerin oluşturduğu hasarlar ile toptan göçmeler malzeme ve işçilik problemlerine bağlı olarak incelenmiştir. Adıyaman ili bölgede gözlemlenen önemli yapısal hasarlar ve toptan göçmeler nedeniyle seçilmiş olup, saha çalışmaları sonucunda inşaat uygulamaları açısından gözlemler yapılmıştır. Ayrıca, Adıyaman ilindeki saha çalışması sonucunda elde edilen verilerin, betonarme yapılarda deprem nedeniyle ortaya çıkan yapısal hasarların önlenmesi konusunda, uygulamacılara olumlu yönlendirmeler sağlayacağı açıktır.

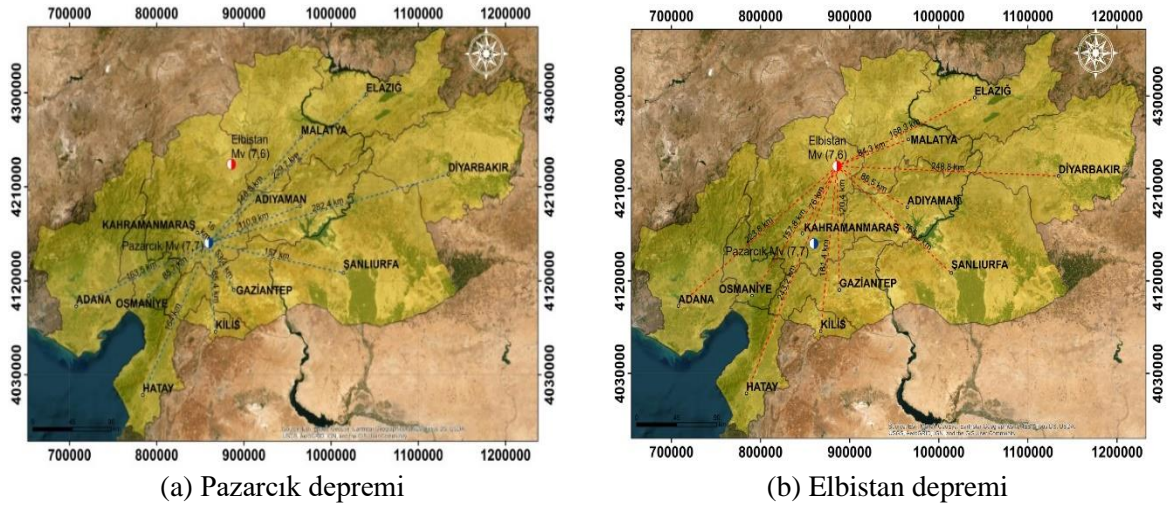


Şekil 2. Depremlerin ivme-zaman ve spektral ivme-periyot grafikleri, (a,b) Pazarcık (Pazarcık-TK 4614) ve (c,d) Elbistan (Göksun-TK 4612)

2. Bölgenin Depremselliği ve Yapı Özellikleri

Tarihsel olarak, Türkiye'nin sismik olarak en aktif bölgelerinden biri olan DAFZ boyunca büyük depremler meydana gelmiştir. DAFZ, Anadolu ve Avrasya levhaları arasında yer alan sol doğrultu atımlı 550 km uzunluğunda bir faydır [4,12,13]. Kahramanmaraş merkezli gerçekleşen iki büyük deprem büyük hasar ve yıkıma neden olmuştur. TK 4614 Pazarcık ve TK 4612 Göksun istasyonlarından elde edilen ivme-zaman ve spektral ivme grafikleri Şekil 2'de sunulmuştur.

Doğu Anadolu Fay Zonu üzerinde yer alan Adıyaman'ın jeolojik yapısı incelendiğinde Palu-Sincik (145 km), Çelikhane-Erkenek (45 km) ve Gölbaşı-Türkoğlu (90 km) gibi segmentleri içermekte ve bölgeyi sismik aktiviteye karşı özellikle hassas hale getirmektedir [5]. Tarihsel ve aletsel dönemlerde DAF zonunda 6 ve üzeri büyüklükte birçok yıkıcı deprem gerçekleşmiştir. Tarihsel deprem kayıtları incelendiğinde, Adıyaman ili ve çevresinde, 1003 ile 1900 yılları arasında büyüklükleri 4.8 ile 7.4 arasında değişen toplam 26 adet deprem meydana gelmiştir [14]. Aletsel dönemde ise 1964 yılı Sincik-Adıyaman (Mw=6), 1981 yılı Gerger-Adıyaman (Mw=5), 2010 yılı Gerger-Adıyaman (Mw=4.7) ve 2017 yılı Samsat-Adıyaman (Mw=5.5) depremleri gerçekleşmiştir. Kahramanmaraş merkezli depremlerin yerleşim yerlerine olan merkez üssü uzaklıkları, Şekil 3'de gösterilmiştir.



Şekil 3. Depremlerin yerleşim yerlerine olan merkez üssü mesafeleri



Şekil 4. Farklı hasar durumlarına sahip betonarme yapılar



(a)

(b)

Şekil 5. Toptan göçmeye maruz kalan asmolen döşeme sistemine sahip yapılar

Adıyaman il merkezinin yapı stoğu incelendiğinde, genelde mühendislik hizmeti almış, normal yükseklikte (1-12 kat) betonarme yapıların çoğunlukta olduğu söylenebilir. Yapılarda taşıyıcı sistemin genel olarak, salt çerçeve ve perde-çerçeve (karma) olarak seçildiği tespit edilmiştir. Bu tip yapılarda malzeme ve işçilik problemlerine bağlı olarak önemli hasarlar ve toptan göçmeler gözlemlenmiştir (Şekil 4(a-b)). Diğer taraftan, betonarme yapılarda döşeme sistemi olarak asmolen döşemenin kirişli plak döşemeye kıyasla tasarımcılar tarafından oldukça fazla tercih edildiği görülmüştür. Yatay yükleri alabilecek miktarda perde yerleştirilmeyen asmolen döşeme sistemine sahip yapılarda toptan göçme veya ağır hasar olduğu belirlenmiştir. Mimari açıdan avantaj sağladığı için tercih edilen asmolen döşeme sistemine sahip bu tip yapılarda yüksek can kayıpları meydana gelmiştir (Şekil 5(a-b)).

3. Betonarme Yapılarda Deprem Hasarına Sebep Olan Faktörler

3.1. Yapı Malzemesi Kalitesi

Deprem etkisi altında hasar gören veya toptan göçmeye maruz kalan betonarme yapılar malzeme kalitesi açısından değerlendirildiğinde, bu yapıların büyük çoğunluğunun 1975 deprem yönetmeliğine göre inşa edilen eski yapılar olduğu gözlemlenmiştir. Beton dayanımının projede öngörülenden daha düşük olması betonarme yapılardaki hasarın artmasına neden olmuştur. 2000 öncesi inşa edilen eski yapılarda beton dayanımının düşük olmasının nedenleri arasında hazır beton teknolojisinin kullanılmaması, uygun olmayan agrega gradasyonu, düşük çimento dozajı, kür işleminin yapılmaması ve taze betona sonradan eklenen ilave su sayılabilir. Diğer taraftan, hazır beton kullanılarak inşa edilen yeni yapılar için ise beton dayanımının öngörülenden düşük olması, kür işleminin eksik yapıldığı ve/veya taze betona sonradan ilave su eklendiğini göstermektedir. Saha çalışmasında düşük beton kalitesi, düz yüzeyli nervürlü donatı seçimi ve düşük çaplı donatı kullanımına bağlı olarak betonarme yapılarda toptan göçmelerin meydana geldiği tespit edilmiştir (Şekil 6(a-b)).

Betonarme yapı elemanlarında çekme bölgesindeki gerilmeleri karşılamak üzere çelik donatılar yerleştirilir. Çelik donatılar 2000 öncesi inşa edilen eski yapılarda düz yüzeyli iken, 2000 yılı sonrasında inşa edilen yapılarda ise nervürlü olarak kullanılmıştır. Nervürlü donatı yüzeyinde imalat esnasında bırakılan çıkıntılar beton ile kenetlenmeyi sağlamaktadır. Betonarme yapı elemanlarının davranışını çelik donatının kalitesi önemli ölçüde etkilemekte olup, çeliğin en önemli mekanik özellikleri ise akma ve çekme dayanımı ile kopma birim uzamasıdır. Adıyaman ilindeki gerçekleştirilen saha gözlemlerinde, birçok ağır hasarlı betonarme yapının kiriş ve kolon boyuna donatılarında oluşan kopma şekilleri,

donatının yeterli sünekliği göstermeden gevrek kırılmaya maruz kaldığını göstermektedir (Şekil 7(a-d)). Buradan, donatının mekanik özelliklerini belirleyen karbon miktarının olması gereken sınırların dışında olabileceği düşünülmektedir.



(a)

(b)

Şekil 6. Toptan göçmeye maruz kalan yapılara ait beton ve donatı örnekleri



(a)

(b)



(c)

(d)

Şekil 7. Gevrek kırılmaya maruz kalan kiriş ve kolon boyuna donatı örnekleri

3.2. Yetersiz Beton Örtüsü ve Segregasyon

Betonarme yapı elemanlarında çelik donatıyı olumsuz dış etkenlere karşı korumak ve beton ile aderansını sağlamak amacıyla donatı üzerinde bir beton örtüsü bulunmalıdır. Ayrıca, dar ve derin yapı elemanlarına ait kalıplarda özensiz beton dökümü sonucunda beton segregasyona uğramaktadır (Şekil 8(a)). Betonun segregasyona uğraması ve/veya beton örtüsünün yetersiz olması durumunda betonun geçirimsizliği artar ve oksijen ile nemin donatıya ulaşması kolaylaşır [15]. Bu durumda, çelik donatıda korozyon problemi ile birlikte donatının kesit alanı azalır ve dolayısıyla betonarme taşıyıcı elemanın taşıma kapasitesi azalır [16]. Tüm bunlara ek olarak, yapım aşamasındaki işçilik hatalarına bağlı olarak ortaya çıkan korozyon problemi nedeniyle yapının depreme karşı dayanıklılığı ve betonarme yapının servis ömrü önemli ölçüde azalır (Şekil 8(b-c)).



(a)

(b)



(c)

Şekil 8. Segregasyon ve yetersiz beton örtüsüne sahip düşey taşıyıcı eleman örnekleri



(a)



(b)



(c)



(d)



(e)



(f)

Şekil 9. Donatı detaylandırma hatalarına bağlı olarak meydana gelen hasarlar

3.3. Donatı Detaylandırma Hataları

Betonarme yapı elemanlarında donatının konum ve düzeni oldukça önemlidir. Çünkü, donatının bu iki özelliği donatının üzerine düşen görevi yerine getirip getirememesini belirlemektedir [16]. Betonarme yapı elemanları, eğilme ile birlikte kesme kuvveti de taşımak zorundadır. Enine donatısı olmayan veya yetersiz olan betonarme taşıyıcı elemanların kesme kuvvetleri etkisinde göçmeleri, ani ve gevrek şeklindedir. Türkiye Bina Deprem Yönetmeliğinde (TBDY-2018) [17] betonarme yapı elemanlarının donatı teşkili ile ilgili olarak önemli hususlar yer almakta olup, özellikle bindirme boyu, etriye aralığı ve kanca ucu detayı oldukça önemlidir. Kolon sıklaştırma bölgesinde etriye aralığının en küçük kesit boyutunun $1/3$ 'ünden, boyuna donatı çapının altı katından ve 15 cm'den büyük olmaması gerekmektedir. Aksi takdirde, özellikle kiriş-kolon birleşim bölgelerinde etriye aralığı ve kanca uç detayındaki problemlere bağlı olarak yapısal hasarlar oluşabilmektedir. Enine donatı takviyesi olarak kullanılan etriyeler yönetmeliğe göre tasarlanıp uygulandığında, betonarme taşıyıcı yapı elemanlarının hem dayanımı hem de sünekliği artar [18]. Diğer taraftan, betonarme taşıyıcı yapı elemanlarında etriye çap ve aralıklarındaki yetersizlik, deprem sırasındaki zorlanmaya bağlı olarak donatıların burkulmasına ve beton örtüsünün dökülmesine sebep olabilir. Etriyeler, yeterli kenetlenmeyi sağlamak için boyuna donatı ile 135° lik bir açıyla kenetlenmelidir. Bu durum, enine ve boyuna donatı arasındaki ayrılmayı önler ve yapısal bütünlük için gerekli aderansı sağlar [18]. Adıyaman il merkezinde gerçekleştirilen saha çalışmasında, betonarme taşıyıcı elemanlarda etriye aralıklarının fazla olması ve etriye kanca açısı ile uzunluğunun standartlara uygun olmamasına bağlı olarak meydana gelen hasarların oldukça fazla olduğu tespit edilmiştir (Şekil 9(a-f)).

Betonarme yapılarda yatay deprem yüklerinin karşılanmasında deprem perdelerinin oldukça hayati bir rolü bulunmaktadır. Saha araştırmasında, perdelerde yapı inşası sırasında soğuk derz oluşumuna bağlı olarak kayma hasarı gözlemlenmiştir (Şekil 10(a)). Ayrıca, perdelerde enine ve boyuna donatı miktarlarının yetersiz olmasının yanısıra çiroz donatısı detayının Türkiye Bina Deprem Yönetmeliğinde (TBDY-2018) [17] belirtilen hususlara uygun olmaması nedeniyle hasar oluştuğu belirlenmiştir (Şekil 10(b)).



(a)

(b)

Şekil 10. Perde donatı detaylandırma hatalarına bağlı olarak meydana gelen hasarlar

3.4. Merdiven Hasarlarına Sebep Olan İşçilik Problemleri

Merdivenlerin yapıda insanların güvenli bir şekilde tahliye edilmesini sağlayacak şekilde deprem etkisindeki zorlanmaya bağlı olarak hasar almaması gerekmektedir. Adıyaman il merkezinde yapılan saha çalışmasında, birçok yapının merdiven ve sahanlıklarında önemli hasarlar meydana geldiği belirlenmiştir (Şekil 11(a-c)). Hasarların donatı detaylandırmasındaki problemlere bağlı olarak, merdivenlerin sahanlığa bağlandığı bölgede yoğunlaştığı ve kabuk atma şeklinde gerçekleştiği tespit edilmiştir.



(a)

(b)



(c)

Şekil 11. İşçilik problemlerine bağlı olarak meydana gelen merdiven hasarları

3.5. Bölme Duvar Hasarına Sebep Olan İşçilik Problemleri

Betonarme yapılarda, özellikle alanları sınırlandırmak ve ayırmak için kullanılan bölme duvarlarda çeşitli seviyelerde hasarlar meydana gelmiş ve insan hayatı için risk oluşturmuştur [19,20]. Bölme duvar malzemelerinin düşük mekanik özellikleri ve işçilik problemleri bu elemanların yapısal bütünlüğünü olumsuz etkilemiş, kesme çatlakları ve düzlem dışı hasarların meydana gelmesine sebep olmuştur (Şekil 12(a-b)).



(a)

(b)

Şekil 12. İşçilik problemlerine bağlı olarak meydana gelen bölme duvar hasarları

4. Sonuçlar ve Öneriler

Bu çalışmada, Adıyaman il merkezinde bulunan betonarme yapılarda 6 Şubat 2023 Kahramanmaraş merkezli depremlerin oluşturduğu hasarlar ile toptan göçmeler malzeme ve işçilik problemlerine bağlı olarak değerlendirilmiştir. Saha çalışması sonucunda aşağıdaki sonuçlar elde edilmiştir:

- 2000 yılı öncesi inşa edilen eski betonarme yapılarda hazır beton teknolojisinin kullanılmaması, agrega gradasyonunun uygun olmaması ve düşük çimento dozajı, beton dayanımının projede öngörülenden daha az olmasına neden olmuştur. Ayrıca, beton dökümünden sonra kür işleminin yapılmaması ve/veya taze betona sonradan ilave su eklenmesi betonarme yapılarda beton kalitesini daha da olumsuz etkilemiştir. Sonuç olarak, taze betonun döküm aşamasında ve sonrasında betonun kalitesini koruyacak ilave önlemler alınmalıdır.
- Betonarme yapı elemanlarının boyuna donatılarında gevrek kırılma olduğu belirlenmiştir. Donatı ile ilgili deneylerin her parti için titizlikle yapılması ve deney sonucu gelmeden donatı yerleşimine başlanmaması sağlanmalıdır.
- Yapım aşamasındaki işçilik hatalarına bağlı olarak oluşan yetersiz beton örtüsü ve segregasyon probleminin, yapının servis ömrünü olumsuz etkileyen donatı korozyonunu yaygın olarak oluşturduğu tespit edilmiştir. Segregasyonu tetikleyen unsurların ortadan kaldırılması için vibrasyon, kalıp malzemesi ve işçiliğine dikkat edilmelidir.
- Betonarme yapı elemanlarında etriye çap ve aralıkları ile etriye kanca detaylarının standartlara uymamasından dolayı önemli hasarlar olduğu belirlenmiştir. Özellikle kiriş-kolon birleşim bölgesi ve boğaz etriye detaylarının titizlikle uygulanması sağlanmalıdır.

- Farklı hasar düzeylerine sahip önemli sayıda yapı için merdiven donatı detaylandırmasındaki problemlere bağlı olarak merdiven hasarlarının olduğu tespit edilmiştir. Merdiven tasarımında, merdiven plağını daha az zorlayacak tasarımlara öncelik verilmeli ve merdiven donatı detaylarına dikkat edilmelidir.
- Taşıyıcı olmayan yapı elemanlarında işçilik problemlerine bağlı olarak özellikle bölme duvarlarda önemli hasarlar olduğu belirlenmiştir. Bölme duvarların daha az hasar almasını sağlamak için malzeme ve işçilik kalitesi artırılarak, duvar göçmelerine karşı file, hasır donatı vb. ilave önlemler alınmalıdır.

Yapılan saha çalışmasında gözlenen tespitler, ülkemizde meydana gelen diğer büyük depremlerden sonra gerçekleştirilen tespitlerden çok farklıdır. Özellikle işçilik problemleri ve denetim mekanizmasındaki sorunlar felaketin boyutlarını oldukça artırmıştır. Buradan, yapıların inşaa ve denetim sürecinde görev alacak elemanların yeterli bilgi birikimi ve uygulama tecrübesine sahip olması gerektiği açıkça söylenebilir. Ayrıca, betonarme yapı elemanlarında hasar oluşmasını engellemek için donatı detaylandırılmasına oldukça dikkat edilmelidir. Özellikle, donatı miktarı, bindirme boyu, etriye aralığı, pas payı ve etriye kanca detaylarının projeye tam uyum sağlanarak uygulanması oldukça önemlidir. Bu hususlar dikkate alındığında, betonarme yapıların depreme karşı dayanıklılığı önemli ölçüde artırılabilir ve Adıyaman ilinde gelecekte meydana gelebilecek sismik olayların olumsuz etkisi azaltılabilir.

Çıkar Çatışması Beyanı

Makale yazarları herhangi bir kurum, kuruluş, kişi ile kişisel ve finansal çıkar çatışması olmadığını beyan etmektedirler.

Kaynaklar

- [1] Kahramanmaraş ve Hatay depremleri raporu. Türkiye Cumhuriyeti Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı; 2023.
- [2] Türkiye deprem tehlike haritası. <https://www.afad.gov.tr/turkiye-deprem-tehlike-haritasi> (Erişim Tarihi: 01.02.2024)
- [3] Yenidoğan C. 6 Şubat 2023 depremleri ve saha gözlemlerine dayalı bina hasarları hakkında ön değerlendirme. Turkish Journal of Civil Engineering 2024;35(5):75-113.
- [4] Yıldız Ö, Kına C. Geotechnical and structural investigations in Malatya province after Kahramanmaraş earthquake on February 6, 2023. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi 2023;12(3):686-703.
- [5] Akar F, Işık, Avcil F, Büyüksaraç A, Arkan E, İzol R. Geotechnical and structural damages caused by the 2023 Kahramanmaraş earthquakes in Gölbaşı (Adıyaman). Applied Sciences 2024;14(5):2165.
- [6] Ozturk M, Arslan MH, Dogan G, Ecemis AS, Arslan HD. School buildings performance in 7.7 Mw and 7.6 Mw catastrophic earthquakes in southeast of Turkey. Journal of Building Engineering 2023;79(15):107810.
- [7] Ivanov ML, Chow WK. Structural damage observed in reinforced concrete buildings in Adiyaman during the 2023 Türkiye Kahramanmaraş Earthquakes. Structures 2023;58:105578.
- [8] Avcil F, Işık E, İzol R, Büyüksaraç A, Arkan E, Arslan MH, Aksoylu C, Eyisüren O, Harirchian E. Effects of the February 6, 2023, Kahramanmaraş earthquake on structures in Kahramanmaraş city. Natural Hazards 2024;120:2953-2991.
- [9] Altunsu E, Güneş O, Öztürk S, Sorosh S, Sarı A, Beeson ST. Investigating the structural damage in Hatay province after Kahramanmaraş-Türkiye earthquake sequences. Engineering Failure Analysis 2024;157:197857.

- [10] Çağlar N, Vural I, Kirtel O, Sarıbiyik A, Sumer Y. Structural damages observed in buildings after the January 24, 2020 Elazığ-Sivrice earthquake in Türkiye. *Case Studies in Construction Materials* 2023;18.
- [11] Sayın E, Yön B, Onat O, Gör M, Öncü ME, Tuğrul Tunç E, Bakır D, Karaton M, Calayır Y. 24 January 2020 Sivrice-Elazığ, Turkey earthquake: geotechnical evaluation and performance of structures. *Bulletin of Earthquake Engineering* 2021;19;657-684.
- [12] Westaway R. Present-day kinematics of the Middle East and eastern Mediterranean. *J Geophys Res* 1994;99.
- [13] Dewey JF, Hempton MR, Kidd WSF, Saroglu F, Şengör AMC. Shortening of continental lithosphere: The neotectonics of Eastern Anatolia - A young collision zone. *Geol Soc Spec Publ* 1986;19.
- [14] Tekin S, Akcan SO. 6 Şubat 2023 tarihinde (Mw 7.7 ve Mw 7.6) gerçekleşen depremler ile ilgili değerlendirmeler ve ilk analiz sonuçları. Adıyaman Üniversitesi Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Uygulama ve Araştırma Merkezi; 2023.
- [15] Baradan B, Yazıcı H, Ün H. Beton ve betonarme yapılarda kalıcılık (Durabilite). İstanbul: Türkiye Hazır Beton Birliği; 2010.
- [16] Doğangün A. Betonarme yapıların hesap ve tasarımı. 15. baskı. İstanbul: Birsen Yayınevi; 2018.
- [17] Türkiye bina deprem yönetmeliği. Afet ve Acil Durum Yönetimi Başkanlığı, TBDY-2018; 2018.
- [18] Ersoy U, Özcebe G. Betonarme. 2. baskı. İstanbul: Evrim Yayınevi; 2001.
- [19] Jia J, Song N, Xu Z, He Z, Bai Y. Structural damage distribution induced by Wenchuan Earthquake on 12th May, 2008. *Earthquake and Structures* 2015;9(1):93-109.
- [20] Temür R, Damcı E, Öncü-Davas S, Öser C, Sarğın S, Şekerci Ç. Structural and geotechnical investigations on Sivrice earthquake (M w = 6.8), January 24, 2020. *Natural Hazards* 2021;106:401-434.

AN ANALYSIS OF APACHE SPARK AND GPU PERFORMANCES ON DATABASE SQL QUERIES FOR DISTRIBUTED NETWORKS

Mehmet TURAN¹, M. Emin TENKEKİ², Kemal GÜNER^{3*},

¹Adiyaman Üniversitesi, Bilgi İşlem Daire Başkanlığı, Adiyaman, 02040, Türkiye

^{2,3}Harran Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Şanlıurfa, 63300, Türkiye

Geliş Tarihi/Received Date: 01.07.2024 Kabul Tarihi/Accepted Date: 03.10.2024 DOI:10.54365/adyumbd.1508182

ABSTRACT

The use of GPU in different fields and its successful results initiate efforts to use GPU in database systems. It is also effective in distributed systems and computer networks in that it accelerates computational tasks by leveraging parallel processing capabilities across multiple nodes and for tasks that require high computational power, such as network traffic analysis and real-time data processing. Digital transformation in all areas of life has led to the emergence of needs such as increased data diversity and faster data analysis. Upgrading the hardware capacity of the system or conducting software-based studies are possible solutions to analyze this data to meet the needs. In this study, Apache Spark and GPU performance differences are examined in commonly used SQL queries on big data. In this context, SQL queries such as grouping, sorting, and filtering, which are widely used in data analysis, are used. While the queries performed with the GPU showed similar results in simple queries compared to the queries performed with Apache Spark, the GPU was completed 3x faster in queries requiring calculation.

Keywords: GPU, Apache Spark, Distributed Networking, Big Data, HPC

DAĞITIK AĞLAR İÇİN VERİ TABANI SQL SORGULARINDA APACHE SPARK VE GPU PERFORMANSLARININ ANALİZİ

ÖZET

Her geçen gün farklı bir alanda kullanılmaya başlanan ve başarılı sonuçlar sergileyen GPU'nun veri tabanlarında kullanılmasına yönelik çalışmalar giderek yaygınlaşmaktadır. Ayrıca dağıtık sistemlerde ve bilgisayar ağlarında da birden fazla düğümde paralel işleme yeteneklerinden yararlanarak hesaplama görevlerini hızlandırmaya ve yüksek hesaplama gücü gerektiren ağ trafiği analizi, gerçek zamanlı veri işleme gibi görevlerde etkin olmaktadır. Hayatın her alanında gerçekleşen dijital dönüşüm veri çeşitliliğinde artış, verilerin daha hızlı analiz edilebilmesi vb. ihtiyaçların ortaya çıkmasına neden olmuştur. Bu verilerin analizi için sistem donanım kapasitesinin artırılması veya yazılım temelli çalışmalar ile ihtiyaçların karşılanabilmesine yönelik çözümler bulunmaktadır. Bu çalışmada ise büyük verilerde Apache Spark ve GPU'nun yaygın olarak kullanılan SQL sorgularındaki performans farklılıkları incelenmiştir. Bu kapsamda veri analizinde genel olarak kullanılan gruplandırma, sıralama ve filtreleme gibi SQL sorguları kullanılmıştır. GPU ile gerçekleştirilen sorguların Apache Spark ile gerçekleştirilen sorgulara göre basit sorgularda benzer sonuçlar sergilerken, hesaplama gerektiren sorgularda GPU'nun 3x kadar daha kısa sürede sonuçlandırmıştır.

Anahtar Kelimeler: GPU, Apache Spark, Dağıtık Ağlar, Büyük Veri, HP

e-posta¹ : mturan@adiyaman.edu.tr ORCID ID: <https://orcid.org/0000-0002-8038-0749>

e-posta² : etenekeci@harran.edu.tr ORCID ID: <https://orcid.org/0000-0001-5944-4704>

e-posta³ : kguner@harran.edu.tr ORCID ID: <https://orcid.org/0000-0003-3495-9044> (Sorumlu Yazar)

1. Introduction

Different concepts and approaches have emerged as a result of the developments aimed at increasing the quality of life. Depending on the object used, it is of great importance in terms of effective use of resources, determining new strategies for solving problems, increasing satisfaction and reducing errors, etc. The concept of data, whose value increases depending on its variety and size, becomes meaningful if it is possessed on a regular base and accurately. By utilizing data in many fields, it is possible to make inferences about how to move forward and what kind of measures should be taken. Data, which was kept limited until recently, has led to the emergence of new systems or solutions in larger volumes, more variables, and faster increases in parallel with the digital transformation that has taken place in recent years. While there was no significant problem in the studies that were widely used and carried out with computers in the past, the growing amount of data and the need to get results from these data in a shorter time have led to the emergence of different technologies.

Initially, CPUs, disks, and RAMs were used for faster processing for long-running operations. When the system used was not sufficient to meet the needs in terms of performance, the problem was solved with new hardware with a higher capacity. Although the developments in the hardware sector have reached a certain point, the amount of data used in processing not only has begun to increase rapidly but also it has been used in different fields. Real-time access to data and the ability to process it in a shorter time are of great importance for sectors operating in similar fields to compete and be advantageous [1].

Efforts to improve the performance of data processing such as analysis, storage, and visualization are of great importance. This has led to significant developments depending on the impact of big data analysis and evaluations of these analyses [2]. Moreover, the state-of-the-art open-source parallel processing frameworks/programming models such as Impala, Hadoop, Spark, and MapReduce have evolved to overcome the issues of distributed big data. In these frameworks/models, the need for more efficient processing of data is met by adding a new server when the server is insufficient with horizontal scalability. Apache Spark, one of the scalable structures used in big data processing, stands out amongst others. With Spark, the system can be scaled to thousands of nodes. With its ability to perform in-memory computation, Apache Spark is preferred because it gives faster results than other big data processing frameworks [3-4]. Today, with the increase in RAM memory capacities, the increase in performance with memory access instead of disk access offers new opportunities to those working in this field [5-6]. In applications utilizing Spark, the size and type of input data and the design of algorithms have a great impact on the performance of the computation process [7-10].

Significant progress has been achieved in GPU technology with the stagnation of developments in the CPU compared to the past, the ability to program GPUs, and their use in different fields. Modern GPUs are not only powerful graphics cards, but they are also preferred for computationally demanding operations due to their parallel computing capability and faster processing compared to traditional CPUs due to their high memory bandwidth [11-13]. The high performance in operations performed with GPU has led to an increase in the number of studies in this field and the concept of GPU Computing has become widespread. Compared to traditional microprocessors, GPUs are seen as a good alternative due to their high capacity in computationally demanding operations. GPUs allow not only graphics operations and calculations but also the execution of any algorithm. The complexity of the hardware used and the complexity of the user functions play an important role in achieving the success obtained from GPU applications [14].

Parallel data processing and the ability to perform parallel computation are the key features that make GPUs stand out. In the microprocessors being developed for GPUs, efforts are being made to increase not only the thread performance but also the number of cores. While the GPU's performance and potential hold great promise for new computer systems, its architecture and programming model are distinctly different from other uniform processors. Increasing the number of programmable processor cores in the GPU has a significant impact on increasing the total system output [15-16]. Furthermore,

combining processors allows for very effective load balancing. This is because any processing function can utilize the entire array of processors.

Achieving high performance in GPU-executed operations depends on using the full memory bandwidth of the GPU and designing the application in a way that is compatible with parallelization. CUDA's scalable programming model enables parallel computing applications to handle large numbers of workloads while allowing parallel processor cores to scale [17]. The computational performance obtained from the GPUs can be achieved by using more than one CPU, but it is not as successful as GPUs in terms of performance/power consumption. GPUs are very efficient in terms of the work they do and the energy they consume [18]. Applications that are not organized according to GPU operation cause a great loss in terms of the amount of energy consumed due to the inability to use GPU capacity effectively.

With the digital transformation, every object has become part of a network. The fact that these objects communicate with each other according to certain rules and the unique addressing of the data has led to the emergence of different approaches. With these developments, it has become possible for every object that is part of daily life to be part of a network, to record the activities of these objects depending on their functioning, and to transfer these records to certain centers depending on the user's permission. This situation makes it easier for service providers to work on many aspects such as development and security based on this data. Big data is generated in every area where technology is used, such as internet service providers, servers, and applications. In the relevant units of many large or small enterprises, there are systems for tracking activities. Billions of data can be recorded in these systems every day. It is of great importance that the processes related to the analysis of these data can be carried out in a shorter time and reports can be created for the needs, and the loss that will occur in the sectors where these data are used can be minimized and measures can be taken. Therefore, it becomes a necessity rather than a need to realize the data analysis process as earliest as possible.

There are many studies on the processing of databases using GPU. Due to the programmability of the GPU, it is seen as a potential hardware that can show higher performance than CPU-based applications in many areas. In this study, the effect of the GPU's parallelization and internal memory advantage on the performance of in-memory data analytics operations on the congestion that prevents full performance in data transfer between CPU and RAM memory is observed. Although the intended use of the data is different, the underlying variables and characteristics are similar. For this purpose, the performance of the GPU in processing log data by considering the processing power and operating principles of the GPU and the performance differences of Apache Spark in the same processes are analyzed.

With two different computing technologies, GPU and Apache Spark, the same SQL queries for commonly used operations such as querying, filtering, grouping, and computation in data were repeatedly performed at different times and for certain numbers of times in two different models and the completion times of the operations were compared.

2. Related Work

Parallel communication and synchronization, as well as sustainable scalability, is one of today's hottest topics. Organizations that direct their activities based on data analysis have a great advantage in their competition with each other [19]. This situation requires the development of new tools to solve the challenges caused by the volume, diversity, and speed characteristics of big data.

Since NVIDIA introduced parallel computing on GPUs with CUDA in 2006, there have been many efforts for different purposes. Although GPU-based database applications are still at the beginning of the road, serious work continues in this field [20]. GPU-based systems can be a good option in terms of both energy and cost to accelerate applications in big data processing and intensive computing. While GPUs are a good option for reducing computational load and efficient resource scheduling, they also have some challenges. The most important challenge is that achieving high performance depends on advanced application development knowledge. Wrede and Ernsting [14] argue that GPUs can provide

significant acceleration in certain situations, but the complexity of the hardware and its functions is a determining factor in achieving this result.

With the introduction of CUDA and OpenCL, the programming of GPUs has become much more efficient. GPU cards, which were mathematically used to greatly increase video processing and transformation tasks, were then used in different areas. He et al. [21], using CUDA, designed a join algorithm that also includes sorting and achieved 2-7 times the performance compared to CPU. Again, Bakkum and Skadron [22] concluded simple queries performed by executing SQLite on GPU within the virtual machine infrastructure 20x faster than SQLite.

Wu [23], considering the limited memory capacity of the GPU, the algorithms applied to the data cannot be used directly for big data. With CUDA unified virtual addressing, data is not necessarily copied to the GPU, as the GPU can directly access the data in CPU memory. However, the performance of the algorithm used will be decisive, depending on the PCIe bandwidth. According to He et al. (2009), the bandwidth for data exchange between GPU and CPU is limited. In addition, the CPU does not allow dynamic memory allocation for GPU cores, so algorithms need to be designed carefully.

Breß et al. [24] argued that a hybrid approach that decides whether to execute the query on the GPU or CPU with a self-adjusting query editor would be a better solution in terms of performance with the HyPE application they developed. Again, Ilić et al. [25], with the application they developed, stated that the use of two processing centers together, depending on the scheduling library to execute the work to be done on the CPU or GPU, contributed significantly to the performance increase.

Li et al. [26] have achieved a performance increase of up to 18x in different machine learning applications with the HeteroSpark platform but emphasized the insufficient memory size when using large data in experiments with a single GPU, and the complexity of data partitioning in multi-GPU applications. In a detailed analysis of queries performed on CPU and GPU, the GPU can only be used for specific queries that can be fixed in memory, which causes problems in compatibility with data storage systems [27].

3. Material & Method

The materials used in this study, which analyzes big data queries on Apache Spark and GPU, consist of hardware, software, and data. The hardware includes a Tesla T4 GPU, 12 GB DDR RAM, and an Intel Xeon 2200 MHz CPU. The software is a Python application using Apache Spark and BlazingSQL libraries. Apache Spark is an open-source, scalable, fault-tolerant, easy-to-use & fast distributed computing framework that runs on datasets. It is also widely used in Java, Scala, Python, and R due to its development APIs and extensive libraries. It supports code reuse across multiple workloads such as real-time data analysis and engineering, graphics processing, data science, and machine learning. For example, it enables parallelization of machine learning algorithms and data transformation logic, enabling fast processing on distributed storage systems of varying sizes and types. Another important reason why Apache Spark preferred in this study is that Spark applications can perform approximately 100 times faster in-memory operations on Hadoop clusters and 10 times faster on disk. In addition, the MapReduce feature allows Spark to be implemented independently. On the other hand, since Apache Spark is an open-source, distributed processing system used for big data workloads, it has some limitations inherent to distributed systems, such as delays, congestion, packet loss, and varying speed due to internet infrastructure services.

Table 1. Processing parquet file with BlazingSQL

```

....
# Create table from parquet file
bc.create_table(deletions, '/content/deletions.parquet')
# SQL Query processing
result = bc.sql('SELECT count(*) FROM main.deletions GROUP BY
creator(key)').get() result_gdf = result.columns
#Showing results print(result_gdf)
....

```

BlazingSQL, on the other hand, offers the convenience of performing the same operations on the GPU that cuDF does on the GPU with the SQL interface instead of the DataFrame functions of ETL raw data performed on the GPU with cuDF (RAPIDS). As in cuDF, the Python language in BlazingSQL offers ease of use and supports many SQL functions, although it cannot perform all the SQL functions. It is easier to create tables with BlazingSQL because Parquet holds metadata. Table 1 shows an example of using BlazingSQL with Python language. The last component of our study is the data, which is approximately 8GB in size and consists of 62,000,000 rows of deletion activity logs for March 2013 provided by the Freebase API under the CC-BY license.

Table 2. The specification of Tesla T4 GPGPU

Specs	
GPU Architecture	NVIDIA Turing
Number of NVIDIA Tensor Core	320
Number of NVIDIA Cuda Core	2560
Single Precision	8.1 TFLOPS
Mixed Precision	(FP16/FP32) 65 TFLOPS
INT8	130 TOPS
INT4	260 TOPS
GPU Memory (GPU Belleği)	16 GB GDDR6 300 GB/sec
ECC	Yes
Interconnect Bandwidth	32 GB/sec
System Interface	x16 PCIe Gen3
Form Factor	Low-Profile PCIe
Thermal Solution	Pasif
Compute APIs	CUDA, NVIDIA TensorRT™, ONNX

Since cuDF and BlazingSQL libraries are compatible with this GPU card, Tesla T4 Graphics processing unit (GPU) is preferred. Additionally, T4 puts forward the benefits of high throughput and lower power consumption as well.

For query performance to be realized in a shorter time in big data, it is necessary to use column-oriented data, which is also suitable for the operation of the GPU. For this purpose, our activity records in CSV format have been converted to column-oriented Parquet format that can be used in both Apache Spark and our GPU application. Converting our 8GB raw CSV data into Parquet format resulted in a compressed data file of approximately 2GB. The reduction in data size is due to the fact that Parquet stores and compresses the data in binary format.

The only difference between row-oriented databases and column-oriented databases is that when a row with row-oriented data is called, the data that is not needed in the row is included in the process, and then the target data can be reached by filtering the unwanted part. In column-oriented data, only the desired row of the relevant column is called (Figure 1)

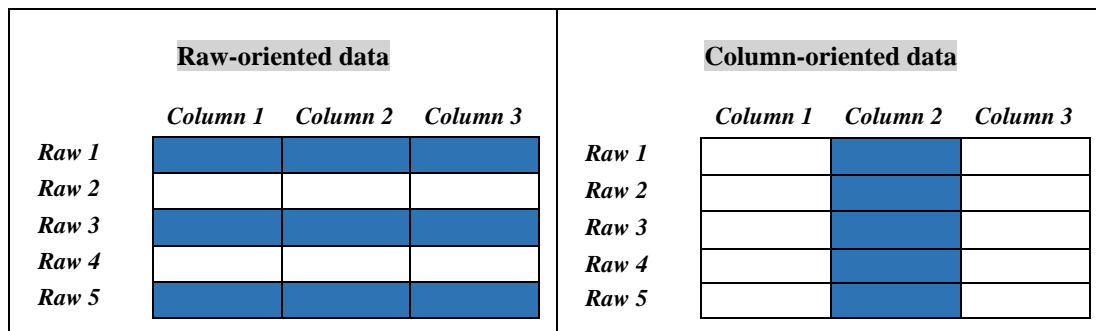


Figure 1. Row and Column oriented databases

The types of queries to be performed for the data are given in Table 3. The reason why these queries were chosen is that they are widely used queries in many applications. The queries were executed at least 5 times at different times with both GPU and Apache Spark and the average execution time was taken into account for experimental results.

Table 3. Query types

1.	Selection of top 10 records with all fields
2.	Sort by any field
3.	Top 10 records with selected specific fields.
4.	Number of total records in any domain
5.	Number of different records in any domain
6.	Grouping by a specific field and the number of records in that group
7.	Choosing according to a certain condition

The details of the query types mentioned in Table 3 for SQL, Spark DataFrame and cuDF DataFrame queries in our Python implementation can be seen in Table 4.

Table 4. Queries for SQL, cuDF, and Apache Spark

1.	SQL	SELECT * FROM Deletions LIMIT 10
	cuDF DataFrame	cuDF.head(10)
	Spark DataFrame	sparkDF.limit(10)
2.	SQL	SELECT * FROM Deletions ORDER BY creation_timestamp
	cuDF DataFrame	cuDF["creator"].sort_values(['creator'])
	Spark DataFrame	sparkDF.orderBy("creation_timestamp")
3.	SQL	SELECT creator, deleter FROM Deletions LIMIT 10
	cuDF DataFrame	cuDF[["creator", "deleter"]].head(10)
	Spark DataFrame	sparkDF.select("creator", "deleter").limit(10)
4.	SQL	SELECT COUNT(*) FROM Deletions
	cuDF DataFrame	cuDF["creator"].count()
	Spark DataFrame	sparkDF.count()
5.	SQL	SELECT COUNT(DISTINCT creator) FROM Deletions
	cuDF DataFrame	cuDF["creator"].unique().count()
	Spark DataFrame	sparkDF.select("creator").distinct().count()
6.	SQL	SELECT COUNT(*) as NumOfEvents, creator FROM Deletions GROUP BY creator
	cuDF DataFrame	cuDF.groupby("creator").agg({"creator": "count"})
	Spark DataFrame	sparkDF.groupBy("creator").count().select("creator", "count")
7.	SQL	SELECT * FROM Deletions WHERE deleter = 'user/funderhill'
	cuDF DataFrame	cuDF.query('deleter == 'user/funderhill')
	Spark DataFrame	sparkDF.where("deleter == 'user/funderhill'")

While processing with Apache Spark, the database is selected through the Driver, then the queries are interpreted with the help of SparkContext, and the related calculations are performed with the help of the Cluster Manager, and the task is completed by performing the tasks on the JVM Nodes where the executors are located (Figure 2).

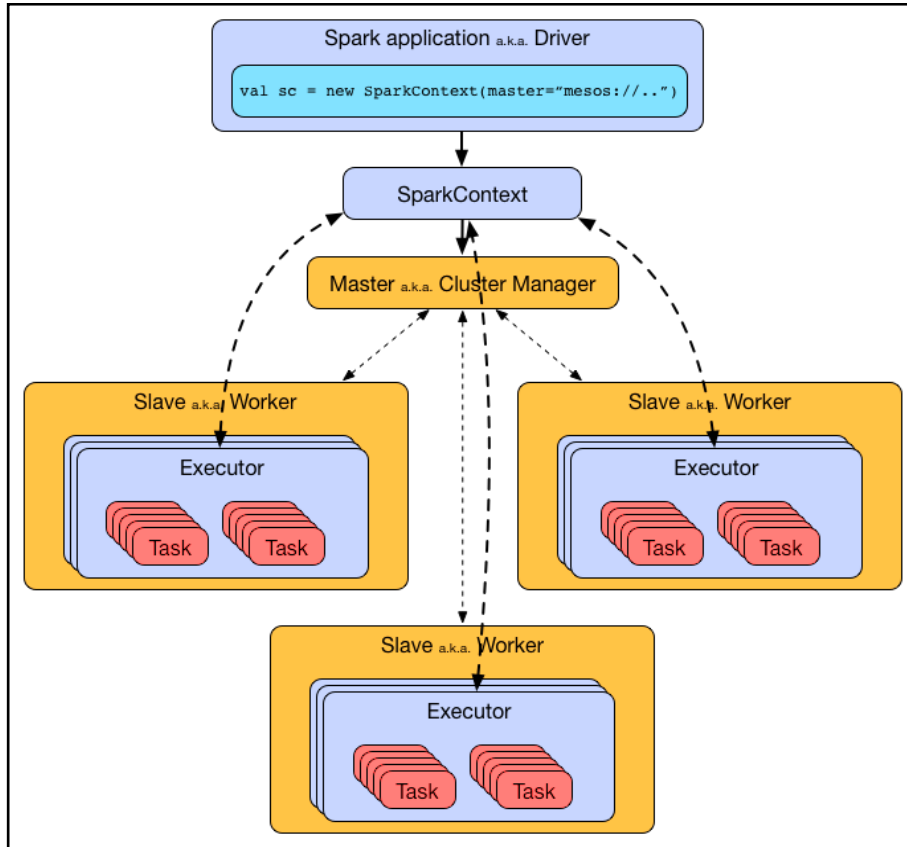


Figure 2. Apache Spark query workflow [28].

After BlazingSQL makes the SQL query compatible on cuDF, Python functions are converted to PTX (the pseudo-assembly language used in CUDA programming) code. The request is then converted to PTX code with CUDA JIT, and finally, the query is executed on the CUDA device using Python Numba and CUDA driver API, and the results are transferred to the CPU (Figure 3).

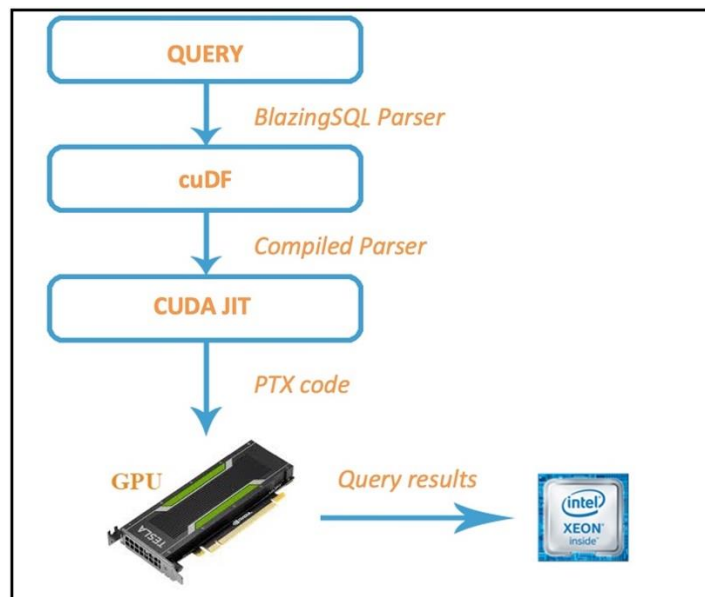


Figure 3. GPU query workflow




Figure 4. The execution times of the queries

In Figure 4, where the performances of two different computing technologies are examined, the execution times of the query operations are considered. No significant difference was observed in the 1st query, where there was no calculation process, and the 6th query, in which conditional filtering was performed. On the other hand, in sorting, grouping, and conditional sorting, the GPU completed the process as little as 3 times faster than Apache Spark (Figure 4).

Moreover, the potential of the GPU in parallel computing is used in the analysis of big data, and its effects on performance are examined. For this purpose, Apache Spark, which stands out due to its success in in-memory computation, and GPU's SQL query execution times are evaluated. For the effective use of GPU, it is of great importance that the application is developed in accordance with the structure and functioning of GPU. While no significant difference was observed in the execution times of requests for simple queries, the GPU had positive effects on the performance increase for computationally demanding queries.

The large volume characteristic of big data also requires high-capacity memory allocation. The limited GPU memory causes the used data size to be within these limits. At this point, in GPU workstations with multiple GPUs, GPUs can be parallelized among themselves to work with larger data.

4. Results and Future Work

In this study, the characteristics of big data, GPU's potential in computational operations, and Apache Spark's power in big data processing are discussed. We used a column-oriented data storage format that both reduces unnecessary work assigned to the CPU and fits the GPU's architecture. In terms of the performance of queries performed with the GPU, it was examined whether the computational power of the GPU would have the same effect on data querying as Apache Spark queries performed with the CPU. For this purpose, activity (log) records kept for different purposes in many sectors were used. The same queries were executed at different times with certain periods and the average execution times for each query type were compared.

Queries were executed on both CPU and GPU, and the same queries were executed in different time periods and a certain number of times, and each query was compared separately. Overall, no significant performance difference was observed in basic queries, but in queries that required sorting, grouping,

and conditional computation, the GPU completed the query in approximately 3x less time. As a result, it was seen that it is possible to perform operations in a shorter time by using GPU in data querying as in many computationally demanding operations.

Nowadays, there are more and more studies on the use of GPUs in terms of computational success and energy-efficient use of big data. Deep learning, machine learning graphics applications, engineering applications, and applications used extensively in scientific research also have GPU support. Recently, there has been much scientific research on the use of GPU in big data solutions such as distributed computing and networking. It will not be a surprise that large-scale data solutions such as Hadoop, Spark, and Hive will have GPU support in the near future.

Conflict of Interests

The authors of the article declare that they have no personal or financial conflict of interest with any institution, organization or person.

References

- [1] Einav L, Levin J. The Data Revolution and Economic Analysis. Innovation Policy and the Economy. University of Chicago Press 2014; 14(1): 1-24
- [2] Mishra R, Sharma R. Big Data: Opportunities and Challenges. International Journal of Computer Science and Mobile Computing. 2015; 4(6): 27-35.
- [3] Spark 101: What Is It, What It Does, and Why It Matters. <https://mapr.com/blog/spark-101-what-it-what-it-does-and-why-it-matters> (Erişim Tarihi: 03.06.2024)
- [4] Ahmed N, Barczak ALC, Susnjak T, Rashid MA. Comprehensive Performance Analysis of Apache Hadoop and Apache Spark for large scale data sets using HiBench. Journal of Big Data 7. 2020;110.
- [5] The New Era of Big Data. <https://www.forbes.com/councils/forbestechcouncil/2023/05/24/the-new-era-of-big-data/> (Erişim Tarihi: 24.5.2023)
- [6] Guner K, Kosar T. Energy-Efficient Mobile Network I/O. In: IEEE Global Communications Conference (GLOBECOM), Abu Dhabi, United Arab Emirates, 2018; 1-6.
- [7] Wang K, Khan MMH. Performance Prediction For Apache Spark Platform. In: High Performance Computing and Communications (HPCC), IEEE 7th International Symposium On Cyberspace Safety and Security (CSS), IEEE 12th International Conference On Embedded Software and Systems (ICESSE), IEEE 17th International Conference, New York, 2015; 166-173.
- [8] Tang S, He B, Yu C, Li Y, Li K. A Survey on Spark Ecosystem: Big Data Processing Infrastructure, Machine Learning, and Applications. In: IEEE Transactions on Knowledge and Data Engineering. 2022; 24(1):71-91.
- [9] Lunga D, Gerrand J, Yang L, Layton C, Stewart R. Apache Spark Accelerated Deep Learning Inference for Large Scale Satellite Image Analytic In IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 2020 13(1):271-283
- [10] Tang Z, Zeng A, Zhang X, Yang L, Li K. 2020, Dynamic memory-aware scheduling in spark computing environment. Journal of Parallel and Distributed Computing 2020 141: 10-22
- [11] Şahin H. Real Time Orthorectification Of Images By General Purpose Computation On Graphical Processing Units Method. Ph.D. thesis Istanbul: Istanbul Technical University: 2016.

- [12] Tirmazi M, Basat RB, Gao J, Yu M. Cheetah: Accelerating Database Queries with Switch Pruning. In: ACM SIGMOD International Conference on Management of Data (SIGMOD '20). Association for Computing Machinery, New York, NY, USA, 2020; 2407–2422
- [13] Guner K, Nine MSZ, Bulut MF, Kosar T. Fasthla: Energy-efficient mobile data transfer optimization based on historical log analysis. In: 16th ACM International Symposium on Mobility Management and Wireless Access, 2018; 59-66.
- [14] Wrede F, Ernsting S. Simultaneous CPU-GPU Execution of Data Parallel Algorithmic Skeletons. *International Journal of Parallel Programming*. 2017; 46(1): 42-61
- [15] Wolf M. *High-Performance Embedded Computing: Applications in Cyber-Physical Systems and Mobile Computing*. 2nd ed. Morgan Kaufmann; 2014; 59-138.
- [16] Lee R, Zhou M, Li C, Hu S, Teng J, Li D, Zhang X. The art of balance: a RateupDB™ experience of building a CPU/GPU hybrid database product. In: proceedings of the VLDB Endowment. 2021; 14(12); 2999–3013.
- [17] Nvidia 2011a. Cuda C Programming Guide. <https://docs.nvidia.com/cuda/cuda-c-programming-guide/index.html> (Erişim Tarihi: 21.02.2018)
- [18] Nvidia 2011b. Energy Efficiency. <http://www.nvidia.com/object/gcr-energy-efficiency.html> (Erişim Tarihi: 22.02.2018)
- [19] The Rise of the Data Economy: Driving Value Through Internet of Things Data Monetization. <https://www.ibm.com/downloads/cas/4jroldq7> (Erişim Tarihi: 07.11.2017)
- [20] Farooqui N, Roy I, Chen Y, Talwar V, Barik R, Lewis BT, Shpeisman T, Schwan K. Accelerating Data Analytics on Integrated Gpu Platforms via Runtime Specialization. *International Journal of Parallel Programming*. 2016; 46: 336-375.
- [21] He B, Yang K, Fang R, Lu M, Govindaraju NK, Luo Q, Sander P. (2008). Relational Joins on Graphics Processors. In: proceedings of the Acm Sigmod International Conference on Management of Data, Sigmod2008, Vancouver, Canada; 2008; 511-524.
- [22] Bakkum P, Skadron K. 2010. Accelerating Sql Database Operations on A Gpu with Cuda. In Gppgu10: Proceedings of the Third Workshop on General-Purpose Computation on Graphics Processing Units, Newyork; 2010; 94-103.
- [23] Wu H. Acceleration and Execution of Relational Queries Using General Purpose Graphics Processing Unit (GPGPU). Ph.D. thesis. Atlanta: Georgia Institute of Technology; 2015.
- [24] Breß S, Schallehn E, Geist I. Towards Optimization of Hybrid CPU/GPU Query Plans in Database Systems. In: *New Trends in Databases and Information Systems 2013*; 27-35.
- [25] Ilić A, Pratas F, Trancoso P, Sousa L. High-Performance Computing on Heterogeneous Systems: Database Queries on CPU and GPU. In: *High Performance Scientific Computing with Special Emphasis on Current Capabilities and Future Perspectives*, 2011; 202–222.
- [26] Li P, Luo Y, Zhang N, Cao Y. Heterospark: A Heterogeneous CPU/GPU Spark Platform for Machine Learning Algorithms. In: *International Conference of Networking Architecture and Storage*, Boston, USA; 2015; 347-348.
- [27] Yuan Y, Lee R, Zhang X. The Yin and Yang of Processing Data Warehousing Queries on GPU Devices. In: *Proceedings of The Vldb Endowment*, 2013; 6(10): 817-828.
- [28] Khourdifi Y, Elalami A, Bahaj M, Zaydi M, Er-Remyly O. Chapter 9 - Framework for integrating healthcare big data using IoMT technology. In: *Advances in ubiquitous sensing applications for healthcare, Computational Intelligence for Medical Internet of Things (MIoT) Applications*, Academic Press 2023; 14; 191-210

METAHEURISTIC MULTI-OBJECTIVE OPTIMIZATION APPROACH FOR REPETITIVE CONSTRUCTION PROJECT SCHEDULING

Gülçağ ALBAYRAK*

Eskişehir Osmangazi University, Faculty of Engineering and Architecture, Department of Civil Engineering, Eskişehir, 26040, Türkiye

Received date/Geliş tarihi: 03.05.2024 Accepted date/Kabul tarihi: 07.10.2024 DOI: 10.54365/adyumbd.1477358

ABSTRACT

The optimization of schedules for repetitive projects is a crucial phase in establishing an effective project timeline concerning both duration and cost. This study presents an innovative metaheuristic multi-objective optimization model tailored for repetitive projects. Distinguished by its original features, this model empowers schedulers to identify an optimal schedule that concurrently minimizes project duration, total cost, and interruption time. It encompasses various constraints and factors, including learning and forgetting effects, inter-activity soft logic, limited work interruption allowances, multiple crew formations, multiple construction methods per activity, while retaining all Critical Path Method (CPM) scheduling capabilities. The effectiveness of this new approach was validated through application to two case studies, demonstrating its capability to deliver optimal schedules for repetitive projects with heightened accuracy in minimizing project duration, cost, and interruption. Furthermore, the integration of learning effects, soft logic, and work interruption allowances within the optimization process substantially reduced project duration and cost, thereby yielding more precise and dependable optimal solutions.

Keywords: *Learning effect, Optimization, Project planning, Repetitive project, Soft logic*

TEKRARLI İNŞAAT PROJESİ ÇİZELGELEMESİ İÇİN METASEZGİSEL ÇOK AMAÇLI OPTİMİZASYON YAKLAŞIMI

ÖZET

Tekrarlı projeler için çizelgeleme, hem süre hem de maliyet açısından etkili bir proje programı oluşturmada çok önemli bir aşamadır. Bu çalışma, tekrarlı işlemleri bulunan projelere uyarlanmış yenilikçi bir metasezgisel çok amaçlı optimizasyon modeli sunmaktadır. Model, planlayıcılara proje süresini, toplam maliyeti ve kesinti süresini aynı anda en aza indiren optimal çizelgeyi belirleme olanağı veren orijinal özellikleriyle öne çıkmaktadır. Model, Kritik Yol Yöntemi (CPM) planlama yeteneklerini korurken, öğrenme ve unutma etkileri, etkinlikler arası yumuşak mantık, iş kesintileri, birden fazla ekip oluşumu, her faaliyet için birden fazla inşaat yöntem seçimi dahil olmak üzere çeşitli kısıtlamaları ve faktörleri kapsamaktadır. Bu yaklaşımın etkinliği, tekrarlı projeler için proje süresini, maliyetini ve kesintiyi en aza indirerek daha yüksek doğrulukla en uygun programları sunma yeteneğini gösteren iki örnek olay incelemesine uygulanarak doğrulanmaktadır. Ayrıca, öğrenme etkilerinin, yazılım mantığının ve iş kesintisi ödeneklerinin optimizasyon sürecine entegrasyonu, proje süresini ve maliyetini önemli ölçüde azaltmakta ve böylece daha kesin ve güvenilir optimum çözümler elde edilmektedir.

Anahtar Kelimeler: *Öğrenme etkisi, Optimizasyon, Proje planlama, Tekrarlı proje, Yumuşak mantık*

* e-mail¹ : galbayrak@ogu.edu.tr ORCID ID: <https://orcid.org/0000-0001-6114-4292>

1. Introduction

The repetitive construction projects entail numerous similar units, each requiring completion of a predefined set of activities. Achieving a comprehensive schedule for repetitive projects, therefore, demands meticulous planning and management of all resources. The crews must complete work in one unit before moving on to the next, necessitating the project scheduler to ensure continuity of work for all resources involved. Maintaining work continuity for crews can reduce idle time and costs, while enhancing productivity and boosting morale among laborers [1].

Two main categories of project scheduling methods exist. The first one is called time-driven and the second type is resource-driven [2]. However, time-driven methods, like the Critical Path Method (CPM), do not account for the work continuity constraint, making them unsuitable for scheduling repetitive projects [3]. This resulted in the development of resource-driven techniques, including the linear scheduling method [4], the Line of Balance (LOB) [5], and other approaches that adapt any of the aforementioned methods. In addition, many methods adopting the Gantt method, Linear Scheduling Method (LSM) and Program Evaluation and Review Technique (PERT) are actively used in the engineering practice; however, the applicability of these techniques varies according to the type and size of the project [6]. On the other hand, resource-based systems guarantee that each team works without any interruptions to minimize downtime, making them appropriate for scheduling repetitive undertakings. The resource-driven methods have proven effective in scheduling repetitive projects, but certain limitations must be addressed for optimal, practical outcomes [7].

The strict adherence to work continuity constraints between repetitive activities may result in longer project durations and higher indirect costs [8]. However, some argue that permitting interruptions during specific tasks when organizing recurrent projects may lead to reduced project timelines [1]. When scheduling and optimizing the project, it is important to consider the forgetting effect resultant from interruptions. The interruptions should be kept to a minimum to prevent idle time and mitigate costs.

Integrating the learning effect into scheduling repetitive projects is believed to result in better accuracy when forecasting project duration, cost, and labor requirements. However, the previous optimization models for repetitive projects did not consider this effect, leading to less reliable and usable optimum solutions for project planners. In addition, it is essential to evaluate various logical sequence alternatives for resolving the time-cost trade-off quandary in repetitive projects [9].

In construction, the order of activities can be categorized into two distinct types: 1) hard logic, which is mandatory and unalterable and 2) soft logic, which presents various potential sequences of activities and allows for the selection of the optimal one [10]. Optimal selection of soft logic for repetitive activities can lead to reduced overall project duration and cost [2]. Soft logic exists in repetitive projects in two forms: firstly, soft logic between units and their interrelations, which has already been studied in the literature [9]; secondly, soft logic within activities themselves in the same unit, which has not been considered in previous optimization models.

Pivotal for effective project management is the accurate identification and incorporation of both forms of soft logic into project planning and execution. There is clearly a crucial necessity for a novel optimization model that surpasses these limitations and generates practical optimal solutions suitable for the construction industry.

The most significant aspect that distinguishes the current study from previous researches is that the developed method has provided convenience and flexibility to the decision-maker considerably. Many variables, each of which must be solved separately, are addressed in an integrated manner through the proposed method. The development of this new model fills a gap in the literature because it combines elements such as learning and forgetting effects, flexible relationships between activities, and the ability to incorporate work interruptions, various crew configurations, and multiple construction methods for each task.

This research introduces a heuristic multi-objective optimization model that addresses all the constraints and factors involved, including the learning and forgetting effects, maintaining soft logic between activities, limiting work interruptions to minimize project duration and reduce crews' idle time, multiple crew formations, multiple construction methods for each activity, and retaining all CPM scheduling capabilities. The proposed model can concurrently reduce the project duration, total cost, and work disruption. This paper presents two case studies; the first validates the model, while the second illustrates its complete capabilities.

2. Literature Review

Optimization studies can be categorized by either their objectives or their methods. The key optimization objectives include minimizing project duration, cost, idle time, resource fluctuations and maximizing profit and net present value [11]. To accomplish these goals, several optimization approaches have been developed, which can be classified as: 1) Mathematical methods, including linear, dynamic, and constraint programming, have been employed in previous researches: [2, 12, and 13]. 2) Heuristic methods have also been utilized [8]. 3) Meta-heuristic methods, such as genetic, particle swarm, and ant colony algorithms, have shown promising results in this field [14, 15]. These techniques can be applied deterministically, or with the use of stochastic models by incorporating simulation techniques, like fuzzy set theory, in order to tackle scheduling uncertainties [16].

Reda [17] presented a linear programming model, which implemented activity time-cost curves to minimize direct costs while maintaining a consistent production rate, in order to optimize the duration of activities. Moselhi and El-Rayes [18] as well as Senouci and Eldin [19] have formulated dynamic programming models to determine the optimal crew size for each activity in order to reduce the project cost. Hegazy and Wassef [20] along with Elbeltagi et al. [21] have applied Genetic Algorithm (GA) techniques to establish the ideal combination of construction methods, crew numbers and interruption durations of activities to decrease the entire project cost.

El-Rayes and Moselhi [22] developed a dynamic programming model, while Hyari and El-Rayes [23] utilized a GA model to minimize project duration and interruption time for each crew. Both models accommodated work interruptions and identified the optimal crew formation, enabling the achievement of minimum project duration. Ipsilandis [24] proposed a linear programming model that considers idle time of resources to minimize overall project duration.

Liu and Wang [25] combined single and multiple-skilled crews through a constraint-programming model to boost productivity and work quality while reducing project duration. Zou et al. [8] proposed a heuristic model that prioritizes work continuity while minimizing the number of crews and allowing for work interruptions to meet a given deadline.

Multi-objective models have been introduced to optimize more than one objective. El-Rayes [26], Moselhi and Hassanein [12] have proposed object-oriented models that incorporate dynamic programming formulas to minimize project duration or cost by finding the best crew formation. Zhang et al. [27] minimized both duration and cost by using a heuristic permutation tree-based model, while Senouci and Al-Derham [28] utilized a GA model to consider various construction methods. Long and Ohsato [29] used a GA model that enables interruptions while optimising duration and cost. GA models developed by Hyari et al. [30] and Eid et al. [31] yield a set of Pareto optimal solutions by taking into account delay damage and early completion incentives.

Heravi and Moridi [15] put forward a particle swarm model to reduce project time and cost by taking into account resource availability and the cost of idle resources. García-Nieves et al. [13] suggested a linear programming model that minimizes project duration or cost while allowing multiple modes of execution. Zou and Zhang [2] proposed a constraint-programming model to minimize project costs within a specified deadline by considering the soft logic of the same activity in different units.

Kaveh et al. [32] presents an innovative algorithm for addressing many-objective trade-offs in construction scheduling, aiming to select the ultimate solution from a set of non-dominated solutions according to the priorities set by the project team. Bettemir and Yücel [33] suggests that construction options can be created by allocating various crew sizes for task execution, with job efficiency being evaluated based on the crew size. The construction duration of each activity is calculated taking into account the necessary workmanship, crew size, and job efficiency, thereby automating the generation of crashing alternatives.

Stochastic models were utilized to incorporate uncertainty into the schedule. For instance, Bakry et al. [34] and Salama and Moselhi [35] created models that optimize project duration and cost while accounting for uncertainties associated with work quantities, resources availability, productivities, and costs. Other studies aimed at optimizing different objectives. For instance, Huang and Halpin [36] optimized the project's overall construction rate by using a graphic linear programming model. Srisuwanrat and Ioannou [37] maximized profits while considering probabilistic durations by using GA model. Huang and Sun [11] maximized the net present value with the help of GA model. Bragadin and Kahkonen [38] minimized idle time for resources using a heuristic algorithm. Notably, previous optimization models failed to utilize learning and forgetting effects, despite their potential to reduce significantly project duration and cost, both during the construction phase and in preparing bid plans.

Hassan et al. [39] devised an innovative multi-objective stochastic scheduling optimization framework suitable for both sequential and non-sequential repetitive construction endeavors. This model can effectively pinpoint optimal crew configurations and deployment dates for each task, aiming to minimize both project duration and cost. Additionally, few studies considered the soft logic between different units. Zou and Rong [40] considers the soft logic relations among sub-activities and explores methods to enhance the objective while adhering to the constraints posed by resource availability.

In recent years, while the subject of scheduling in construction projects has been investigated, the studies have particularly focused on delay analysis. Researchers on that topic have conducted numerous studies, which is one of the primary areas of scientific study due to the effects of delays on time and cost in construction projects [41]. Çevikbaş and Işık provides a benchmarking tool to evaluate the merits of delay analysis methods to the practitioners [42]. Also a new delay analysis method is proposed that overcomes the disadvantages of existing delay analysis methods in order to minimize delay-related problems in construction projects [43].

This study puts forward an innovative multi-objective optimization model that takes into account key constraints and factors that influence the duration and cost of iterative projects, for example, the learning and forgetting effects and the flexible logic between varied activities. The unit remains the same, enabling restricted work disruption, various crew formations, and diverse construction methods for each activity, a limitless number of preceding and succeeding events, and the conventional relationship types. The objective of this approach is to reduce the project length, overall expenditure, and interruption time all at once.

3. Methodology

To improve the optimization of repetitive scheduling, this study proposes a model that takes into account simultaneous constraints and satisfies several multi-objectives at once. The methodology for the research is divided into two stages. Firstly, an in-depth literature review was conducted in order to ascertain the limitations of prior repetitive scheduling optimization models and to identify the key parameters that bear on project scheduling and can create a more realistic schedule. The next phase entails creating a metaheuristic multi-objective optimization model that factors in the aforementioned parameters collectively and allows multiple scheduling choices to define the best solutions, which reduce the project's overall duration, total cost, and total downtime.

The proposed model comprises three principal modules, 1) input module, 2) schedule and cost development module, 3) multi-objective optimization and ranking module. The model was developed employing Excel spreadsheets. The developed model has numerous features, such as:

- For each undertaking, a multitude of team structures can be appointed, with limitations set by the user as major and minor benchmarks.
- Each task can have up to ten distinct construction methods. Each of the construction methods may introduce varying technologies, building materials, machinery, employee crews, and strategies to accomplish the work.
- The duration of activities in each unit is calculated taking into account the learning effect.
- Users are allowed to interrupt any selected activity between units. The duration of interrupted activities will be calculated taking into account the forgetting effect.
- Each activity may have any number of predecessor and successor relationships.
- The relationships between activities can be finish-to-start (FS), finish-to-finish (FF), start-to-start (SS), or start-to-finish (SF) with or without delays.
- The user can repeat activities for all units or a specific range of units.
- The activities can be scheduled in parallel, shifted or optimized modes. The optimized mode can combine parallel and shifted crews to minimize the project duration. In the parallel mode, all crews for the same activity are scheduled to begin at the same time. In the shifted mode, the start of each activity is shifted from the others, with multiple crews not starting the activity at the same time.
- The project cost is determined by accounting for the direct cost, indirect cost, liquidated damages caused by delays, and fees for incentives for early completion.
- The model allows for multi-mode use, optimizing duration, cost, and interruption simultaneously, or single-mode use, optimizing each objective individually.
- This model is suitable for repetitive projects with typical durations, such as housing compounds, roads, and piping projects.

3.1. Input Module

The aim of this module is to gather all necessary data for the development and optimization of project schedule and cost. It is categorized into three major input groups.

The first group is project input which comprising of;

- activity count and unit count,
- project completion deadline,
- liquidated damages per day and maximum liquidated damages,
- daily early completion incentives and maximum early completion incentives,
- daily indirect costs.

The second group is activities' input for schedule development consists of;

- the available construction methods for each activity,
- the initial duration of each activity for each available construction method,
- all of the activity's precedence relationships, which can be one of the following four types: SF, SS, FF, FS.
- the minimum number and maximum number of crews that can be assigned,

- the learning effect for each activity,
- the allowance for interruption,
- the maximum interruption duration if allowed,
- the forgetting duration due to interruption if allowed,
- the soft logic options between activities,
- available construction methods for each activity,
- crews scheduling options (work in parallel, in a shifted arrangement, or in an optimized arrangement), and
- the range of units for each activity to be executed.

The last group is input for cost development of the activities includes;

- the cost of materials per unit for each method,
- the cost of labor per day for each method,
- the cost of equipment per day for each method, and
- the cost of any subcontractors per unit for each method.

The aforementioned input items consist of information about the project to be analysed and the decision maker's preferences. Therefore, the inputs must be provided by the decision maker.

3.2. Schedule and Cost Development Module

The aim of this module is to compute the commencement, conclusion, and direct expenditure of every operation in each unit. It then proceeds to ascertain the overall project length, entire expenditure, and total pause time for every cycle employing heuristic regulations.

The subsequent stages explicate how to conduct the schedule and expenditure estimations:

1. Determine the average rate (R) of any activity (i) through Eq. (1),

$$R_i = \frac{c_i}{DI_i - DL_i * (\frac{U}{c_i} - 1)} \quad (1)$$

Where activity (i) has c_i crews, an initial duration of DI_i and a learning duration of DL_i , and there are U total units. The average rate combines the traditional activity rate with its learning rate.

2. The starting point (S) for an activity (i) in unit (l) can be determined by following these steps:

- For the initial activity in the first unit, the starting point is presumed to be: $S_{11} = I$
- If an activity (i) has preceding activities, then for each of these preceding activities:

If $R_i < R_{(i-1)}$, then:

for FS relationship: $S_{il} = F_{(i-1)l} + I$

for SS relationship: $S_{il} = S_{(i-1)l}$

for FF relationship: $S_{il} = F_{(i-1)l} - DI_{(i)} + I$

for SF relationship: $S_{il} = S_{(i-1)l} - DI_{(i)}$

If $R_i > R_{(i-1)}$, then:

for FS relationship: $S_{il} = F_{(i-1)u} - (\sum DI_i + \sum DL_i) + I$

for SS relationship: $S_{iI} = S_{(i-1)u} - (\Sigma DI_i + \Sigma DL_i)$

for FF relationship: $S_{iI} = F_{(i-1)u} - (\Sigma DI_i + \Sigma DL_i) - DI_{(i)} + I$

for SF relationship: $S_{iI} = S_{(i-1)u} - (\Sigma DI_i + \Sigma DL_i) - DI_{(i)}$

Where $F_{(i-1)I}$ represents the finish of the preceding activity of i in unit I , $F_{(i-1)u}$ depicts the end of the previous activity of i in the final unit U , and ΣDI_i and ΣDL_i indicate the total initial duration and learning duration of activity i respectively. The sums of DI_i and DL_i are contingent on the quantity of units and crews designated to activity i .

3. The initiation and completion of activity (i) within unit (j) and their respective expenditures are determined according to the illustration presented in Figure 1.

If interruptions are not allowed, the term $DINT_i$, which represents the duration of interruptions for activity i , will be removed from all equations.

The Conflict (CF) value guarantees that there is no overlap or unnecessary delay between two activities within the same unit. The variance can be determined by computing the duration between the start of activity i and the completion of its preceding activities within the same unit.

4. The duration of learning can be calculated using one of the following ways:

- Linear assumption by the user, for example: 5% of the initial duration.
- The linear model, expressed as Eq. (2) and Eq. (3), was developed by Thomas et al. [44].

$$Y_i = Y_1 * (i)^s \quad (2)$$

$$s = \log(LR) / \log(2) \quad (3)$$

Where Y_i represents the duration of unit (i), s denotes the learning curve slope calculated by using Eq. (3), Y_1 is the initial duration of the first unit, and LR is the learning rate expressed as a percentage.

5. The total cost of the project is determined using Eq. (4).

$$TC = \sum_1^n DC_i + IC * DP + LD * DD + IN * DE \quad (4)$$

As given in Eq. (4), where $\sum_1^n DC_i$ represents the sum of direct costs for all activities, IC denotes the indirect cost per day, DP specifies the project duration, LD represents the late delivery cost per day, and DD is the duration of delay beyond the due date. DP is the project duration, LD is the liquidated damages per day, DD is the delayed duration, IN is the incentive fees per day, and DE is the early completion duration.

6. If interruption is permitted, the subsequent regulations must be adhered to. Interruption is not allowed for the first or last activities since it will not benefit the project schedule. Interruption should only be applied when the current activity has a higher rate than its predecessor and successor activities, as this is the sole situation in which allowing interruption will reduce the overall project duration. For an activity, the interruption duration to be used should be the minimum of the following: the maximum interruption duration set by the user.

The interruption duration for an activity within a unit should be at a minimum to ensure that it follows the previous activity without any positive or negative delay. The duration of interruption resulting in an average rate of the interrupted activity being equivalent to that of the succeeding activity should also be considered.

The initial point (S) at which activity (i) begins in unit (I) is determined by the following formula:

for FS relationship: $S_{il} = F_{(i-1)u} - (\sum DI_i + \sum DINT_i + \sum DL_i) + 1$

for SS relationship: $S_{il} = S_{(i-1)u} - (\sum DI_i + \sum DINT_i + \sum DL_i)$

for FF relationship: $S_{il} = F_{(i-1)u} - (\sum DI_i + \sum DINT_i + \sum DL_i) - DI_{(i)} + 1$

for SF relationship: $S_{il} = S_{(i-1)u} - (\sum DI_i + \sum DINT_i + \sum DL_i) - DI_{(i)}$

The duration of forgetting should be included in the activity duration. Additionally, the average rate of interrupted activity should be recalculated to take into account the interruption duration, as demonstrated in Eq. (5).

$$R_i = \frac{C_i}{DI_i + (DINT_i - DL_i) \left(\frac{U}{C_i} - 1 \right)} \tag{5}$$

7. If the optimal crew arrangement is chosen, the subsequent steps will be enforced.

- The first activity will be scheduled in parallel mode, then
- If $R_i > R_{(i-1)}$, activity (i) will be scheduled in shifted mode
- If $R_i < R_{(i-1)}$, activity (i) will be scheduled in parallel mode

Additionally, optimized crew arrangement will minimize the project duration. It produces schedules with less durations and costs without any additional resources.

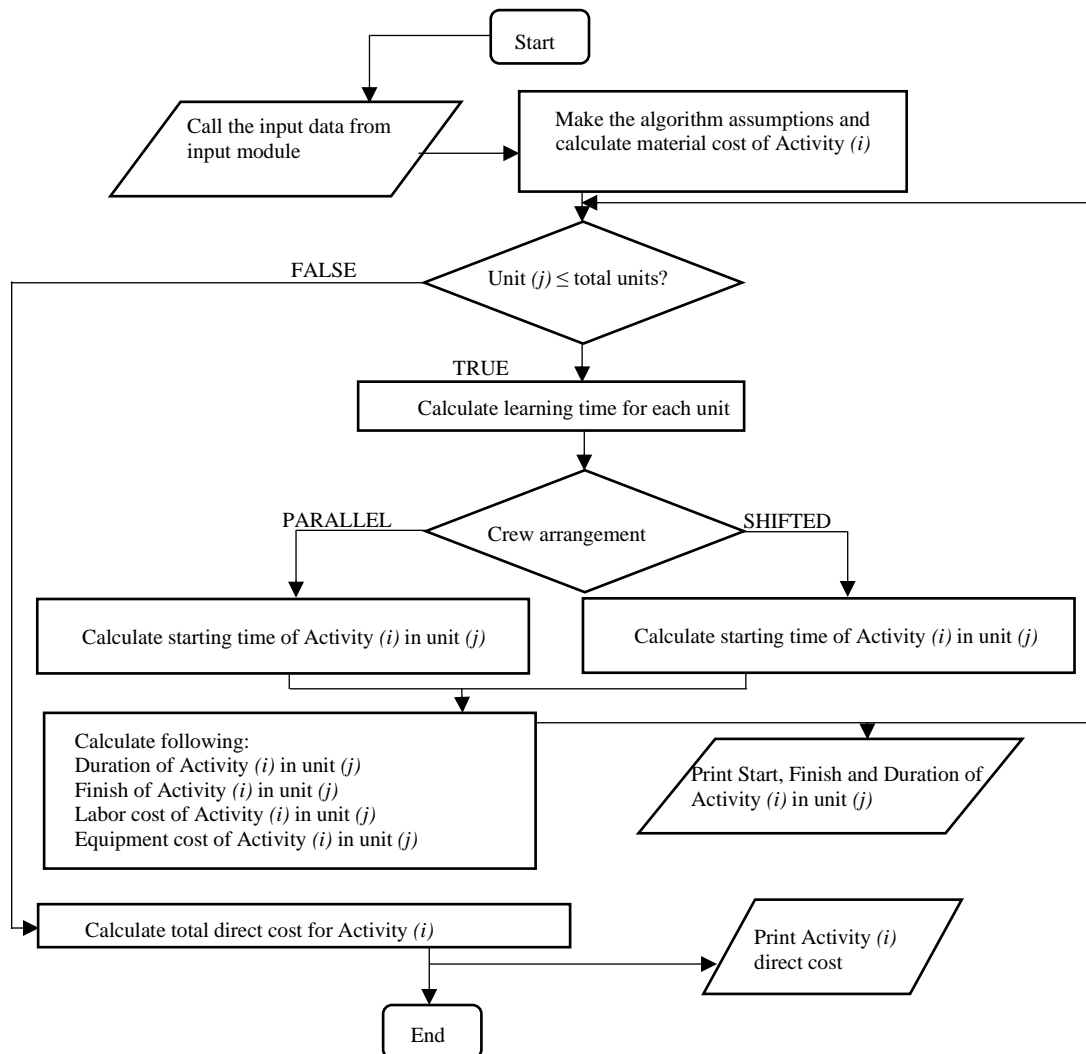


Figure 1. Flowchart of the schedule and cost development module

3.3. Optimization and Ranking Module

The aim of this module is to create a multi-objective optimization system that determines the best combination of crew formations for activities, construction methods, interruption durations, and soft logic to minimize project time, cost, and work interruption simultaneously, employing metaheuristic rules. In multi-objective optimization, no single solution can satisfy all objectives at once. Instead, the focus is on Pareto optimality to generate non-dominated Pareto optimal solutions. However, the proposed model is designed to conduct optimization in the following modes to help the users in making trade-offs between different solutions based on their preferences: single mode for optimizing time of the project, single mode for optimizing total project cost, multi-mode for optimizing the combined impact of duration, cost, and interruption, and multi-mode for identifying Pareto frontiers.

3.4. Decision Variables

The model takes into account various decision variables that impact both project duration and cost. These variables include:

- The number of crews assigned to an activity, which will be constrained within minimum and maximum limits to reflect available resources for each activity. However, increasing the number of crews will raise the activity's cost and diminish learning benefits.
- Construction method, encompassing different technologies, materials, equipment, labor crew configurations, and methods employed to execute the activity.
- Allowance for work interruptions, which can be implemented in specific activities to decrease project duration.
- Soft logic between activities, representing different options for job sequencing logic within the activity sequence.

3.5. Objective Functions

The model is designed to minimize project duration, overall cost, and interruption durations. It integrates several objective functions, which vary depending on the optimization mode, as depicted in Eqs. (6-9).

$$\text{Minimize total project time} = DP \quad (6)$$

$$\text{Minimize total project cost} = TC = \sum_1^n DC + IC * DP + LD * DD + IN * DE \quad (7)$$

$$\text{Minimize total interruption time} = \sum_1^n DINT \quad (8)$$

The collective influence of duration, cost, and interruption can be assessed through the weighted sum approach [45]. This method transforms the multi-objective optimization challenge into a single objective optimization by consolidating all objectives into a single function, enabling the calculation of the Combined Impact Factor (CIF) as outlined in Eq. 9. To standardize each objective function, project duration, total project cost, and interruption time are divided by predetermined constant values specified by the user. Subsequently, each normalized optimization objective is multiplied by a weighting factor, indicating the relative significance of that particular objective.

$$CIF = \left(W_d * \frac{DP}{DP^*} \right) + \left(W_c * \frac{TC}{TC^*} \right) + \left(W_{dint} * \frac{DINT}{DINT^*} \right) \quad (9)$$

W_d represents the relative weighting factor for duration, W_c stands for the relative weighting factor for cost, and W_{dint} signifies the relative weighting factor for interruption time. DP^* denotes the suggested project time by the user (i.e., project deadline), TC^* represents the suggested project cost by the user (i.e., preliminary budget), and $DINT^*$ indicates the suggested total interruption time by the user.

4. Model Application

This module comprises two primary stages: Initially, it generates potential combinations of decision variables for all activities in each iteration through a permutation tree-based approach, ensuring the attainment of the optimal solution. All feasible iterations are created and cataloged in matrices, utilized in the computations of the schedule and cost development module subsequently. Upon the completion of each iteration, the outcomes, in conjunction with the input data, are stored in a repository provided they meet the user's requirements.

During the scheduling process, interruption duration will be computed, as outlined in Section 3.2, ensuring that the chosen interruption duration positively affects the project schedule. Subsequently, the module organizes all outcomes based on the chosen mode and objectives. In the case of a single mode, the results are ranked in descending order according to the selected objective.

4.1. Case Study 1

To validate the results obtained by the proposed model, the case study presented by Hegazy [46] as used. The project entails constructing a 3-kilometer highway that is divided into 10 sections, each with a length of 300 meters. The project deadline is tight, and the contractor opted to work from both the east and west to prevent resource congestion.

The project incurs a daily indirect cost of \$300, with a liquidated damage set at \$100000/day and an early completion incentive of \$20000/day. Table 1 refers for all necessary data on the relevant project activities.

Table 1. The information for case study

Activity	Location	Section	Pred.	Quantity	Max. no. of crews	Mode 1		Mode 2		Mode 3	
						Cost (\$)	Dur. (day)	Cost (\$)	Dur. (day)	Cost (\$)	Dur. (day)
1. Excavation	East	1-5	-	2100 m ³	2	21000	3	30000	2	-	-
2. Subbase	East	1-5	1	600 m ²	2	7800	2	-	-	-	-
3. Base	East	1-5	2	6000 m ²	3	72000	10	80000	8	100000	5
4. Binder	East	1-5	3	6000 m ²	1	30000	1.2	-	-	-	-
5. Asphalt	East	1-5	4	3600 m ²	1	14400	1	-	-	-	-
6. Curbs	East	1-5	3	600 m	1	31200	2	38000	1	-	-
7. Lightning	East	1-5	6	7 Poles	2	19245	2	25000	1	-	-
8. Sidewalks	East	1-5	7	300 m	2	10950	2	-	-	-	-
9. Paint	East to West	1-10	8 and 17	300 m	1	198	0.2	-	-	-	-
10-17. Same as 1-8 but at West	West	10-6	Same as Activities 1-8								

4.2. Results and Discussion for Case 1

The problem was solved using the proposed model with the same inputs and options as [46]. Interruption was not allowed, learning effect was not utilized, and scheduling was done in parallel mode.

Table 2 presents the comparison between Hegazy [46] and the proposed model’s results for a single objective function to minimize cost. The study determined that both models produced schedules with similar costs and durations. However, the proposed model utilized fewer crews while maintaining the same construction method. Furthermore, the proposed model yielded superior and more precise optimum solutions, particularly when leveraging the learning effect and calculating costs based on daily labor expenses.

Table 2. The comparison of results for Case 1

Point of comparison	Hegazy [46]	The proposed model
Optimal set of crew combination $c_i = \{c_1, c_2, \dots, c_n\}$	{2,1,3,1,1,1,2,2,1,2,1,1,1,1,1}	{2,1,2,1,1,1,1,1,2,1,2,1,1,1,1}
Total no. of crews	24	21
Optimal set of construction methods combination $cm_i = \{cm_1, cm_2, \dots, cm_n\}$	{1,1,3,1,1,1,1,1,1,1,3,1,1,1,1}	{1,1,3,1,1,1,1,1,1,1,3,1,1,1,1}
Optimal project duration	29.2 days	29.2 days
Optimal project total cost	\$2419530	\$2419530

Another scenario was analyzed to consider the optimized mode of crew’s arrangement instead of scheduling all crews in parallel or in the shifted mode, while maintaining all other options constant. The analysis resulted in a superior solution with a minimum cost of \$2359730 and a duration of 26.6 days. When the project duration decreased by 8.90%, the total cost also decreased by 2.47%. Table 3 shows the minimum cost solution obtained.

Table 3. The optimum results for minimum cost with optimized crew arrangement

No	Set of crew combination $c_i = \{c_1, c_2, \dots, c_n\}$	Set of construction methods combination $cm_i = \{cm_1, cm_2, \dots, cm_n\}$	Selected crew arrangement	Project dur. (day)	Total cost (\$)
1	{2,1,3,1,1,1,1,1,2,1,3,1,1,1,1}	{1,1,3,1,1,1,1,1,1,1,3,1,1,1,1}	{p,p,s,s,s,p,p,p,s,p,p,s,s,s,p,p,p}	26.6	2359730

Each activity will be examined to illustrate the additional benefits and capabilities of the proposed model. Two more scenarios will be explored, using the same options as [46], to generate solutions for (1) minimum duration and (2) minimum combined impact of duration and cost. The results obtained from the proposed model for minimum duration can be found in Table 4, while Table 5 displays the four best solutions for minimum combined impact of both duration and cost.

Table 4. The optimum schedule for minimum duration

No	Set of crew combination $c_i = \{c_1, c_2, \dots, c_n\}$	Set of construction methods combination $cm_i = \{cm_1, cm_2, \dots, cm_n\}$	Project dur. (day)	Total cost (\$)
1	{2,2,3,1,1,1,1,2,1,2,2,3,1,1,2,2}	{2,1,3,1,1,2,2,1,1,2,1,3,1,1,2,2,1}	23.2	2497080

Table 5. The optimum schedules for minimum combined impact of both duration and cost

No	Set of crew combination $c_i = \{c_1, c_2, \dots, c_n\}$	Set of construction methods combination $cm_i = \{cm_1, cm_2, \dots, cm_n\}$	Project dur. (day)	Total cost (\$)	CIF
1	{2,2,3,1,1,1,2,2,1,2,2,3,1,1,1,2,2}	{2,1,3,1,1,2,1,1,1,2,1,3,1,1,2,1,1}	24.2	2462530	96,542%
2	{2,2,3,1,1,1,1,2,1,2,2,3,1,1,1,1,2}	{2,1,3,2,1,1,2,1,1,2,1,3,1,1,2,2,1}	23.2	2497080	97,004%
3	{2,2,2,1,1,1,1,1,1,2,2,2,1,1,1,1,1}	{2,1,3,1,1,1,1,1,1,2,1,3,1,1,1,1,1}	26.2	2440530	97,157%
4	{2,2,3,1,1,1,1,2,1,2,2,3,1,1,1,2,2}	{2,1,3,2,1,1,2,1,1,2,1,3,1,1,2,1,1}	24	2486705	97,199%

The CIF for each solution is calculated using the following data: weighting factors have been assigned to duration, cost, and interruption duration at 20%, 80%, and 0%, respectively. DP^* stands at 30 days, while TC^* is set at \$2450000.

4.3. Case Study 2

The second case study presents as an illustrative example, employing various options to highlight the comprehensive capabilities of the proposed model and underscore the significance of diverse parameters in the analysis. This case study centers on a project encompassing the construction of eight villas. The scope of work for each villa involves executing internal finishes, commencing from block works and culminating in final additions. The project is bound by a strict deadline of 65 days. Indirect costs incurred by the project amount to \$1000 per day, while liquidated damages are set at \$2000 per day, with a maximum cap of \$50000. Notably, the project does not offer any early completion incentive fees. Learning duration is estimated at 8% of the original duration for every crew involved in the activities. Additionally, a forgetting duration of 4% from the original duration is assumed for activities interrupted during execution. Table 6 comprehensively outlines all necessary data related to the project's activities, considering two proposed scenarios for soft logic. It is important to note that all relationships between activities are assumed Finish-to-Start (FS) with no lags or leads, providing a standardized framework for analysis and comparison.

Table 6. The information for Case Study 2

Activity	Soft Logic (1)	Soft Logic (2)	Max. no. of crews	Interruption (days)	Construction Method 1			Construction Method 2		
	Pred. Act.	Pred. Act.			Labor Cost(\$)/day	Mat. Cost (\$)/unit	Dur. (days)	Labor Cost(\$)/day	Mat. Cost (\$)/unit	Dur. (days)
1. Blockworks	-	-	3	-	1875	16000	6	500	16000	5
2. Plastering dots	1	1	2	5	1950	4000	3	-	-	-
3. Electrical conduits	2	2	2	-	1425	7000	5	600	7000	4
4. Plastering fill	3	3	2	-	1950	10000	5	-	-	-
5. Wiring pulling	4	4	2	-	1500	11000	4	500	11000	2
6. Marble flooring	5	7	3	-	1350	12000	6	-	-	-
7. Painting 1st coat	6	5	2	-	1650	8000	5	-	-	-
8. Doors installation	7	6	2	5	1800	9000	2	700	9000	1
9. Painting final coat	8	8	2	-	1650	5000	3	-	-	-
10. Electrical final fix	9	9	2	-	1800	11000	2	-	-	-

4.4. Results and Discussion for Case Study 2

Initially, the case study was approached in a single-mode analysis to discern optimal solutions for individual objective functions. Table 7 presents the optimal crew numbers, construction methods, soft logic, interruption allowances, and resultant durations, costs, and interruption durations for each objective. To calculate the Combined Impact Factor (CIF) and minimize the collective effects of duration, cost, and interruption duration, relative weighting factors were applied: 30% for duration, 65% for cost, and 5% for interruption duration. Key parameters included DP^* (65 days), TC^* (\$1250000), and $DINT^*$ (10 days).

Table 7. The optimum results for Case Study 2

#	Set of crew combination $c_i = \{c_1, c_2, \dots, c_n\}$	Set of construction methods combination $cm_i = \{cm_1, cm_2, \dots, cm_n\}$	Interruption allowance	Selecte d soft logic	Proj. dur. (day)	Total cost (\$)	Interruption dur. (day)	CIF
Objective 1: Minimizing duration								
1	{3,2,2,2,2,2,2,2,2,2}	{2,1,2,1,1,1,1,2,1,1}	{0,1,0,0,0,0,0,1,0,0}	1	53	1310464	8.52	N/A
Objective 2: Minimizing cost								
1	{2,1,1,1,1,1,1,1,1,1}	{1,1,1,1,1,1,1,1,1,1}	{0,0,0,0,0,0,0,1,0,0}	1	66.64	1226768	4.2	N/A
Objective 3: Minimizing combined impact of duration, cost and interruption duration								
1	{2,1,1,1,1,2,2,1,2,2}	{2,1,1,1,1,1,1,1,1,1}	{0,0,0,0,0,0,0,0,0,0}	1	60.04	1255768	0	93.01
2	{3,1,1,1,1,2,2,1,2,2}	{2,1,1,1,1,1,1,1,1,1}	{0,0,0,0,0,0,0,0,0,0}	1	60.04	1258168	0	93.14
3	{2,1,1,1,1,2,2,1,2,2}	{2,1,2,1,1,1,1,1,1,1}	{0,0,0,0,0,0,0,0,0,0}	1	59.04	1267392	0	93.15
4	{3,1,1,1,1,2,2,1,2,2}	{1,1,1,1,1,1,1,1,1,1}	{0,0,0,0,0,0,0,0,0,0}	1	61.04	1250228	0	93.18
5	{3,1,1,1,1,2,2,1,2,2}	{2,1,2,1,1,1,1,1,1,1}	{0,0,0,0,0,0,0,0,0,0}	1	59.04	1269792	0	93.28

To underscore the significance of integrating learning and forgetting effects in the optimization process, the case study was revisited under identical original conditions but without considering these effects. The results presented in Table 8 mention the substantial impact of integrating learning and forgetting effects. Specifically, incorporating these effects reduced the project duration by 10.16% (from 59 days to 53 days) and lowered project costs by 9.96% (from \$1362400 to \$1226768). Notably, applying the learning effect led to a smaller number of crews when minimizing project costs, fostering further learning development due to increased repetitions.

Table 8. The optimum results without learning and forgetting effects

#	Set of crew combination $c_i = \{c_1, c_2, \dots, c_n\}$	Set of construction methods combination $cm_i = \{cm_1, cm_2, \dots, cm_n\}$	Interruption allowance	Selecte d soft logic	Proj. dur. (day)	Total cost (\$)	Interruption dur. (day)	CIF
Objective 1: Minimizing duration								
1	{2,2,2,2,1,2,3,2,2,2}	{2,1,1,1,2,1,1,2,1,1}	{0,1,0,0,0,0,0,1,0,0}	2	59	1362400	12	N/A
Objective 2: Minimizing cost								
1	{3,2,2,2,2,2,3,2,2,2}	{1,1,1,1,1,1,1,1,1,1}	{0,1,0,0,0,0,0,1,0,0}	2	62	1353800	12	N/A

Furthermore, the study investigated the benefits of allowing work interruption in specific activities during repetitive project optimization. Table 9 displays the outcomes of the analysis conducted under the condition of disallowing work interruption in any activity. Integrating work interruption resulted in 5.02% reduction in project duration (from 55.8 days to 53 days) and 8.93% decrease in project costs (from \$1239200 to \$1226768). These findings underscore the positive impact of judiciously applying work interruption strategies in enhancing project efficiency and reducing costs.

Table 9. The optimum results without interruption

#	Set of crew combination $c_i = \{c_1, c_2, \dots, c_n\}$	Set of construction methods combination $cm_i = \{cm_1, cm_2, \dots, cm_n\}$	Interrupti on allowance	Selecte d soft logic	Proj. dur. (day)	Total cost (\$)	Interru ption dur. (day)	CIF
Objective 1: Minimizing duration								
1	{3,2,2,2,2,2,2,1,2,2}	{2,1,2,1,1,1,1,2,1,1}	{0,0,0,0,0,0,0,0,0,0}	1	55.8	1299192	0	N/A
Objective 2: Minimizing cost								
1	{2,1,1,1,1,1,1,1,2,2}	{1,1,1,1,1,1,1,1,1,1}	{0,0,0,0,0,0,0,0,0,0}	1	68.84	1239200	0	N/A

5. Conclusions

Creating a feasible, effective, and optimal timetable for repetitive projects stands as a crucial challenge for the project success. This study embarked on a meticulous exploration of pertinent literature to identify pivotal factors influencing scheduling in the repetitive projects. Subsequently, an innovative heuristic multi-objective optimization model was devised to concurrently minimize the project duration, cost, and interruption duration. This research enriches the body of knowledge on repetitive project scheduling in the following ways:

Literature Review Enhancement: By furnishing a comprehensive review of literature pertaining to optimization in repetitive project scheduling, this research equips scholars with a reliable foundation to discern key considerations and limitations prevalent in earlier studies.

Innovative Optimization Model: The development of a novel optimization model is a significant contribution, as it accommodates factors like learning and forgetting effects, soft logic between activities, seamless crew work continuity, integration of work interruption in specific activities, diverse crew formations, and multiple construction methods for each activity. The model also encompasses all Critical Path Method (CPM) scheduling capabilities and takes into account various construction costs such as direct, indirect, delay damages, and early completion incentive fees.

Metaheuristic Optimization Method: This research introduces an effective metaheuristic approach to schedule and optimize repetitive projects. The model's versatility enables simultaneous minimization of duration, cost, and interruption duration in multi-mode. Additionally, it can operate in single mode, optimizing one objective function at a time, thereby enhancing flexibility for project planners.

Impactful Factors: Integration of learning and forgetting effects in repetitive scheduling significantly reduces project duration.

Soft Logic Consideration: Incorporating soft logic into the model enhances its value, leading to shorter project durations without incurring additional costs. Optimal selection of soft logic between activities is pivotal in achieving this outcome.

To sum up, the main contribution of the study is the integration of learning effects, soft logic and work interruption allowances into the optimization process, significantly reducing project time and cost, thus enabling more accurate and reliable optimum solutions.

Additionally, the developed model was validated using a previous case study, demonstrating its superior accuracy. The model's distinctive features ensure its practicality in optimizing real construction repetitive projects. This research holds significant implications for both industry practitioners and scholars, providing effective solutions for multi-constraint, multi-objective repetitive scheduling challenges. Moreover, it serves as a springboard for future researchers, encouraging exploration of non-typical durations in activities, considering resource transfer time, and cost between different units for further optimization endeavors.

Conflict of Interest

The authors declare that they have no conflict of interest.

References

- [1] Monghasemi S, Abdallah M. Linear optimization model to minimize total cost of repetitive construction projects and identify order of units. *Journal of Management in Engineering ASCE* 2021; 37(4).
- [2] Zou X, Zhang L. A constraint programming approach for scheduling repetitive projects with atypical activities considering soft logic. *Automation in Construction* 2020; 109.
- [3] Arditi D, Tokdemir O, Suh K. Challenges in line-of-balance scheduling. *Journal of Construction Engineering and Management* 2002; 128(6): 545-556.
- [4] Johnston DW. Linear scheduling method for highway construction. *Journal of the Construction Division ASCE* 1981; 107(2): 247-261.
- [5] Arditi D, Albulak M. Line-of-balance scheduling in pavement construction. *Journal of Construction Engineering and Management ASCE* 1986; 112(3): 411-424.
- [6] Okudan O, Çevikbaş M, Işık Z. An exploratory study on the critical features of construction project planning software. *Sigma Journal of Engineering and Natural Sciences* 2023; 41(4): 781-792.
- [7] Zhang L, Zou X. Chapter 6 - Resource-constrained scheduling in repetitive construction projects. *Repetitive Project Scheduling: Theory and Methods*, Elsevier 2015; 71-85.
- [8] Zou X, Zhang L, Zhang Q. A biobjective optimization model for deadline satisfaction in line-of-balance scheduling with work interruptions consideration. *Mathematical Problems in Engineering* 2018; Article ID 6534021.
- [9] Fan S, Sun K, Wang Y. GA optimization model for repetitive projects with soft logic. *Automation in Construction* 2012; 21: 253-261.
- [10] Tamimi S, Diekmann J. Soft logic in network analysis. *Journal of Computing in Civil Engineering* 1988; 2(3): 289-300.
- [11] Huang R, Sun K. A GA optimization model for workgroup-based repetitive scheduling (WoRSM). *Advances in Engineering Software* 2009; 40:3, 212-228.
- [12] Moselhi O, Hassanein A. Optimized scheduling of linear projects. *Journal of Construction Engineering and Management ASCE* 2003; 129(6): 664-673.
- [13] García-Nieves JD, Ponz-Tienda JL, Ospina-Alvarado A, Bonilla-Palacios M. Multipurpose linear programming optimization model for repetitive activities scheduling in construction project. *Automation in Construction* 2019; 105.
- [14] Altuwaim A, El-Rayes K. Optimizing the scheduling of repetitive construction to minimize interruption cost. *Journal of Construction Engineering and Management* 2018; 144(7).
- [15] Heravi G, Moridi S. Resource-constrained time-cost tradeoff for repetitive construction projects. *KSCE Journal of Civil Engineering* 2019; 23(8): 3265-3274.

- [16] Bakry I. Optimized scheduling of repetitive construction projects under uncertainty. PhD thesis, Department of Building, Civil and Environmental Engineering, Concordia University, Montreal 2014.
- [17] Reda R. RPM repetitive project modelling. *Journal of Construction Engineering and Management ASCE* 1990; 116(2): 316-330.
- [18] Moselhi O, El-Rayes K. Scheduling of repetitive projects with cost optimization. *Journal of Construction Engineering and Management ASCE* 1993; 119(4): 681-697.
- [19] Senouci A, Eldin N. Dynamic programming approach to scheduling of nonserial linear project. *Journal of Computing in Civil Engineering* 1996; 10(2): 106-114.
- [20] Hegazy T, Wassef N. Cost optimization in projects with repetitive nonserial activities. *Journal of Construction Engineering and Management ASCE* 2001; 127(3): 183-191.
- [21] Elbeltagi E, Elkassas E, Abdel Rasheed I, Al-Tawil S. Scheduling and cost optimization of repetitive projects using genetic algorithms. *ICCTA Alexandria Egypt* 2007.
- [22] El-Rayes K, Moselhi O. Optimizing resource utilization for repetitive construction projects. *Journal of Construction Engineering and Management ASCE* 2001; 127(1): 18-27.
- [23] Hyari K, El-Rayes K. Optimal planning and scheduling for repetitive construction projects. *Journal of Management in Engineering ASCE* 2006; 22(1): 11-19.
- [24] Ipsilandis P. Multiobjective linear programming model for scheduling linear repetitive projects. *Journal of Construction Engineering and Management ASCE* 2007; 133(6): 417-424.
- [25] Liu S, Wang C. Optimizing linear project scheduling with multi-skilled crews. *Automation in Construction* 2012; 24: 16-23.
- [26] El-Rayes K. Object-oriented model for repetitive construction scheduling. *Journal of Construction Engineering and Management ASCE* 2001; 127(3): 199-205.
- [27] Zhang H, Li H, Tam CM. Heuristic scheduling of resource-constrained, multiple-mode and repetitive projects. *Construction Management and Economics* 2016; 24(2): 159-169.
- [28] Senouci A, Al-Derham H. Genetic algorithm-based multi-objective model for scheduling of linear construction projects. *Advances in Engineering Software* 2008; 39(12): 1023-1028.
- [29] Long L, Ohsato A. A genetic algorithm-based method for scheduling repetitive construction projects. *Automation in Construction* 2009; 18(4): 499-511.
- [30] Hyari K, El-Rayes K, El-Mashaleh M. Automated trade-off between time and cost in planning repetitive construction projects. *Construction Management and Economics* 2009; 27(8): 749-761.
- [31] Eid M, Abdelrazek M, Elbeltagi E. Multi-objective repetitive activities projects scheduling using Genetic Algorithms. *CRC Press Boca Raton FL* 2012; 331-335.
- [32] Kaveh A, Farivar R, Sajjad M. Many-objective optimization for construction project scheduling using non-dominated sorting differential evolution algorithm based on reference points. *Scientia Iranica*, 2021; 28(6): 3112-3128.
- [33] Bettemir ÖH, Yücel T. Simplified solution of time-cost trade-off problem for building constructions by linear scheduling. *Jordan Journal of Civil Engineering* 2023; 17(2).
- [34] Bakry I, Moselhi O, Zayed T. Optimized scheduling and buffering of repetitive construction projects under uncertainty. *Engineering, Construction and Architectural Management* 2016; 23(6): 782-800.
- [35] Salama T, Moselhi O. Multi-objective optimization for repetitive scheduling under uncertainty. *Engineering, Construction and Architectural Management* 2019; 27(7): 1294-1320.
- [36] Huang R, Halpin D. Graphically based LP modelling for linear scheduling analysis: the POLO system. *Engineering, Construction and Architectural Management* 2000; 7(1): 41-51.
- [37] Srisuwanrat C, Ioannou P. Optimal scheduling of probabilistic repetitive projects using completed unit and genetic algorithms. *Winter Simulation Conference Washington DC* 2007; 2151-2158.
- [38] Bragadin M, Kahkonen K. Heuristic solution for resource scheduling for repetitive construction projects. *Management and Innovation for a Sustainable Built Environment Amsterdam The Netherlands* 2011.
- [39] Hassan A, El-Rayes K, Attalla M. Stochastic scheduling optimization of repetitive construction projects to minimize project duration and cost. *International Journal of Construction Management* 2023; 23(9): 1447-1456.

- [40] Zou X, Rong Z. Resource-constrained repetitive project scheduling with soft logic. *Engineering, Construction and Architectural Management* 2024 (ahead-of-print).
- [41] Çevikbaş M, Işık Z. Overarching review on delay analyses in construction projects. *Buildings* 2021; 11(3): 109.
- [42] Çevikbaş M, Işık Z. Detecting the most appropriate delay analysis methods for mega airport projects. *Engineering, Construction and Architectural Management* 2023; 30(6): 2463-2480.
- [43] Çevikbaş M, Okudan O, Işık Z. New delay-analysis method using modified schedule and modified updated schedule for construction projects. *Journal of Construction Engineering and Management* 2022; 148(11): 1-18.
- [44] Thomas H, Mathews C, Ward J. Learning curve models of construction productivity. *Journal of Construction Engineering and Management ASCE* 1986; 112(2): 245-258.
- [45] Agrama FA. Multi-objective genetic optimization for scheduling a multi-storey building. *Automation in Construction* 2014; 44: 119-128.
- [46] Hegazy T. Computerized system for efficient scheduling of highway construction. *Transportation Research Record: Journal of the Transportation Research Board*, No. 1907, Transportation Research Board of the National Academies, Washington DC 2005; 8-14.

TOPLAM HARMONİK BOZULMA SEVİYESİNİN REAKTİF GÜÇ KOMPANZASYONUNA BAĞLI DEĞİŞİMİ

Faruk KÜRKER^{1*}

¹Adiyaman Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Adiyaman, 02040, Türkiye
Geliş Tarihi/Received Date: 29.09.2024 Kabul Tarihi/Accepted Date: 31.10.2024 DOI:10.54365/adyumbd.1558116

ÖZET

Yapılan çalışmada, sulama sistemleri ve ambalaj malzemesi üreten tesiste, üç fazda reaktif güç kompanzasyonu devre dışı (OFF) ve devrede (ON) iken aktif güç (P), görünür güç (S), reaktif güç (Q), yerdeğiştirme güç faktörü (dPF), harmonikli güç faktörü (PF) ve akım için % toplam harmonik bozulma (%THD_I) değerleri incelenmiştir. Harmoniklerin mevcut olduğu sistemlerde reaktif güç kompanzasyonu OFF ve ON iken güç analizörü ile ölçüm yapılarak reaktif güç kompanzasyonunun toplam harmonik bozulmaya etkisi analiz edilmiştir. Diğer bir ifade ile çalışma; ayrıntılı bir şekilde reaktif güç kompanzasyonunun %THD_I'ye nasıl etki ettiğine dair analizler yapılmıştır. Reaktif güç kompanzasyonu OFF ve ON durumunda PF ve dPF ile %THD_I değerleri grafiksel olarak incelenmiştir. Çalışmada, reaktif güç kompanzasyonu OFF durumunda iken ölçülen %THD_I değerinin, reaktif güç kompanzasyonu ON durumunda iken daha yüksek değerde olduğu tespit edilmiştir. Makaledeki sonuçlar, reaktif güç kompanzasyonunun %THD_I değerini minimum %7,180 fark ile %8,45'ten %15,63'e, maksimum ise %18,723 fark ile %7,64'den %26,36'e yükseltmiştir.

Anahtar Kelimeler: *Reaktif Güç Kompanzasyonu, Reaktif Güç (Q), Toplam Harmonik Bozulma (THD), Güç Faktörü (PF).*

VARIATION OF TOTAL HARMONIC DISTORTION LEVEL DEPENDING ON REACTIVE POWER COMPENSATION

ABSTRACT

In this study, active power (P), apparent power (S), reactive power (Q), displacement power factor (dPF), harmonic power factor (PF) and % total harmonic distortion for current (%THDI) values were analysed in a plant producing irrigation systems and packaging materials when reactive power compensation was OFF and ON in three phases. In systems where harmonics are present, the effect of reactive power compensation on total harmonic distortion is analysed by measuring with three analysers when reactive power compensation is OFF and ON. In other words, the study analyses in detail how reactive power compensation affects %THDI. PF, dPF and %THDI values are analysed graphically in OFF and ON state of reactive power compensation. In the study, it was found that the %THDI value measured when the reactive power compensation is OFF is higher than when the reactive power compensation is ON. The results in the paper show that the %THDI value of reactive power compensation increased from 8.45% to 15.63% with a minimum difference of 7.180% and from 7.64% to 26.36% with a maximum difference of 18.723%.

Keywords: *Reactive Power Compensation, Reactive Power (Q), Total Harmonic Distortion (THD), Power Factor (PF).*

* e-posta¹ : fkurker@adiyaman.edu.tr ORCID ID: <https://orcid.org/0000-0003-1544-9743> (Sorumlu Yazar)

1. Giriş

Aktif güç elektrikle çalışan tüm cihazlarda aydınlatma, ısıtma ve hareket gibi işlevleri yapmak için kullanılır. Kilowatt (kW) olarak ifade edilir. Aktif gücün yanı sıra, transformatör, bobin ve motor gibi endüktif yüklerin de çalışması için gerekli olan manyetik bir alan temini için şebekeden reaktif güce ihtiyaç duyarlar. Herhangi bir iş yapmayan kilovolt-ampere-reaktif (kVAr) olarak adlandırılan reaktif gücün aktif güce bir faydası olmadığı gibi, hatları gereksiz yükler, hem ekstra gerilim düşümüne ve zarara neden olur hemde hattın taşıma kapasitesinin azalmasına neden olur. Görünür güç kilovolt-ampere (kVA) olarak ifade edilen, aktif ve reaktif güç ile birlikte şebekeden çekilen toplam gücü ifade eder [1-3].

Elektrik enerjisinin üretiminden tüketimine kadar geçen süreçte, elektrik sisteminin verimliliğinin önemli parametrelerinden biri güç faktörüdür. Güç faktörü, elektrik devresinde kullanılan aktif gücün, görünen güce oranıdır. Yüksek bir güç faktörü, elektrik enerjisinin daha verimli kullanıldığını, dolayısıyla daha az enerji kaybı olduğunu gösterir. Düşük bir güç faktöründe ise, elektrik enerjisi daha verimsiz kullanılır ve bu durum, elektrik hatlarındaki gerilimin düşmesine, enerji kayıplarını artmasına, hatların taşıma kapasitesinin azalmasına, elektrik faturalarının yükselmesine, elektrik ekipmanlarının ömrünün kısalmaya ve sistemde gereksiz ısınmalara neden olabilir. Güç faktörünü iyileştirmek için kullanılan en yaygın yöntemlerden biri, kapasitör bankalarıdır. Bu bankalar, sistemdeki endüktif yüklerin neden olduğu reaktif gücü telafi ederek güç faktörünü 1'e yaklaştırır [4-6].

Yeni nesil elektrik dağıtım sistemlerinde, doğrultucu ekipmanları, güç kaynakları, ayarlanabilir hız sürücüleri, ev aletleri vb. gibi doğrusal olmayan yük kullanımında önemli derecede artış olmuştur [7-8]. Alternatif akım (AC) şebekesinden nonsinüsoidal akımlar çeken doğrusal olmayan yükler, 'harmonikler' olarak adlandırılan akım ve gerilim bozulmasına sebep olmaktadır [9]. Harmonikler tüketici ürünlerinde ve güç sistemlerinde kondansatör sigortalarının atması, ekipmanların aşırı ısınması, bozulmuş gerilim dalga şekilleri, aşırı nötr akımları, düşük güç faktörü ve transformatörlerin aşırı ısınması gibi çeşitli sorunlara sebep olur [10-15].

Elektrik sistemindeki güç kalitesini artırmak için kullanılan güç faktörü düzeltme kondansatörleri, bazen istenmeyen bir durum olan rezonans adı verilen olayın oluşmasına neden olarak zararlı harmoniklerin artmasına yol açabilirler [16]. Reaktif güç kompanzasyonunda kullanılan kondansatörler, lineer devre elemanı olması sebebiyle harmonikli akım şebekeden çekmez. Fakat, nonlineer yükler nedeniyle harmonik gerilimlerin ve harmonikli akımların olduğu sistemde kondansatörler, harmoniklerden önemli oranda etkilenir.

Reaktif güç kompanzasyonu amacıyla kompanzasyon kondansatörünün uygulanmasının THD değerini arttırdığı gözlemlenmiştir. Harmonikler kirliliği sistemde zaten mevcut olduğundan, kondansatörlerin THD seviyesini arttırdığı ve yükselttiği düşünülebilir çünkü kondansatörler büyük frekanslarda çok düşük empedanslar sunar ancak güç faktörünü iyileştirebilir. Kondansatörün harmonik bozulmayı kendisinin başlatmadığını söylemek doğrudur, ancak toplam harmonik bozulma değerinde bir artışa neden olan bozulma seviyesini artırabilir ve geliştirebilirler.

Sinüsoidal olmayan bir sistemde, kapasitörler harmonik bozulmalardan etkilenir çünkü reaktansları akan akımın frekansına bağlıdır. Kapasitif reaktans, kondansatör empedansı denklem 1'deki ifade ile bulunmaktadır.

$$X_C = \frac{1}{2 \cdot \pi \cdot f \cdot C} \quad (1)$$

Burada; X_C kapasitif reaktans, f gözlenen harmonik akımın frekansı, C kapasitans. Denklemden de görüldüğü gibi, frekansın azalması ya da artması kondansatör empedansının artmasına veya azalmasına sebep olacaktır. 50 Hz şebeke frekansında 10 ohm olan kondansatör empedansı, 250 Hz olan 5. harmonik bileşenin frekansı için 2 ohm olacaktır. Daha yüksek frekanslar ve sabit bir kapasitans için kapasitif reaktansın sıfıra eğilimli olduğunu, bunun da rezonansa neden olarak kısa devre olasılığını artırabileceğini belirtmek mümkündür. Dolayısıyla kondansatörler, empedansları sebebiyle sistemdeki nonlineer yükler nedeniyle oluşan harmonikleri üzerlerine çekmektedirler. Üzerine harmonikli akımları çeken kondansatörün RMS (root mean square) akımının artmasıyla, kondansatörler hem mekaniki hemde elektriksel olarak zorlanacaktır. Yani harmonik bileşenlere sahip akımlar ve gerilimler, kondansatörün dielektrik malzemesinin zorlanmasına ve dolayısıyla dielektrik kayıpların artmasına sebep olacaktır. Reaktif güç kompanzasyonunda kullanılan kondansatörler harmoniğe neden olmazlar fakat var olan harmoniğin artmasına neden olurlar. Bu nedenle, harmonik bozulmaya maruz kalan şebelere kondansatörler monte edilirken, rezonans sorunlarından kaçınarak kondansatör bankalarının iyi bir performans göstermesini garanti etmek için ayrıntılı bir çalışma yapılmalıdır [17].

Literatürde, kompanzasyonun özellikle kondansatör bankaları ile sağlandığı sistemlerde, harmonik bozulma üzerinde bazı etkileri olduğu gösterilmiştir. Kompanzasyon amacıyla kullanılan kondansatörler, sistemde var olan harmoniklerle rezonansa girerek harmonik genliklerini artırabilir. Bu durum, literatürde rezonans olgusu olarak bilinir ve özellikle harmonik üreten yükler bulunan sistemlerde dikkat edilmesi gereken bir konudur. [18] nolu çalışmada, öncelikle güç faktörü düşük olan bir endüstriyel tesis seçilmiştir. Bu endüstriyel tesisin elektrik sistemindeki sorunları çözmek için basit bir yöntem olan 'reaktif güç kompanzasyonu' uygulanmıştır. Bu işlemin ardından, elektrik sistemindeki bazı değerler ölçülmüş ve sonuçlar bir tabloya yazılmıştır. Yapılan ölçümler sonucunda, kapasitörlerin elektrik sistemindeki bazı sorunları azalttığı ancak başka bir sorunu yani 'harmonik' adı verilen bir kirliliği artırdığı sonucuna ulaşılmıştır. [19] nolu çalışmada sunulan sonuçlar, güç faktörü iyileştirildikçe Volt-Amper-Reaktif (VAR) kompanzasyonunun güç sisteminin aktif güç işleme kapasitesini artırmaya yardımcı olduğunu ancak kapasitör eklenmesinin sistemdeki toplam harmonik bozulmayı artırdığını göstermiştir. [20] nolu çalışmada, harmonikli bir endüstriyel elektrik sisteminin (IES) ortak bağlantı noktasındaki (PCC) güç faktörünü iyileştirmek için yoğunlaştırılmış ve dağıtılmış reaktif güç kompanzasyonunu karşılaştırmıştır.

Ölçüm yapılan, sulama sistemi üreten tesiste, özellikle güç elektroniği bileşenleri, değişken hız sürücüler (pompa motorlarının hızını kontrol etmek için kullanılan sürücüler), inverterler, kaynak makineleri ve LED aydınlatmalardan kaynaklı olarak harmonikler meydana gelmektedir. Ambalaj sistemleri tesisinde ise sıvımalı karton, baskılı karton ve doppel kutu üretimi gerçekleştirmektedir. Bu fabrikalarda kullanılan başlıca harmonik üretebilecek makineler, ofset baskı makineleri, laminasyon makineleri ve kutu üretim makineleri şeklindedir. Ofset baskı makineleri, büyük motorlar ve güç elektroniği bileşenleri ile çalıştığından, yani hız kontrol üniteleri, servo motorlar ve invertörler kullandığından bu ekipmanlar harmonik kaynağıdır. Laminasyon makineleri, karton üzerine ince bir film veya kağıt tabaka eklemek için kullanıldığından, yani yüksek torklu motorlar laminasyon işlemi sırasında ve ısıtma ünitelerinde kullanılan yarı iletken cihazlar da harmonik kaynağıdır. Kutu üretim makineleri da, yüksek güçlü motorlar ve hassas kontrol üniteleri içermesi nedeniyle harmonik kaynağıdır. Kesim makinelerinde yüksek güçlü motorlar ve inverterler kullanılır. Yapıştırma ve birleştirme makinelerinde ise servo motorlar kullanılır.

Bu çalışmada, sanayi tesisinde reaktif güç kompanzasyonu ON ve OFF iken güç parametre değerleri ile %THD₁ değerleri güç analizörü ile ölçülmüştür. Reaktif güç kompanzasyonu ON ve OFF iken güç parametre değerlerindeki değişimin %THD₁'daki değişim üzerine etkisine bakılmıştır. Çalışmada, reaktif güç kompanzasyonundan önce ve sonra %THD₁ değeri üzerine olan etkisi ölçülen güç parametre değerleri baz alınarak grafiksel olarak incelenmiştir. Elde edilen sonuca göre reaktif güç kompanzasyonu devere de iken PF iyileşirken, %THD₁ değerinin arttığı gözlemlenmiş ve bunun sonucu olarak güç kalitesinde azalma meydana gelmiş yani sinüs dalgada bozulma meydana gelmiştir. Literatürdeki bazı çalışmalar, harmoniklerin reaktif güç kompanzasyonu ile etkileşimini ele alırken bu çalışmada daha fazla ayrıntı ile reaktif güç kompanzasyonunun harmoniklere nasıl etki ettiğine dair

analizler yapılmıştır. Reaktif güç kompanzasyon stratejilerinin harmoniklere göre ayarlanması konularında bu çalışma literatüre yeni katkılar sağlamıştır.

2. Materyal ve Metod

Elektrik sistemindeki bozulmaları (harmonikleri) ölçmek için sıkça kullanılan bir yöntemle Toplam Harmonik Bozulma yani kısaca THD diyoruz. THD, elektrik akımındaki veya gerilimdeki dalga şekillerinin bozulmasının ne kadar büyük olduğunu gösteren bir sayıdır. Denklem 2 ve 3 ise bunu hesaplamak için kullanılan matematiksel ifadelerdir [21].

$$\%THD_I = \frac{\sqrt{\sum_{n=2}^{\infty} I_{nrms}^2}}{I_{1rms}} \cdot \%100 = \frac{\sqrt{\sum_{n=2}^{\infty} I_n^2}}{I_1} \cdot 100 \quad (2)$$

$$\%THD_V = \frac{\sqrt{\sum_{n=2}^{\infty} V_{nrms}^2}}{V_{1rms}} \cdot \%100 = \frac{\sqrt{\sum_{n=2}^{\infty} V_n^2}}{V_1} \cdot 100 \quad (3)$$

Harmoniklerin olmadığı durumlarda yani yalnız temel frekanstan oluşan tam bir sinüs dalga şekli için gerilimin toplam harmonik bozulma (THD_V) ve akımın toplam harmonik bozulma (THD_I) değerleri sıfırdır. Harmoniklerin mevcut olmadığı durumlarda güç faktörü ($\cos \varphi$) ve PF eşit iken, harmoniklerin bulunduğu durumlarda ise $\cos \varphi$, PF'ye eşit değildir. Hem harmonikli hem de harmonik olmayan durumlar için geçerli olan PF denklem 4'deki gibi ifade edilir [22].


$$PF = \frac{P}{S} = \cos \varphi \cdot \frac{1}{\left(\sqrt{(1 + THD_I^2)(1 + THD_V^2)}\right)} = dPF \cdot \text{distortion PF} \quad (4)$$

Denklem 4'de, $\cos \varphi$ yer değiştirme güç faktörünü (dPF), toplam aktif gücü P, toplam görünür gücü S ve distortion PF ise bozulma güç faktörünü ifade etmektedir. Gerilim ve akım arasındaki faz kayması nedeniyle gerçek gücün görünür güce oranı dPF olarak tanımlanır ve denklem 5'deki haliyle hesaplanır [22].

$$dPF = \cos(\delta_1 - \theta_1) = \cos \varphi \quad (5)$$

Denklem 5'de, θ_1 akımın faz açısıdır, δ_1 voltajın faz açısıdır; φ ise güç faktörü açısıdır.

Çalışmada, sulama sistemleri ve ambalaj malzemesi üreten tesiste, üç fazda reaktif güç kompanzasyonu OFF ve ON iken P, S, Q, dPF, PF ve $\%THD_I$ değerleri güç analizörü ile ölçülmüştür. Şekil 1'de, güç analizörü ile yapılan ölçüm bağlantısı görülmektedir. Güç analizörünün sürücüsü yardımıyla, sistemin çektiği akımın harmonik spektrumu ve elde edilen karakteristikler, bilgisayar ortamına aktarılarak daha ayrıntılı olarak incelenmiştir.



Şekil 1. Güç analizörü ile yapılan ölçüm bağlantısı

3. Araştırma ve Bulgular

Sulama sistemleri üreten tesiste 2000 kVA'lık trafoda, ambalaj sanayisinde üretim yapan tesiste yük yok iken ve yük olduğunda, güç parametre değerleri kompanzasyon OFF ve ON durumunda iken üç fazda akım ve gerilim için %THD değerleri Çizelge 1, Çizelge 2, Çizelge 3 ve Çizelge 4'de verilmiştir. Çizelgelerden de görüldüğü üzere ölçüm yapılan tesislerde kompanzasyon on durumuna geçtiğinde %THD_I değerlerinde artış olduğu görülmüştür. Çizelge 1'de Sulama Sistemleri Tesisi 2000 kVA Trafoda reaktif güç kompanzasyonu OFF ve ON iken I_{rms} , V_{rms} , P, S, Q, PF, dPF, %THD_I ve %THD_V ölçüm değerleri görülmektedir. R fazında kompanzasyon OFF iken %THD_I değeri %14,25 seviyelerinde iken kompanzasyon ON durumuna getirildiğinde %THD_I değeri %24,88 seviyelerine yükselmiştir. S fazında kompanzasyon OFF iken %THD_I değeri %14,88 seviyelerinde iken kompanzasyon ON durumuna getirildiğinde %THD_I değeri %25,65 seviyelerine yükselmiştir. Ayrıca T fazında kompanzasyon OFF iken %THD_I değeri %14,426 seviyelerinde iken kompanzasyon ON durumuna getirildiğinde %THD_I değeri %28,011 seviyelerine yükselmiştir. Çizelge 1'deki ölçümlerde R-S-T fazlarında reaktif güç kompanzasyonu OFF ve ON durumunda %THD_I arasında farklar sırasıyla R fazında %10,636, S fazında %10,77 ve T fazında %13,585'tir.

Çizelge 1. Sulama Sistemleri Tesisinde 2000 kVA Trafoda Ölçülen Güç Parametre Değerleri

Parametreler	Kompanzasyon OFF Faz R	Kompanzasyon OFF Faz S	Kompanzasyon OFF Faz T	Kompanzasyon ON Faz R	Kompanzasyon ON Faz S	Kompanzasyon ON Faz T
U (V)	391.232	390.221	390.448	395.691	393.860	392.847
U_{rms} (V)	226.044	225.670	224.887	228.300	227.59	226.783
I_{rms} (A)	0.680	0.672	0.669	0.604	0.603	0.596
P (W)	130	131	5	133	61	63
S (VA)	154	152	151	138	137	135
Q (VAr)	83	76	150	37	123	119
dPF	0.856	0.876	0.030	1	0.458	0.5
PF	0.842	0.865	0.034	0.963	0.448	0.469
THD _I (%)	14.252	14.883	14.426	24.888	25.653	28.011
THD _V (%)	3.922	3.849	4.050	4.54	4.55	4.558

Sulama sistemleri üreten tesiste gerçekleştirilen üç faz ölçümlerin parametreleri Şekil 2, 5, 8, 11, 14, 17, 20, 23'de görülmektedir. Şekil 3, 6, 9, 12, 15, 18, 21, 24 (a)'da gerilim dalga şekli ve (b)'de


akım dalga şekli görülmektedir. Şekil 4, 7, 10, 13, 16, 19, 22, 25’de ise ifade edilen ölçümlerin akım için harmonik spektrumu görülmektedir.

Reaktif güç kompanzasyonu OFF iken sulama sistemi üretim tesisi beslemesinde kullanılan 2000 kVA trafoda yapılan ölçümde, şekil 2’de üç fazlı sistemde ölçülen güç değerleri, şekil 3’de üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli ve şekil 4’de ise üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri görülmektedir.


Reaktif güç kompanzasyonu ON iken sulama sistemi üretim tesisi beslemesinde kullanılan 2000 kVA trafoda yapılan ölçümde, şekil 5’de üç fazlı sistemde ölçülen güç değerleri, şekil 6’da üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli ve şekil 7’de ise üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri görülmektedir.

1st phase		2nd phase		3rd phase	
Ursm	UI_12	Ursm	UI_23	Ursm	UI_13
226.044	391.232	225.670	390.221	224.887	390.448
thd(U)	S(kVA)	thd(U)	S(kVA)	thd(U)	S(kVA)
3.922	0.154	3.849	0.152	4.050	0.151
I_rsm	P(kW)	I_rsm	P(kW)	I_rsm	P(kW)
0.680	0.130	0.672	0.131	0.669	0.005
thd(I)	Q(kVAR) i	thd(I)	Q(kVAR) c	thd(I)	Q(kVAR) c
14.252	0.083	14.883	-0.076	14.426	-0.150
Pf i	dPf	Pf c	dPf	Pf c	dPf
0.842	0.856	0.865	0.876	0.034	0.030
Total info					
Stot(kW)	Gtot(kVAR)	Ptot(kW)	Pftot c	I null	
0.30	-0.14	0.27	0.88	1.34	

Şekil 2. Sulama sistemi üretim tesisi beslemesinde kullanılan 2000 kVA trafoda, reaktif güç kompanzasyonu OFF iken üç fazlı sistemde ölçülen güç değerleri




Şekil 3. Sulama sistemi üretim tesisi beslemesinde kullanılan 2000 kVA trafoda, reaktif güç kompanzasyonu OFF iken üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli




Şekil 4. Sulama sistemi üretim tesisi beslemesinde kullanılan 2000 kVA trafoda, reaktif güç kompanzasyonu OFF iken üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri

1st phase		2nd phase		3rd phase	
Ursm	UI_12	Ursm	UI_23	Ursm	UI_13
228.300	395.691	227.590	393.860	226.788	392.847
thd(U)	S(kVA)	thd(U)	S(kVA)	thd(U)	S(kVA)
4.540	0.138	4.550	0.137	4.558	0.135
I_rsm	P(kW)	I_rsm	P(kW)	I_rsm	P(kW)
0.604	0.133	0.603	0.061	0.596	-0.063
thd(I)	Q(kVAR) c	thd(I)	Q(kVAR) c	thd(I)	Q(kVAR) i
24.888	-0.037	25.653	-0.123	28.011	-0.119
Pf c	dPf	Pf c	dPf	Pf i	dPf
0.963	1.000	0.448	0.458	0.469	0.500
Total info					
Stot(kW)	Qtot(kVAR)	Ptot(kW)	Ptot c	I null	
0.31	-0.28	0.13	0.42	1.18	

Şekil 5. Sulama sistemi beslemesinde kullanılan 2000 kVA trafoda, reaktif güç kompanzasyonu ON iken üç fazlı sistemde ölçülen güç değerleri



Şekil 6. Sulama sistemi üretim tesisi beslemesinde kullanılan 2000 kVA trafoda, reaktif güç kompanzasyonu ON iken üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli



Şekil 7. Sulama sistemi üretim tesisi beslemesinde kullanılan 2000 kVA trafoda, reaktif güç kompanzasyonu ON iken üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri

Çizelge 2’de ambalaj üretim tesisinde hiçbir yük (makine, ekipman vb.) çalıştırılmadığı durumda reaktif güç kompanzasyonu OFF ve ON iken I_{rms} , V_{rms} , P, S, Q, PF, dPF, %THD_I ve %THD_V ölçüm değerleri görülmektedir.

R fazında kompanzasyon OFF iken %THD_I değeri %7,406 seviyelerinde iken kompanzasyon ON durumunda %THD_I değeri %23,88 seviyelerine yükselmiştir. S fazında kompanzasyon OFF iken %THD_I değeri %7,641 iken kompanzasyon ON durumunda %THD_I %26,364 seviyesine yükselmiştir. Ayrıca T fazında kompanzasyon OFF iken %THD_I değeri %9,751 iken kompanzasyon ON durumunda %THD_I değeri %27,482 seviyesine yükselmiştir. Çizelge 2’deki ölçümlerde R-S-T fazlarında reaktif güç kompanzasyonu OFF ve ON durumunda %THD_I arasında farklar sırasıyla R fazında %16,482, S fazında %18,723 ve T fazında %17,731’dir.

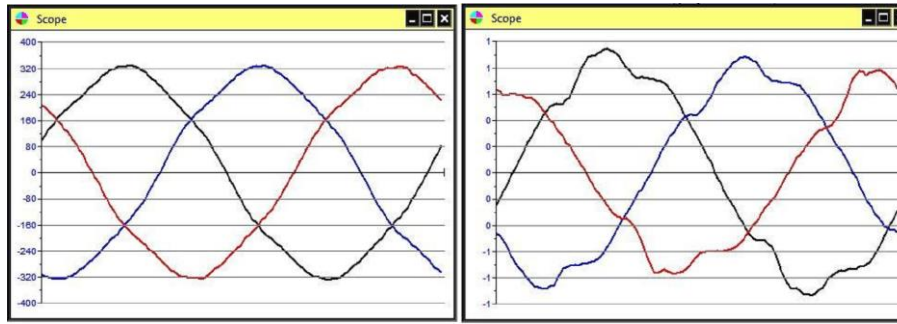
Çizelge 2. Ambalaj üretim tesisinde hiçbir yük (makine, ekipman vb.) çalıştırılmadığı durumdaki güç parametre değerleri

Parametreler	Komp. OFF Faz R	Komp. OFF Faz S	Komp. OFF Faz T	Komp. ON Faz R	Komp. ON Faz S	Komp. ON Faz T
U (V)	389.503	387.366	386.929	392.442	390.926	390.464
U_{rms} (V)	224.686	224.527	222.720	226.383	226.330	225.011
I_{rms} (A)	0.627	0.581	0.516	0.503	0.420	0.400
P (W)	120	108	93	108	88	82
S (VA)	141	130	115	114	95	90
Q (VAr)	74	73	67	35	36	37
dPF	0.855	0.831	0.815	0.979	0.957	0.944
PF	0.852	0.828	0.812	0.951	0.925	0.910
THD _I (%)	7.406	7.641	9.751	23.888	26.364	27.482
THD _V (%)	3.590	3.518	3.380	3.335	3.299	3.088

Reaktif güç kompanzasyonu OFF iken ambalaj üretim tesisinde hiçbir yük (makine, ekipman vb.) çalıştırılmadığı durumda yapılan ölçümde, şekil 8’de üç fazlı sistemde ölçülen güç değerleri, şekil 9’da üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli ve şekil 10’da ise üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri görülmektedir. Reaktif güç kompanzasyonu ON iken ambalaj üretim tesisinde hiçbir yük (makine, ekipman vb.) çalıştırılmadığı durumda yapılan ölçümde, şekil 11’de üç fazlı sistemde ölçülen güç değerleri, şekil 12’de üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli ve şekil 13’de ise üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri görülmektedir.

1st phase		2nd phase		3rd phase	
Ursm	Ul_12	Ursm	Ul_23	Ursm	Ul_13
224.686	389.503	224.527	387.366	222.720	386.929
thd(U)	S(kVA)	thd(U)	S(kVA)	thd(U)	S(kVA)
3.590	0.141	3.518	0.130	3.380	0.115
Irsm	P(kW)	Irsm	P(kW)	Irsm	P(kW)
0.627	0.120	0.581	0.108	0.516	0.093
thd(I)	Q(kVAR) i	thd(I)	Q(kVAR) i	thd(I)	Q(kVAR) i
7.406	0.074	7.641	0.073	9.751	0.067
Pf i	dPf	Pf i	dPf	Pf i	dPf
0.852	0.855	0.828	0.831	0.812	0.815
Total info					
Stot(kW)	Qtot(kVAR)	Ptot(kW)	Pfot i	I null	
0.39	0.21	0.32	0.83	0.10	


Şekil 8. Ambalaj üretim tesisinde hiçbir yük (makine, ekipman vb.) çalıştırılmadığı durumda reaktif güç kompanzasyonu OFF iken üç fazlı sistemde ölçülen güç değerleri



(a)

(b)


Şekil 9. Ambalaj üretim tesisinde hiçbir yük (makine, ekipman vb.) çalıştırılmadığı durumda reaktif güç kompanzasyonu OFF iken üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli




Şekil 10. Ambalaj üretim tesisinde hiçbir yük (makine, ekipman vb.) çalıştırılmadığı durumda reaktif güç kompanzasyonu OFF iken üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri

1st phase		2nd phase		3rd phase	
Ursm	U _{I_12}	Ursm	U _{I_23}	Ursm	U _{I_13}
226.383	392.442	226.330	390.926	225.011	390.464
thd(U)	S(kVA)	thd(U)	S(kVA)	thd(U)	S(kVA)
3.335	0.114	3.299	0.095	3.088	0.090
I _{rsm}	P(kW)	I _{rsm}	P(kW)	I _{rsm}	P(kW)
0.503	0.108	0.420	0.088	0.400	0.082
thd(I)	Q(kVAR) c	thd(I)	Q(kVAR) c	thd(I)	Q(kVAR) c
23.888	-0.035	26.364	-0.036	27.482	-0.037
Pf c	dPf	Pf c	dPf	Pf c	dPf
0.951	0.979	0.925	0.957	0.910	0.944
Total info					
Stot(kW)	Qtot(kVAR)	Ptot(kW)	Ptot c	I null	
0.30	-0.11	0.28	0.93	0.11	

Şekil 11. Ambalaj üretim tesisinde hiçbir yük (makine, ekipman vb.) çalıştırılmadığı durumda reaktif güç kompanzasyonu ON iken üç fazlı sistemde ölçülen güç değerleri



Şekil 12. Ambalaj üretim tesisinde hiçbir yük (makine, ekipman vb.) çalıştırılmadığı durumda reaktif güç kompanzasyonu ON iken üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli



Şekil 13. Ambalaj üretim tesisinde hiçbir yük (makine, ekipman vb.) çalıştırılmadığı durumda reaktif güç kompanzasyonu ON iken üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri

Çizelge 3’de ambalaj üretim tesisinde yüklerin (makine, ekipman vb.) çalıştırıldığı durumda reaktif güç kompanzasyonu OFF ve ON iken I_{rms} , V_{rms} , P, S, Q, PF, dPF, %THD_I ve %THD_V ölçüm değerleri görülmektedir.

R fazında kompanzasyon OFF iken %THD_I değeri %8,313 iken kompanzasyon ON durumunda %THD_I değeri %16,729 seviyesine yükselmiştir. S fazında kompanzasyon OFF iken %THD_I değeri %8,450 iken kompanzasyon ON durumunda %THD_I değeri %15,63 seviyesine yükselmiştir. T fazında kompanzasyon OFF iken %THD_I değeri %8,879 iken kompanzasyon ON durumunda %THD_I değeri %17,1 seviyesine yükselmiştir. Çizelge 3’deki ölçümlerde R-S-T fazlarında reaktif güç kompanzasyonu OFF ve ON durumunda %THD_I arasında farklar sırasıyla R fazında %8,416, S fazında %7,180 ve T fazında %8,221’dir.

Çizelge 3. Ambalaj üretim tesisinde yüklerin (makine, ekipman vb.) çalıştırıldığı durumdaki güç parametre değerleri


Parametr eler	Komp. OFF Faz R	Komp. OFF Faz S	Komp. OFF Faz T	Komp. ON Faz R	Komp. ON Faz S	Komp. ON Faz T
U (V)	382.822	380.704	379.452	395.572	393.380	391.428
U_{rms} (V)	220.974	220.433	218.507	227.864	227.544	226.119
I_{rms} (A)	1.963	1.960	1.804	1.120	1.091	1.002
P (W)	390	391	348	244	235	215
S (VA)	434	432	394	255	248	227
Q (VAr)	190	183	185	75	79	71
dPF	0.904	0.911	0.888	0.972	0.962	0.966
PF	0.899	0.905	0.883	0.956	0.948	0.949
THD _I (%)	8.313	8.450	8.879	16.729	15.630	17.100
THD _V (%)	3.051	3.147	3.017	2.836	2.886	2.652

Reaktif güç kompanzasyonu OFF iken ambalaj üretim tesisinde yüklerin (makine, ekipman vb.) çalıştırıldığı durumda yapılan ölçümde, şekil 14’de üç fazlı sistemde ölçülen güç değerleri, şekil 15’de üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli ve şekil 16’da ise üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri görülmektedir.


Reaktif güç kompanzasyonu ON iken ambalaj üretim tesisinde yüklerin (makine, ekipman vb.) çalıştırıldığı durumda yapılan ölçümde, şekil 17’de üç fazlı sistemde ölçülen güç değerleri, şekil 18’de üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli ve şekil 19’da ise üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri görülmektedir.

1st phase		2nd phase		3rd phase	
Ursm	Ul_12	Ursm	Ul_23	Ursm	Ul_13
220.974	382.822	220.433	380.704	218.507	379.452
thd(U)	S(kVA)	thd(U)	S(kVA)	thd(U)	S(kVA)
3.051	0.434	3.147	0.432	3.017	0.394
Irsm	P(kW)	Irsm	P(kW)	Irsm	P(kW)
1.963	0.390	1.960	0.391	1.804	0.348
thd(I)	Q(kVAR) I	thd(I)	Q(kVAR) I	thd(I)	Q(kVAR) I
8.313	0.190	8.450	0.183	8.879	0.185
Pf I	dPf	Pf I	dPf	Pf I	dPf
0.899	0.904	0.905	0.911	0.883	0.888
Total info					
Stot(kW)	Qtot(kVAR)	Ptot(kW)	Ptot I	I null	
1.26	0.56	1.13	0.90	0.22	

Şekil 14. Ambalaj üretim tesisinde yüklerin (makine, ekipman vb.) çalıştırıldığı durumda reaktif güç kompanzasyonu OFF iken üç fazlı sistemde ölçülen güç değerleri




Şekil 15. Ambalaj üretim tesisinde yüklerin (makine, ekipman vb.) çalıştırıldığı durumda reaktif güç kompanzasyonu OFF iken üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli




Şekil 16. Ambalaj üretim tesisinde yüklerin (makine, ekipman vb.) çalıştırıldığı durumda reaktif güç kompanzasyonu OFF iken üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri

1st phase		2nd phase		3rd phase	
Ursm	UI_12	Ursm	UI_23	Ursm	UI_13
227.864	395.572	227.544	393.380	226.119	391.428
thd(U)	S(kVA)	thd(U)	S(kVA)	thd(U)	S(kVA)
2.836	0.255	2.886	0.248	2.652	0.227
I_rsm	P(kW)	I_rsm	P(kW)	I_rsm	P(kW)
1.120	0.244	1.091	0.235	1.002	0.215
thd(I)	Q(kVAR) c	thd(I)	Q(kVAR) c	thd(I)	Q(kVAR) c
16.729	-0.075	15.630	-0.079	17.100	-0.071
Pf c	dPf	Pf c	dPf	Pf c	dPf
0.956	0.972	0.948	0.962	0.949	0.966
Total info					
Stot(kW)	Qtot(kVAR)	Ptot(kW)	PfTot c	I null	
0.73	-0.23	0.69	0.95	0.15	

Şekil 17. Ambalaj üretim tesisinde yüklerin (makine, ekipman vb.) çalıştırıldığı durumda reaktif güç kompanzasyonu ON iken üç fazlı sistemde ölçülen güç değerleri



Şekil 18. Ambalaj üretim tesisinde yüklerin (makine, ekipman vb.) çalıştırıldığı durumda reaktif güç kompanzasyonu ON iken üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli



Şekil 19. Ambalaj üretim tesisinde yüklerin (makine, ekipman vb.) çalıştırıldığı durumda reaktif güç kompanzasyonu ON iken üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri

Çizelge 4’de ambalaj üretim tesisinde akım trafo kutusu panosunda reaktif güç kompanzasyonu OFF ve ON iken I_{rms} , V_{rms} , P, S, Q, PF, dPF, %THD_I ve %THD_V ölçüm değerleri görülmektedir.

R fazında kompanzasyon OFF iken %THD_I değeri %21,703 iken kompanzasyon ON durumunda %THD_I değeri %37,424 seviyesine yükselmiştir. S fazında kompanzasyon OFF iken %THD_I değeri %21,19 iken kompanzasyon ON durumunda %THD_I değeri %38,587 seviyesine yükselmiştir. T fazında kompanzasyon OFF iken %THD_I değeri %21,166 iken kompanzasyon ON durumunda %THD_I değeri %36,519 seviyesine yükselmiştir. Çizelge 3’deki ölçümlerde R-S-T fazlarında reaktif güç kompanzasyonu OFF ve ON durumunda %THD_I arasında farklar sırasıyla R fazında %15,721, S fazında %17,397 ve T fazında %15,353’dür.

Çizelge 4. Ambalaj üretim tesisinde akım trafo kutusu panosunda ölçülen güç parameter değerleri


Parametr eler	Komp. OFF Faz R	Komp. OFF Faz S	Komp. OFF Faz T	Komp. ON Faz R	Komp. ON Faz S	Komp. ON Faz T
U (V)	393.006	392.547	391.184	393.690	392.889	391.624
U_{rms} (V)	227.017	226.664	225.733	227.362	226.820	226.078
I_{rms} (A)	245.869	235.655	231.836	180.245	166.158	168.160
P (W)	37 442	34 676	35 173	38 184	35 023	35 445
S (VA)	55 817	53 415	52 333	40 981	37 688	38 017
Q (VAr)	41 396	40 629	38 751	14 879	13 921	13 746
dPF	0.691	0.667	0.691	1.000	1.000	0.997
PF	0.671	0.649	0.672	0.932	0.929	0.932
THD _I (%)	21.703	21.190	21.166	37.424	38.587	36.519
THD _V (%)	2.213	0	0	0	0	0

Reaktif güç kompanzasyonu OFF iken ambalaj üretim tesisinde akım trafo kutusu panosunda yapılan ölçümde, şekil 20’de üç fazlı sistemde ölçülen güç değerleri, şekil 21’de üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli ve şekil 22’de ise üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri görülmektedir.


Reaktif güç kompanzasyonu ON iken ambalaj üretim tesisinde akım trafo kutusu panosunda yapılan ölçümde, şekil 23’de üç fazlı sistemde ölçülen güç değerleri, şekil 24’de üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli ve şekil 25’de ise üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri görülmektedir.

1st phase		2nd phase		3rd phase	
Ursm	Ul_12	Ursm	Ul_23	Ursm	Ul_13
227.017	393.006	226.664	392.547	225.733	391.184
thd(U)	S(kVA)	thd(U)	S(kVA)	thd(U)	S(kVA)
2.213	55.817	0	53.415	0	52.333
I_rsm	P(kW)	I_rsm	P(kW)	I_rsm	P(kW)
245.869	37.442	235.655	34.676	231.836	35.173
thd(I)	Q(kVAR) i	thd(I)	Q(kVAR) i	thd(I)	Q(kVAR) i
21.703	41.396	21.190	40.629	21.166	38.751
Pf i	dPf	Pf i	dPf	Pf i	dPf
0.671	0.691	0.649	0.867	0.672	0.691
Total info					
Stot(kW)	Qtot(kVAR)	Ptot(kW)	Pfot i	I null	
161.55	120.77	107.29	0.66	15.19	

Şekil 20. Ambalaj üretim tesisinde akım trafo kutusu panosunda reaktif güç kompanzasyonu OFF iken üç fazlı sistemde ölçülen güç değerleri




Şekil 21. Ambalaj üretim tesisinde akım trafo kutusu panosunda reaktif güç kompanzasyonu OFF iken üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli




Şekil 22. Ambalaj üretim tesisinde akım trafo kutusu panosunda reaktif güç kompanzasyonu OFF iken üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri

1st phase		2nd phase		3rd phase	
Ursm	Ui_12	Ursm	Ui_23	Ursm	Ui_13
227.362	393.690	226.820	392.889	226.078	391.624
thd(U)	S(kVA)	thd(U)	S(kVA)	thd(U)	S(kVA)
0	40.981	0	37.688	0	38.017
I_rsm	P(kW)	I_rsm	P(kW)	I_rsm	P(kW)
180.245	38.184	166.158	35.023	168.160	35.445
thd(I)	Q(kVAR) c	thd(I)	Q(kVAR) c	thd(I)	Q(kVAR) c
37.424	-14.879	38.587	-13.921	36.519	-13.746
Pf c	dPf	Pf c	dPf	Pf c	dPf
0.932	1.000	0.929	1.000	0.932	0.997
Total info					
Stot(kW)	Qtot(kVAR)	Ptot(kW)	Ptot c	I null	
116.69	-42.55	108.65	0.93	6.29	

Şekil 23. Ambalaj üretim tesisinde akım trafo kutusu panosunda reaktif güç kompanzasyonu ON iken (ON) üç fazlı sistemde ölçülen güç değerleri



Şekil 24. Ambalaj üretim tesisinde akım trafo kutusu panosunda reaktif güç kompanzasyonu ON iken (ON) üç fazlı sistemde (a) gerilim dalga şekli ve (b) akım dalga şekli




Şekil 25. Ambalaj üretim tesisinde akım trafo kutusu panosunda reaktif güç kompanzasyonu ON iken üç fazlı sistemde her bir faz için akımın frekans bileşenlerini gösteren harmonik spektrum analizleri

Çizelge 5'te reaktif güç kompanzasyon sisteminin devreye alınması ve devreden çıkarılması durumlarında ölçülen Q, % THD_I, PF ve dPF değerleri görülmektedir.

Çizelge 5. Reaktif güç kompanzasyon sisteminin ON ve OFF durumunda ölçülen Q, %THD_i, PF ve dPF değerleri


Reaktif Güç Komp. OFF Durumunda Q (Var)	Reaktif Güç Komp. ON Durumunda Q (Var)	Reaktif Güç Komp. OFF Durumunda %THD _i	Reaktif Güç Komp. ON Durumunda %THD _i	Reaktif Güç Komp. OFF Durumunda PF	Reaktif Güç Komp. ON Durumunda PF	Reaktif Güç Komp. OFF Durumunda dPF	Reaktif Güç Komp. ON Durumunda dPF
83	37	14.252	24.888	0.842	0.963	0.856	1
150	119	14.426	28.011	0.034	0.469	0.03	0.5
74	35	7.406	23.888	0.852	0.951	0.855	0.979
73	36	7.641	26.364	0.828	0.925	0.831	0.957
67	37	9.751	27.482	0.812	0.910	0.815	0.944
190	75	8.313	16.729	0.899	0.956	0.904	0.972
183	79	8.450	15.630	0.905	0.948	0.911	0.962
185	71	8.879	17.100	0.883	0.949	0.888	0.966
41 396	14 879	21.703	37.424	0.671	0.932	0.691	1
40 629	13 921	21.190	38.587	0.649	0.929	0.667	1
38 751	13 746	21.166	36.519	0.672	0.932	0.691	0.997

Çizelge 5'deki değerler göz önüne alınarak şekil 26, 27 ve 28'deki grafikler elde edilmiştir. Şekil 26'da reaktif güç kompanzasyon sisteminin OFF ve ON durumlarında, tüm ölçümler grafikte de görüldüğü üzere %THD_i değeri, kompanzasyon ON iken artmıştır.




Şekil 26. Reaktif Güç Kompanzasyonu ON ve OFF durumlarında, %THD_i değerleri

Şekil 27'de reaktif güç kompanzasyon sisteminin OFF ve ON durumlarında, tüm ölçümler grafikte de görüldüğü üzere PF değerleri artıyor yani güç kalitesi iyileşiyor iken, %THD_i değeri, kompanzasyon ON iken artmıştır yani güç kalitesi azalmıştır.



Şekil 27. Reaktif Güç Kompanzasyonu OFF ve ON durumlarında, PF ve %THD₁ değerleri

Şekil 28'de reaktif güç kompanzasyon sisteminin OFF ve ON durumlarında, tüm ölçümler grafikte de görüldüğü üzere dPF değerleri artıyor yani güç kalitesi iyileşiyor iken, %THD₁ değeri, kompanzasyon ON iken artmıştır yani güç kalitesi azalmıştır.



Şekil 28. Reaktif Güç Kompanzasyonu OFF ve ON durumlarında, dPF ve %THD₁ değerleri

Genel olarak, harmonik bozulma ve reaktif güç kompanzasyonu arasındaki ilişki literatürde geniş çapta incelenmiş olup, bu çalışmanın sonuçları da önceki bulgularla tamamiyle örtüşmektedir.

4. Sonuçlar

Endüstriyel tesislerde reaktif güç kompanzasyonu doğru şekilde tasarlandığında, güç kalitesini iyileştirir, enerji verimliliğini artırır ve ekipman ömrünü uzatır. Ancak yanlış tasarlanan bir kompanzasyon sistemi, sistemdeki harmonik bozulmaları artırabilir ve rezonansa neden olabilir. Bu rezonans, motorların, inverterlerin ve diğer elektronik cihazların zarar görmesine yol açabilir. Bu nedenle, üretim ve imalat tesislerinde rezonans frekanslarının doğru bir şekilde belirlenmesi ve kompanzasyon devresinin buna göre tasarlanması gerekmektedir. Pasif veya aktif harmonik filtreler, kompanzasyon sistemlerine entegre edilerek rezonans problemleri minimize edilmelidir. Enerji sürekliliği kritik olan tesislerde aktif harmonik filtre kullanımı zorunlu hale getirilmeli ve harmoniklerin anlık izlenmesi sağlanmalıdır. Reaktif güç kompanzasyonu bir tesise yapılacak ise tesis önce harmonik yönünden incelenmeli ve standart değerler baz alınarak harmonikli reaktif güç kompanzasyonu yapılmalıdır.

Bu çalışmada reaktif güç kompanzasyonunun toplam harmonik bozulmaya olan etkisi, sulama sistemleri üreten tesiste, ambalaj sanayisinde üretim yapan tesis yüklü ve yüksüz iken üç fazda reaktif güç kompanzasyonu OFF ve ON durumunda iken ölçümler yapılarak açıklanmıştır. Reaktif güç kompanzasyonu OFF ve ON iken %THD₁ sonuçları analiz edilip tablolaştırılmış ve grafik haline getirilmiştir. Elde edilen sonuçlar reaktif güç kompanzasyonu ON iken şebekeden çekilen reaktif gücü azalttığını göstermiştir. Ancak reaktif güç kompanzasyonunda kullanılan kondansatörler nedeniyle %THD₁ değeri artmıştır. Reaktif güç kompanzasyonun %THD₁ değerini minimum %7,180 fark ile %8,45'ten %15,63'e, maksimum ise %18,723 fark ile %7,64'den %26,36'e yükseltmiştir. Sonuç olarak güç kalitesinin en önemli parametrelerinden birisi olan güç faktörü, reaktif güç kompanzasyonu yapılarak iyileştirildiğinde, %THD₁ değerinin arttığı görülmüştür. %THD₁ değerinin artmasıyla güç kalitesi azalmıştır. Bu yüzden, reaktif güç kompanzasyon sistemleri tasarlanırken harmoniklerin göz önünde bulundurulması güç kalitesi için önem arz etmektedir.

Kaynaklar

- [1] Kocatepe C, Uzunoğlu M, Yumurtacı R, Karakaş A ve Arıkan O. Elektrik Tesislerinde Harmonikler. İstanbul: Birsen Yayınevi; 2003.
- [2] Adak S, Cangı H ve Yılmaz AS. Doğrusal Olmayan Yüklerde Güç Faktörünün Düzeltilmesi ve Harmonik Bileşenlerin Süzülmesi. Gazi Üniversitesi Fen Bilimleri Dergisi 2019; 7 (1): 153-164.
- [3] Kakilli A, Tunçalp K ve Sucu M. Harmoniklerin Reaktif Güç Kompanzasyon Sistemine Etkilerinin İncelenmesi. Fırat Üniversitesi Fen ve Mühendislik Bilimleri Dergisi 2008; 20 (1): 109-115.
- [4] Camui C, Petre V and Boicea V. Power Factor Correction: a Hands-on Introduction for Students. International Conference and Exposition on Electrical And Power Engineering (EPE), Iasi, Romania; 2020.
- [5] Sharma YK and Vijay MR. Capacitor Banks and its Effect on Power System with High Harmonics Loads. In: 3rd International Conference for Convergence in Technology (I2CT), Pune, India; 2018.
- [6] Olaru D and Florica D. Model Analysis for Sinusoidal Power Factor Corrector. U.P.B. Sci. Bull., Series C 2012; 74 (4): 273-282.
- [7] Singh R, Paniyil P and Zhang Z. Transformative Role of Power Electronics: In solving climate emergency. IEEE Power Electronics Magazine 2022; 9 (2): 39-47.
- [8] Williamson SS. The success of electric mobility will depend on power electronics. Nature Electronics 2022; 5(1): 14-15.
- [9] Grady WM and Santoso S. Understanding power system harmonics. Power Engineering Review IEEE 2001; 21(11): 8-11.
- [10] Kutija M and Pravica L. Electric Power Quantities in the Presence of Harmonics-Case Study. In: IEEE 19th International Power Electronics and Motion Control Conference (PEMC), Gliwice, Poland; 2021.

- [11] Azzam-Jai A and Ouassaid M. A Multifunctional PV-Based Shunt Active Power Filter Using Neural Network Controller. International Symposium on Advanced Electrical and Communication Technologies (ISAECT), Rabat, Morocco; 2018.
- [12] Subjak JS and McQuilkin JS. Harmonics-causes, effects, measurements, and analysis: an update. IEEE Transactions on Industry Applications 1990; 26 (6): 1034-1042.
- [13] Arrillaga J, Watson NR and Chen S. Power system quality assessment. New York: Wiley; 2000.
- [14] Elphick S, Gosbell V, Smith V, Perera S, Ciufu P and Drury G. Methods for harmonic analysis and reporting in future grid applications. IEEE Transactions on Power Delivery 2017; 32 (2): 989–995.
- [15] Conroy E. Power monitoring and harmonic problems in the modern building. Power Engineering Journal 2001; 15 (2): 101–107.
- [16] Riaz MT, Afzal MM, Aaqib SM and Ali H. Analysis and Evaluating the Effect of Harmonic Distortion Levels in Industry. In: 4th International Conference on Energy Conservation and Efficiency (ICECE), Lahore, Pakistan; 2021.
- [17] Moraes PHF *et al.* Synchronous compensation versus capacitive compensation for reactive power in industrial systems subjected to harmonic distortion. In: IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), Florence, Italy; 2016.
- [18] Biricik S and Özerdem ÖC. Harmonic distortion comparison of switched capacitors with active power filter for reactive power compensation. In: 9th International Conference on Environment and Electrical Engineering, Prague, Czech Republic; 2010.
- [19] Munir HM, Xie C, Zou J, Wang X, Kashif SAR and Younas T. Impact of VAR compensation on total harmonic distortion measured using smart meter. In: 2nd International Conference on Power and Renewable Energy (ICPRE), Chengdu, China; 2017.
- [20] Giha Yidi SA, Sousa Santos V, Berdugo Sarmiento K, Candelo-Becerra JE, de la Cruz J. Comparison of Reactive Power Compensation Methods in an Industrial Electrical System with Power Quality Problems 2024; 5 (3): 642-661.
- [21] Grady WM and Gilleskie RJ. Harmonics And How They Relate To Power Factor, Proc. of the EPRI Power Quality Issues & Opportunities Conference (PQA '93), San Diego, United States; 1993.
- [22] Wakileh JG. Power Systems Harmonics: Fundamentals, Analysis and Filter Design. 1st ed. New York: Springer; 2001.

VERİ ÖN İŞLEME TEKNİKLERİNİN SAĞLIK VERİLERİNİN SINIFLANDIRMA BAŞARISINA ETKİSİNİN İNCELENMESİ

Feyza ERDOĞAN¹, Vahit TONGUR^{2*}, Betül UZBAŞ³

^{1,2} Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Yazılım Mühendisliği Bölümü, Konya, 42250, Türkiye

³ Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, 42250, Türkiye

Geliş Tarihi/Received Date: 08.04.2024 Kabul Tarihi/Accepted Date: 22.11.2024 DOI: 10.54365/adyumbd.1466631

ÖZET

Veri madenciliği sürecinin en temel adımlarından biri olan veri ön işleme teknikleri, literatürde sıklıkla başvurulan bir süreçtir. Bu çalışmada Hepatit hastalığına ait veri kümesi üzerinde sağlık alanında sık kullanılan veri ön işleme tekniklerinin etkinliği incelenmiştir. Sırasıyla eksik veri, dengesiz veri kümesi, aykırı veri, normalizasyon ve özellik seçimi işlemleri uygulanmıştır. Veri kümesinin her adımda elde edilen yeni versiyonu için literatürde sıklıkla kullanılan beş makine öğrenmesi yöntemi (KNN, LR, RF, SVM, ANN) ile sınıflandırma yapılmıştır. Elde edilen sonuçlar, doğru ve gerekli veri ön işleme tekniklerinin seçimi ile model başarısına olumlu katkısını desteklemektedir. Tüm aşama sonunda elde edilen model performansları %85 ve üzerinde olup, tüm performans belirleme ölçütleri bazında tutarlı sonuçlar göstermektedir. Her bir veri ön işleme model performansına kademeli olarak katkıda bulunmuş, en yüksek katkı ise son aşamada uygulanan özellik seçimi ile sağlanmıştır. Özellik seçimi, modelin performansını belirgin şekilde iyileştirerek sınıflandırma başarısına önemli ölçüde katkı sağlamıştır.

Anahtar Kelimeler: Hepatit, Makine Öğrenmesi, Sağlık Veri Kümesi, Veri Ön İşleme

INVESTIGATION OF THE EFFECT OF DATA PRE-PROCESSING TECHNIQUES ON THE CLASSIFICATION SUCCESS OF HEALTH DATA

ABSTRACT

Data preprocessing techniques, one of the most fundamental steps in the data mining process, are frequently referenced in the literature. In this study, the effectiveness of commonly used data preprocessing techniques in the health field was examined on a dataset related to Hepatitis disease. The processes of handling missing data, managing imbalanced datasets, outlier detection, normalization, and feature selection were applied in sequence. For each new version of the dataset obtained at every step, classification was performed using five machine learning methods commonly used in the literature (KNN, LR, RF, SVM, ANN). The results obtained support the positive contribution of correctly selecting the appropriate data preprocessing techniques to model success. The model performances achieved in all steps are above 85%, showing consistent results across all performance evaluation metrics. Each data preprocessing step contributed gradually to model performance, with the highest contribution provided by the feature selection applied in the final stage. Feature selection significantly enhanced the model's performance, making a substantial contribution to classification success.

Keywords: Data Preprocessing, Health Dataset, Hepatitis, Machine Learning

e-posta¹ : ferdogan@ktun.edu.tr ORCID ID: <https://orcid.org/0000-0002-9750-0495>

* e-posta² : vtongur@ktun.edu.tr ORCID ID: <https://orcid.org/0000-0001-5419-7839> (Sorumlu Yazar)

e-posta³ : buzbas@ktun.edu.tr ORCID ID: <https://orcid.org/0000-0002-0255-5988>

1. Giriş

Günümüz çağı, büyük veri çağı olarak adlandırılmaktadır. Sağlık, mühendislik, finans gibi daha birçok alanda, veriler bir araya gelerek veri kümelerini oluşturmaktadır. Veri sayısının her geçen gün artması, veri kümelerinin işlenmesi hususunda bazı problemleri de beraberinde getirmektedir [1, 2].

Veri madenciliği, veriyi keşfetme ve faydalı bilgiye erişme süreci olarak tanımlanabilmektedir [3, 4]. Bu sayede, elde edilen faydalı bilgiler ilişkilendirilerek amaca uygun bir şekilde geleceğe yönelik kullanılabilir [5].

Veri madenciliği sürecinde faydalı bilgiye erişilebilmesi, kullanılan veri kümesinin yapısı ve kalitesi ile doğrudan ilişkilidir [4, 6]. Veri madenciliğinde önemli bir aşamaya sahip olan veri ön işleme, bu doğrultuda yararlanılan kritik bir adımdır. Veri ön işleme sürecindeki işlemler kullanılan veri kümesine bağlı olarak seçilmelidir. Veri ön işleme aşamasındaki temel adımlar; eksik veri giderme (veri temizleme), aykırı veri tespiti (veri temizleme), dengesizlik sorunu (veri artırma), normalizasyon (veri dönüştürme) ve özellik seçimidir (veri indirgeme) [4, 7, 8].

Günümüzde var olan birçok veri kümesinde yukarıda bahsi geçen problemler sıklıkla yer almaktadır. Özellikle sağlık verilerinde karşılaşılan en büyük sorun, eksik veri, aykırı (hatalı) veri ve dengesizlik sorunudur [9]. Eksik veri oluşumu genel olarak hastalardan talep edilen bilgilerin tamamının sağlanamamasından kaynaklanır. Aykırı veri oluşumu ise ölçüm yapılan cihaz, ölçüm yapan personel, ölçüm sırasında gerçekleşen hatalı/eksik eylem gibi nedenlerle ortaya çıkmaktadır. Dengesizlik sorunu ise veri kümesinde yer alan farklı sınıf etiketine sahip örnek sayılarının adil dağılıma sahip olmamasıdır [9-10]. Örneğin; iyi huylu ve kötü huylu olmak üzere iki adet sınıf değerinden oluşan bir kanser veri kümesinin olduğu varsayalım. Veri kümesindeki toplam 500 örnek hasta verisinin yer aldığını ve bu örneklerin 100 adet iyi huylu; 400 adet kötü huylu hasta örneği olduğunu düşünülürse dengesiz bir veri kümesi olduğunu söylenebilir.

Makine öğrenmesi, günümüzde adından sıkça söz ettirmekte olup; birçok algoritmayı içerisinde barındırmaktadır [11, 12]. Bu algoritmalar, veriler üzerinde matematiksel ve istatistiksel bazı yöntemler kullanarak bir model ortaya koymakta ve anlamlı sonuçlar üretmektedir [10, 13]. Algoritmalar sonucu elde edilen model, tahmin yeteneğine sahiptir ve tahmin başarısı doğrudan model ile ilişkilidir. Modelin başarısı da doğrudan veri kümesi ile ilişkilidir. Çünkü makine öğrenmesi algoritmaları, dengeli ve veri eksikliği bulunmayan veri kümeleri için tasarlanmıştır [3, 9]. Dolayısıyla bu tür eksiklikleri içeren kalitesiz bir veri kümesinde algoritma iyi performans gösteremeyecektir. Bu doğrultuda, başarılı bir makine öğrenmesi süreci için veri kümesi üzerinde gerekli olan veri ön işleme tekniklerinin uygulanması kaçınılmazdır.

Literatürdeki çalışmalar, veri ön işleme adımlarını genellikle tekil teknikler (örneğin, yalnızca eksik veri giderme veya yalnızca sınıf dengesizliği giderme) veya birkaç tekniğin kombinasyonu şeklinde ele almaktadır. Bu çalışmada ise, diğer çalışmalardan farklı olarak veri ön işlemenin tüm temel adımları (eksik veri giderme, aykırı veri tespiti, sınıf dengesizliği giderme, normalizasyon ve özellik seçimi) aşamalı olarak ve üst üste uygulanmıştır. Çalışma, özellikle *Hepatitis* veri seti üzerinde eksiksiz bir veri ön işleme süreci sunarak, bu veri kümesi için tüm adımları kapsayan en kapsamlı çalışma olma özelliğini taşımaktadır. Bu çok aşamalı ön işleme yaklaşımı ile veri kalitesini artırarak sınıflandırma başarısına katkı sağlanması amaçlanmış ve sağlık verilerinin sınıflandırılmasında veri ön işleme tekniklerinin toplu etkisi ortaya konmuştur. Böylece, çalışma hem veri ön işlemeye bütünsel yaklaşımıyla hem de *Hepatitis* veri seti üzerinde kapsamlı uygulamasıyla literatüre yenilikçi bir katkı sunmaktadır. Çalışmada uygulanan veri ön işleme adımlarını ve her aşamanın veri kümesi üzerindeki etkisini görselleştiren akış şeması, Şekil 1'de sunulmuştur.



Şekil 1. Çalışmada uygulanan veri ön işleme adımlarının akış şeması

Çizelge 1. Literatür özeti

Makale	Veri Seti	Problem	Yöntem	Sonuç
Özüğür ve Orman [9]	PIMA	Eksik Değer, Dengesiz Veri	SMOTEENN, MICE	%91 (F-score)
Mitra ve Samanta [12]	Hepatitis	Eksik Değer, Özellik Seçimi	EMB, RS	%100 (Sınıflandırma Doğruluğu)
Saygın ve Baykara [10]	ILPD	Özellik Seçimi	SFS	LGBM %82.12, MLP %81.13, DT %81.13, SVM %77.87 ve LR %77.80
Orooji ve Kermani [13]	Hepatitis	Dengesiz Veri	Random Over-Sampling, Random Under-Sampling	Over-Sampling: sensitivity, accuracy ve f-score (%99.9); specificity %100
Nahzat ve Yağanoğlu [11]	PIMA	Normalizasyon, Eksik Veri	Mean/Median	%88.31 (RF-Accuracy)

Literatürde sağlık verilerinin makine öğrenmesi algoritmaları ile sınıflandırılması adına pek çok çalışma yer almaktadır. Çizelge 1'de literatürde yer alan bazı çalışmalar yazar bilgisi, kullanılan veri

seti, veri setine ait problem, veri setine uygulanan en başarılı veri ön işleme tekniđi (*Yöntem*), ve elde edilen başarı sonucu (*Sonuç*) şeklinde özetlenmiştir.

Bu çalışmanın geriye kalan kısmı řu şekilde organize edilmiştir: ikinci bölümde çalışmada kullanılan veri seti ve veri seti üzerinde uygulanan veri ön işleme teknikleri hakkında bilgilendirme yapılmıştır. Üçüncü bölümde her bir yöntemden elde edilen deneysel sonuçlar sunulmuştur. Son olarak dördüncü bölümde ise çalışma sonucunda elde edilen temel sonuçlar ve bu çalışmanın gelecekteki çalışmalara katkısı yorumlanmıştır.

2. Materyal ve Metod

Bu bölüm üç temel başlıktan oluşmaktadır. İlk olarak, çalışmada kullanılan veri seti hakkında bilgilendirme yapılmıştır. Ardından, veri seti üzerinde uygulanan veri ön işleme teknikleri hakkında bilgi verilmiştir. Son olarak, sınıflandırma algoritmalarının başarı kıyaslaması için kullanılan performans belirleme ölçütleri sunulmuştur.

2.1. Veri Seti Tanıtımı

Hepatitis veri seti, Gail Gong tarafından 1988 yılında literatüre kazandırılmıştır [14]. Kaliforniya Üniversitesi Irvine Makine Öğrenmesi Veritabanı'nda yer alan veri seti [15], hepatit hastası bireylerin ölçüm değerlerinden oluşan bir sınıflandırma veri setidir. Hayatta kalan ve ölü olmak üzere iki sınıfı olan veri setinde; toplamda 155 vaka örneđi ve sınıf özniteliđi dışında 19 öznitelik bulunmaktadır [16]. Bu özniteliklerden bazıları kategorik veri tipine sahipken; veri ön işleme tekniklerinin uygulanabilmesi adına sayısal veri tipine dönüřtürülmüştür. Çizelge 2'de veri setinde yer alan öznitelikler hakkında açıklamalar verilmiştir.

Çizelge 2. Hepatitis veri setinin temel yapısı

Öznitelik	Veri Tipi	Aralık
Age	Sayısal	[7,78]
Sex	Sayısal	[1,2]
Steroid	Kategorik	[1,2]
Antivirals	Sayısal	[1,2]
Fatigue	Kategorik	[1,2]
Malaise	Kategorik	[1,2]
Anorexia	Kategorik	[1,2]
LiverBig	Kategorik	[1,2]
LiverFirm	Kategorik	[1,2]
SpleenPalpable	Kategorik	[1,2]
Spiders	Kategorik	[1,2]
Ascites	Kategorik	[1,2]
Varices	Kategorik	[1,2]
Bilirubin	Kategorik	[3,8]
AlkPhosphate	Kategorik	[26,295]
Sgot	Kategorik	[14,648]
Albumin	Kategorik	[2.1,6.4]
Protime	Kategorik	[0,100]
Histology	Sayısal	[1,2]

2.2. Veri Ön İşleme

Bu başlıkta, veri seti üzerinde sırasıyla uygulanan beş ön işleme tekniği ve bu teknikleri uygularken kullanılan yöntemler yer almaktadır.

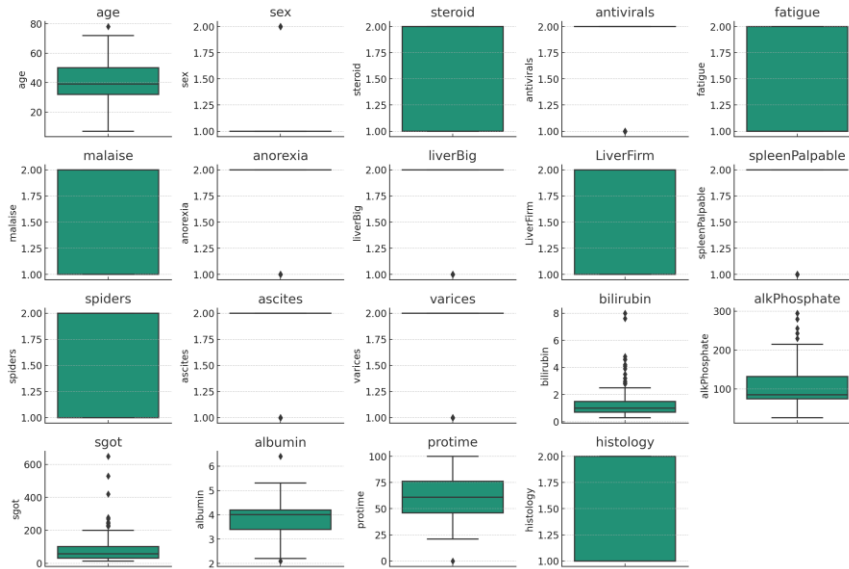
2.2.1. Eksik Veri Giderme

Hepatit veri setinde 167 adet eksik veri (missing value) bulunmaktadır. Bu da tüm veri setinin yaklaşık %5.39'una tekabül etmektedir. Bazı veri ön işleme teknikleri ve sınıflandırma algoritmaları eksik veri içeren veri setleri üzerinde kullanılamamaktadır. Bu sebeple bir veri seti eksik değer içeriyorsa ilk adım eksik verileri gidermek olacaktır. Literatürde eksik verileri gidermek için; istatistiksel, basit, makine öğrenmesi teknikleri kullanan ve karmaşık yapıya sahip yöntemler bulunmaktadır [9, 16]. Bu çalışmada, hepatit veri seti üzerinde eksik verileri gidermek için istatistiksel bir yöntem olan ortalama ile doldurma (mean imputation) yöntemi kullanılmıştır. Bu yöntem eksik verileri, ait olduğu sütundaki verilerin aritmetik ortalamasını kullanarak doldurmaktadır. Ortalama ile doldurma yöntemi basit, uygulaması kolay yöntemdir. Az oranda eksik veriye sahip ve eksik veri dağılımının düzensiz olduğu durumlarda kullanışlı olması nedeniyle tercih edilmiştir.

2.2.2. Aykırı Veri Tespiti

Aykırı veri (outlier data), bir veri setini oluşturan örneklerden büyük oranda farklılık gösteren veri olarak adlandırılmaktadır [17]. Veri girişi sırasında yapılan hatalar, hatalı ölçüm gibi nedenlerden dolayı aykırı veri oluşabilmektedir [18]. Aykırı veriler, özellikle sonrasında gerçekleştirilecek ön işleme adımları ve sınıflandırma aşamasında modelin yanlılığına düşmesine neden olabilmektedir. Bu doğrultuda, modelin performansı olumsuz yönde etkilenecek ve güvenilirliği azalacaktır. Aykırı veri tespiti, bu problemlerin çözümü için kullanılan ön işleme tekniklerinden biridir. Veri setindeki aykırı değerleri tespit etmek için; görselleştirme, IQR, Z-score, Hampel vb. literatürde birçok farklı yöntem bulunmaktadır [17-19].

Eksik veri giderme işlemi sonucu elde edilen yeni Hepatit veri seti üzerinde, kutu grafiği kullanılarak aykırı veri tespiti gerçekleştirilmiştir. Şekil 2'de her bir öznitelik için kutu grafiği ile aykırı veri tespiti sonuçları sunulmuştur. Şekil 2'de görüldüğü üzere, bazı kutuların alt ve üst kısımlarına dağılmış küçük noktalar yer almaktadır. Bu noktalar, aykırı veri olarak isimlendirilmekte olup; özellikle bilirubin, alkPhosphate, sgot ve protime özniteliklerinde dikkat çekmektedir.



Şekil 2. Aykırı verilere ait kutu grafiği sonuçları

Bu alıřmada aykırı veri tespiti iin eyrekler Arası Aıklık (*Interquartile Range, IQR*) yntemi kullanılmıřtır. Bu yntem, veri setinin yayılımını lmek iin aykırı veri tespitinde kullanılan istatistiksel bir yntemdir [20, 21]. IQR ynteminde ncelikle veriler kekten byge sıralanır. Ardından veri setinin alt yarısındaki (*Q1*) ve st yarısındaki (*Q2*) ortanca deđerler hesaplanarak farkı alınır. Bu fark deđeri IQR deđerini temsil etmekte olup, genellikle $Q1 - 1.5 \times IQR$ deđerinin altında kalan ve $Q3 + 1.5 \times IQR$ deđerinin stnde kalan veriler aykırı veri olarak adlandırılmaktadır.

IQR yntemi ile aykırı veriler tespit edildikten sonra aykırı deđerler bulunduđu znelik deđerlerinin aritmetik ortalaması ile doldurularak tamamlanmıřtır.

2.2.3. Sınıf Dengesizliđi Problemi

Sınıf dengesizliđi, bir veri setindeki sınıf deđerlerinin rnek sayısı bakımından dengesiz bir dađılıma sahip olması řeklinde aıklanabilir [9, 22]. Sınıf dengesizliđi bulunan veri setlerinde makine đrenmesi algoritmaları taraflı bir performans sergileyebilir. ođunluk sınıfı rneđinin ok olması nedeniyle model, azınlık sınıfını ayırt edememekte ve bylece eksik đrenme veya ařırı đrenme gibi problemler meydana gelerek model bařarısı olumsuz ynde etkilenmektedir [23].

Ařırı yeniden rnekleme, melez yeniden rnekleme, sentetik yeniden rnekleme ve eksik yeniden rnekleme yntemleri literatrde sınıf dengesizliđi problemini zlemek iin nerilen yntemlerdir [9].

Bu alıřmada sentetik yeniden rnekleme yntemlerinden olan SMOTE yntemi kullanılmıřtır. Sentetik yeniden rnekleme, adından da anlaşılacađı zere azınlık sınıfı rnekleri zerinde keřif yaparak yeni yapay rnekler retme yntemidir [9, 23]. Ařırı yeniden rnekleme ynteminden farklı olarak rnekleri dođrudan kopyalamaması; ıkarımlar ile yeni yapay rnekler oluřturması ařırı đrenme riskini azaltmaktadır. SMOTE, veri setindeki azınlık sınıfına ait rneklerden benzer formdaki rnekleri seme ve bu rnekler arasında sentetik veri noktaları oluřturarak yapay rnek retimine dayanan bir yntemdir [9, 23, 24]. zellikle, tıbbi tanı veri setlerinde bařarılı bir řekilde kullanılmaktadır.

2.2.4. Normalizasyon

Veri setlerinde yer alan bazı znelikler farklı deđer aralıklarına sahip olabilmektedir. izelge 2'de sunulan Hepatit veri setine ait aralık deđerlerine bakıldıđında, znelikler arasında farklılıklar olduđu dikkat ekmektedir. zellikle sınıflandırma algoritmalarının bařarısında bylesine farklı ve u deđer aralıkları model performansını olduka etkilemektedir. Veri setindeki tm verileri matematiksel yntemler kullanarak yeniden dzenleme iřlemi normalizasyon olarak adlandırılmaktadır [10]. Hepatit veri setinde Min-Max Normalizasyonu yntemi kullanılmıřtır. Bahsi geen yntemin matematiksel forml Denklem 1'de verilmiřtir.

$$x_{yeni} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Min-max yntemi; literatrde sıklıkla kullanılan, basit ve znelikleri belirli bir deđer aralıđında yeniden leklendirmeyi sađlayan bir normalizasyon yntemidir [25, 26]. Bu yntemle veriler [0,1] aralıđında yeniden leklendirilir. Denklem 1'de $\max(x)$ ve $\min(x)$ sırasıyla ilgili znelik iin maksimum ve minimum deđerleri ifade etmektedir. x , leklendirilecek verinin mevcut deđer; x_{yeni} leklendirme iřlemi sonucu elde edilen [0,1] aralıđındaki yeni veri deđerini temsil etmektedir.

2.2.5. zellik Seimi

Bazı veri setlerinde doğrudan sonucu etkilemeyen alakasız/gereksiz öznitelikler bulunmaktadır. Bu tür özelliklerin varlığı işlem süresini uzatma, gereksiz bellek kullanımı, gereksiz özellik nedeniyle model başarısını etkileme gibi sorunlara yol açabilmektedir [10, 27, 28]. Özellik seçimi, veri setindeki sonucu doğrudan etkilemeyen alakasız/gereksiz özellikleri kaldırarak; veri setini en iyi şekilde temsil eden özellik alt kümesini bulma işlemidir [1, 29].

Özellik seçimi yöntemleri, kendi içerisinde üç başlık altında incelenmektedir. Filtre yöntemleri, herhangi bir öğrenme veya sınıflandırma algoritması kullanmadan; verilerin genel özelliklerine bakarak özelliğın seçilip/seçilmemesine karar veren yöntemlerdir. Sarmalayıcı yöntemler, öğrenme veya sınıflandırma algoritması kullanarak; özelliğın seçilip/seçilmemesine karar veren ve değerlendiren yöntemlerdir. Gömülü yöntemler ise filtre ve sarmalayıcı yöntemlerin bir birleşimi olarak düşünülebilir [2, 30].

Bu çalışmada Hepatit veri seti üzerinde sarmalayıcı yöntemlerden olan Ardışık Öznitelik Seçimi (*Sequential Backward Selection, SBS*) yöntemi kullanılmıştır. SBS, veri setindeki her bir özelliğın teker teker elenmesi mantığına dayanan ve her aşamada model performansını dikkate alarak eleme işlemini gerçekleştiren bir özellik seçim yöntemidir [31, 32]. Yöntemin, özellikleri teker teker ele alarak değerlendirmesi hem karmaşıklığı azaltma hem de aşırı öğrenmeden kaçınma noktasında oldukça önemlidir.

2.3. Performans Belirleme Ölçütleri

Hepatit veri seti üzerinde gerçekleştirilen her bir veri ön işleme tekniğı sonrası oluşan yeni veri seti literatürde sıklıkla kullanılan K-En Yakın Komşu (*K-Nearest Neighbors, KNN*), Lojistik Regresyon (*Logistic Regression, LR*), Rastgele Orman (*Random Forest, RF*), Destek Vektör Makinesi (*Support Vector Machine, SVM*) ve Yapay Sinir Ağları (*Artificial Neural Network, ANN*) makine öğrenmesi algoritmalarıyla sınıflandırma işlemine uygulanmıştır. Bu yöntemlerin ve veri ön işleme tekniklerinin model başarısına etkisini belirlemek adına literatürde sıklıkla başvurulan performans belirleme ölçütleri kullanılmıştır.

Kullanılan makine öğrenmesi yöntemleri için veri seti %70 oranında eğitim %30 oranında test veri kümelerine ayrılmıştır. *KNN* algoritmasında k değeri 5 olarak belirlenmiştir. *ANN*'de giriş katmanındaki nöron sayısı ilgili adımda oluşan veri setinin özellik sayısına eşit olacak şekilde, gizli katmandaki nöron sayısı; n giriş katmanındaki nöron sayısı olmak üzere $2n+1$ şeklinde ve çıkış katmanındaki nöron sayısı ise veri setindeki sınıf sayısına bağlı olmak şartıyla 1 olarak belirlenmiştir. *RF* algoritmasında ağaç sayısı 100 olarak belirlenmiştir.

Karmaşıklık Matrisi (*Confusion Matrix, CM*), sınıflandırma problemlerinde bir modelin tahminleri ile gerçek değerlerini kıyaslayarak; doğru ve hatalı tahmin sayılarını gösteren bir performans belirleme yöntemidir. *CM* sonucu elde edilen veriler ile model performansını değerlendirmek için kullanılan 4 önemli ölçütün hesabı yapılabilmektedir. Bunlar; doğruluk (*accuracy*), hassasiyet (*precision*), duyarlılık (*recall/sensitivity*) ve F_1 -skoru (F_1 -Score) ölçütleridir [33].

Bu çalışmada bahsi geçen beş makine öğrenmesi algoritmasının performans değerlendirmesi doğruluk, hassasiyet, duyarlılık ve F_1 -skoru ölçütleri kullanılarak yapılmıştır. Bahsi geçen dört performans belirleme ölçütünün matematiksel formülleri Denklem 2-5'te sunulmuştur [10].

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Recall/Sensitivity} = \frac{TP}{TP + FN} \quad (4)$$

$$F_1 - \text{score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

Denklemlerde sunulan *TP* (*True Positive, Doğru Pozitif*) terimi, doğru tahmin edilen hayatta kalan hepatit hastalarının sayısını belirtmektedir. Örnek olarak, gerçekten hayatta kalan bir hastanın model tarafından hayatta kalan olarak sınıflandırılması verilebilir. *FP* (*False Positive, Yanlış Pozitif*) terimi, yanlış tahmin edilen hayatta kalan hepatit hastalarının sayısını belirtmektedir. Örnek olarak, aslında ölü olan bir hastanın model tarafından yanlışlıkla hayatta kalan olarak sınıflandırılması verilebilir. *FN* (*False Negative, Yanlış Negatif*) terimi, yanlış tahmin edilen ölü hepatit hastalarının sayısını belirtmektedir. Örnek olarak, aslında hayatta kalan bir hastanın model tarafından yanlışlıkla ölü olarak sınıflandırılması verilebilir. *TN* (*True Negative, Doğru Negatif*) terimi, doğru tahmin edilen ölü hepatit hastalarının sayısını belirtmektedir. Örnek olarak, gerçekten ölü olan bir hastanın model tarafından ölü olarak sınıflandırılması verilebilir.

Dođruluk (*accuracy*) ölçütü, modelin tüm tahminlerinin doğru olma oranını gösterir. Modelin doğru sınıflandırma oranını ölçerek genel başarı düzeyini değerlendirmeye yarar. Bu ölçüt, tüm pozitif ve negatif sınıflandırmaların doğru tahmin edilip edilmediđine odaklanır.

Hassasiyet (*precision*) ölçütü, modelin "hayatta kalan" olarak sınıflandırdığı hastaların gerçekten hayatta kalma durumunu ifade eder. Yanlış pozitiflerin azaltılmasına odaklanır ve modelin dođruluđunu artırır. Hasta verisinde hassasiyet, modelin hayatta kalan olarak sınıflandırdığı hastaların gerçekten hayatta kalanların oranını gösterir.

Duyarlılık (*recall/sensitivity*) ölçütü, modelin gerçekten hayatta kalan hastaları dođru bir şekilde "hayatta kalan" olarak sınıflandırma oranını gösterir. Yanlış negatiflerin azaltılmasına odaklanır. Hasta verisinde duyarlılık, modelin hayatta kalan hastaları kaçırmadan dođru sınıflandırma yeteneđini gösterir.

F_1 -skoru (F_1 -score) ölçütü, hassasiyet ve duyarlılıđın harmonik ortalaması olarak hesaplanır. Modelin "hayatta kalan" sınıfını tespit etmedeki genel dengesini ifade eder ve özellikle dengesiz veri kümelerinde faydalıdır. Hasta verisinde F_1 -skoru, hassasiyet ve duyarlılık deđerleri arasında bir denge sađlayarak modelin genel sınıflandırma başarısını ifade eder.

3. Deneysel Sonular

Bu bölümde, her bir veri ön işleme tekniđi sonrası elde edilen yeni veri seti üzerinde *KNN*, *LR*, *RF*, *SVM* ve *ANN* algoritmaları tarafından yapılan sınıflandırma işleminde elde edilen sonuçlar yer almaktadır.

Çizelge 3'te; eksik deđerlerin yer aldığı örneklerin dođrudan veri setinden kaldırıldığı ve hiçbir veri ön işleme tekniđi uygulanmamış orijinal Hepatitis veri seti üzerinde gerçekleştirilen deney sonuçlarına yer verilmiştir. Veri setinden eksik deđerlerin yer aldığı örneklerin kaldırılması sonucu 80 adet örnek üzerinden ilgili işlemler yapılmıştır.

Çizelge 3'teki performans sonuçlarına bakıldığında, eksik veriler nedeniyle veri setindeki örnek sayısının azaldığı ve bunun da sınıflandırıcıların performansında tutarsızlıklara yol açtığı görülmektedir. Özellikle veri setinin dengesiz yapısı, bazı sınıflandırıcıların performansını olumsuz etkilemiştir. Örneđin, *RF* algoritması, genelde küçük ve dengesiz veri kümelerinde gösterdiği dayanıklılık nedeniyle diđer algoritmalara kıyasla daha iyi sonuçlar vermiştir. Buna karşılık, *SVM* algoritmasının düşük F_1 -skoruna sahip olması, dengesiz veri dağılımına uyum sađlayamamasından kaynaklanmakta ve modelin sınıflandırma başarısını düşürmektedir. *RF* algoritmasının, F_1 -skor dışında tüm ölçütlerde diđer

yöntemleri geride bırakması dikkat çekicidir. F_1 -skordaki düşüklüğün sebebi, sınıf dengesizliđi nedeniyle bazı algoritmaların belirli bir sınıfa ait örnekleri daha iyi tanimasından kaynaklanan eksik veya aşırı öğrenme olarak değerlendirilebilir. Bir yöntemin başarılı sayılabilmesi için tüm ölçütlerde tutarlı performans göstermesi önemlidir.

Çizelge 3. Orijinal Veri Kümesi Üzerinde Performans Sonuçları

Ölçüt/Algoritma	<i>KNN</i>	<i>LR</i>	<i>RF</i>	<i>SVM</i>	<i>ANN</i>
<i>Accuracy</i>	0.88	0.84	0.92	0.79	0.88
<i>Precision</i>	0.87	0.84	0.92	0.69	0.89
<i>Recall</i>	0.88	0.84	0.92	0.79	0.88
<i>F₁-score</i>	0.87	0.84	0.74	0.74	0.88

Çizelge 4'te eksik veri giderme işlemi sonrası oluşan yeni Hepatit veri seti üzerinde makine öğrenmesi yöntemlerinin performans sonuçları yer almaktadır. Burada dikkat edilmesi gereken husus; örnek sayısının orijinal halini alarak 155 olmasıdır.

Çizelge 4. Eksik Veri Giderme Sonrası Performans Sonuçları

Ölçüt/Algoritma	<i>KNN</i>	<i>LR</i>	<i>RF</i>	<i>SVM</i>	<i>ANN</i>
<i>Accuracy</i>	0.81	0.83	0.83	0.79	0.77
<i>Precision</i>	0.79	0.81	0.81	0.75	0.73
<i>Recall</i>	0.81	0.83	0.83	0.79	0.77
<i>F₁-score</i>	0.79	0.81	0.79	0.76	0.75

Çizelge 4'teki verilere bakıldığında, örnek sayısındaki artışın performans etkisi açıkça görülebilmektedir. Eksik veri giderme işlemi, veri setindeki örnek sayısını 155'e çıkararak daha fazla bilgi sağlamış, ancak bu artış bazı ölçütlerde olumlu etki yaratırken bazı ölçütlerde negatif bir etkiye yol açmıştır. Özellikle, örnek sayısının artmasıyla birlikte sınıf dengesizliğinin de artması, sınıflandırıcıların performansında dengesizliğe ve genel sınıflandırma başarısının düşmesine neden olmuştur. Bu gibi değişimler, veri setinin ihtiyaç duyduğu ön işleme tekniklerinin belirlenmesine katkı sağlamaktadır. Eksik veri giderme işlemi sonrasında *KNN*, *LR* ve *RF* algoritmalarının benzer performans göstermesi, artan örnek sayısının sınıflandırma dengesini olumlu etkilediğini göstermektedir. Ancak, özellikle *LR* ve *RF* algoritmalarında sınıf dengesizliđi nedeniyle sınıflandırma doğruluğunun optimal seviyeye ulaşamadığı gözlemlenmiştir. Eksik veri giderme işlemi ile örnek sayısı artsa da sınıf dengesizliđi sorunu performansı sınırlamaya devam etmektedir.

Çizelge 5'te sınıf dengesizliđi probleminin çözümü sonrası oluşan yeni Hepatit veri seti üzerinde makine öğrenmesi yöntemlerinin performans sonuçları yer almaktadır. Burada dikkat edilmesi gereken husus; azınlık sınıfına ait örnek sayısının artışıyla güncel örnek sayısının 246 olmasıdır.

Çizelge 5. Sınıf Dengesizliğini Giderme Sonrası Performans Sonuçları

Ölçüt/Algoritma	<i>KNN</i>	<i>LR</i>	<i>RF</i>	<i>SVM</i>	<i>ANN</i>
<i>Accuracy</i>	0.82	0.84	0.93	0.93	0.93
<i>Precision</i>	0.85	0.84	0.93	0.93	0.93
<i>Recall</i>	0.82	0.84	0.93	0.93	0.93
<i>F₁-score</i>	0.82	0.84	0.93	0.93	0.93

Çizelge 5'teki verilere bakıldığında, önceki iki adımdaki performans sonuçlarına kıyasla ciddi bir artış olduđu açıkça görölmektedir. Eksik veri giderme ve dengesiz veri probleminin çözümü sonrasında makine öğrenme yöntemleri, her iki sınıf hakkında dengeli bilgiye sahip olarak daha başarılı bir öğrenme ve sınıflandırma süreci geçirmektedir. Aksi halde, model yalnızca tek bir sınıfa yanlı davranabilir ve bu durum performans düşüşüne yol açabilir. Bu adımda dikkat edilmesi gereken bir diđer husus, her bir yöntemin tüm ölçütler için tutarlı sonuçlar elde etmesidir. *SMOTE* yöntemi ile sınıf dengesizliđi sorunu giderilmiş ve azınlık sınıfındaki örnek sayısı artırılmıştır. Bu adımın ardından *RF*, *SVM* ve *ANN* algoritmaları %93 doğruluk oranına ulaşarak dengeli bir veri setinin sınıflandırıcılar üzerindeki olumlu etkisini göstermiştir. Bu üç algoritmanın yüksek doğruluk ve tutarlı F1-skora sahip olması, *SMOTE* yönteminin sınıf dengesizliđi sorununu başarılı bir şekilde gidermiş ve model başarısını artırmış olduğunu kanıtlamaktadır. *KNN* ve *LR* algoritmalarının diđer algoritmalarından daha düşük performans göstermesi, komşuluk temelli algoritmaların dengesiz veri setlerinde daha hassas olması ile ilişkilendirilebilir.

Çizelge 6'da normalizasyon sonrası ölçeklendirilen yeni Hepatit veri seti üzerinde makine öğrenmesi yöntemlerinin performans sonuçları yer almaktadır.

Çizelge 6. Normalizasyon Sonrası Performans Sonuçları

Ölçüt/Algoritma	<i>KNN</i>	<i>LR</i>	<i>RF</i>	<i>SVM</i>	<i>ANN</i>
<i>Accuracy</i>	0.82	0.84	0.93	0.93	0.92
<i>Precision</i>	0.85	0.84	0.93	0.93	0.92
<i>Recall</i>	0.82	0.84	0.93	0.93	0.92
<i>F₁-score</i>	0.82	0.84	0.93	0.93	0.92

Çizelge 6'daki verilere bakıldığında, normalizasyon işlemi sonrasında makine öğrenmesi yöntemlerinin performans sonuçlarında belirgin bir deđişim olmadığı görölmektedir. Normalizasyon işlemi ile veri setindeki tüm özellikler aynı ölçeđe getirilmiştir. Böylece herhangi bir özelliđin model üzerinde aşırı etkili olmasının önüne geçilmiştir. Bu durum, sınıflandırma algoritmalarının genel performansına katkı sağlasa da Hepatit veri setinde özellikler arasında büyük ölçek farklılıkları bulunmadığından, performansta anlamlı bir deđişim yaratmamıştır. Çizelgeden de anlaşılacağı üzere, *KNN* ve *RF* algoritmaları normalizasyon sonrası daha tutarlı bir performans gösterirken, normalizasyonun *SVM* ve *ANN* üzerindeki etkisi sınırlı kalmıştır. Bu durum, Hepatit veri setinde ölçek farklılıklarının ciddi bir sınıflandırma sorunu oluşturmadığını ve normalizasyonun sınıflandırıcılar üzerindeki etkisinin göreceli olarak düşük olduğunu göstermektedir.

Çizelge 7'de aykırı veri tespiti sonrası elde edilen yeni Hepatit veri seti üzerinde makine öğrenmesi yöntemlerinin performans sonuçları yer almaktadır.

Çizelge 7. Aykırı Veri Tespiti Sonrası Performans Sonuçları

Ölçüt/Algoritma	<i>KNN</i>	<i>LR</i>	<i>RF</i>	<i>SVM</i>	<i>ANN</i>
<i>Accuracy</i>	0.81	0.79	0.85	0.81	0.83
<i>Precision</i>	0.80	0.77	0.87	0.77	0.81
<i>Recall</i>	0.81	0.79	0.85	0.81	0.83
<i>F₁-score</i>	0.80	0.78	0.81	0.78	0.79

Çizelge 7'deki verilere bakıldığında, aykırı veri tespiti sonrasında tüm yöntemlerin performansında gözlemlenen negatif etki dikkat çekmektedir. Veri setindeki aykırı deđerler, doğrudan sınıflandırma algoritmalarının performansını etkileyebilmektedir. Aykırı veri tespiti ve işlenmesi, veri setindeki aşırı deđerleri düzeltmeye odaklanmakta olup, bu işlem bazen veri setinin doğal varyansını azaltabilir veya verilerin temsil gücünü deđiştirebilir. Eđer aykırı deđerler, veri setinin önemli bir

parçasını oluşturuyorsa, bu değerlerin işlenmesi modelin gerçek dünya verilerini yorumlama yeteneğini olumsuz etkileyebilir. Aykırı veri tespiti sonrasında RF algoritması, diğer algoritmalara kıyasla en yüksek doğruluk oranını göstermiş olsa da genel olarak performans değerlerinde bir miktar düşüş gözlemlenmiştir. Bu düşüş, aykırı veri işleminin veri setinin doğal varyans ve temsil gücünde değişiklikler yaratması nedeniyle yaşanmış olabilir. Özellikle *SVM* ve *LR* algoritmalarında gözlemlenen performans düşüşü, aykırı veri işleminin bazı algoritmaların uyum yeteneğini olumsuz etkilediğini göstermektedir.

Çizelge 8’de özellik seçimi sonrası elde edilen yeni Hepatit veri seti üzerinde makine öğrenmesi yöntemlerinin performans sonuçları yer almaktadır. Özellik seçimi işlemi sonucunda *sex*, *steroid*, *antivirals*, *fatigue*, *LiverFirm*, *spleenPalpable*, *spiders*, *ascites*, *varices* ve *bilirubin* olmak üzere 10 adet öznelik bulunmaktadır.

Çizelge 8. Özellik Seçimi Sonrası Performans Sonuçları

Ölçüt/Algoritma	<i>KNN</i>	<i>LR</i>	<i>RF</i>	<i>SVM</i>	<i>ANN</i>
<i>Accuracy</i>	0.89	0.85	0.91	0.93	0.96
<i>Precision</i>	0.90	0.85	0.91	0.93	0.96
<i>Recall</i>	0.89	0.85	0.91	0.93	0.96
<i>F₁-score</i>	0.89	0.85	0.91	0.93	0.96

Çizelge 8’deki verilere bakıldığında, özellik seçimi sonrasında tüm yöntemlerin performansında kayda değer bir artış olduğu görülmektedir. Her bir sınıflandırma yöntemi farklı yapıya sahip olduğu için, uygulanan ön işleme tekniklerinin her yöntemde aynı etkiye sahip olmaması beklenebilir. Çizelge 3 ile Çizelge 8 arasında bazı adımlarda negatif sonuçlar gözlemlense de son durumda elde edilen performans artışı ve ölçütler arasındaki tutarlılık, veri ön işleme tekniklerinin sınıflandırma üzerindeki olumlu etkisini açıkça göstermektedir. Özellik seçimi sonrası *ANN*, *SVM* ve *RF* algoritmalarının %90’ın üzerinde doğruluk oranlarına ulaşması, alakasız özelliklerin çıkarılmasının model performansını iyileştirdiğini göstermektedir. Özellik seçimi ile gereksiz veri yükü azaltılmış ve modelin daha odaklanmış bir şekilde öğrenmesi sağlanmıştır. Özellikle *ANN* algoritmasının %96 doğruluk oranına ulaşması, özellik seçiminin çok katmanlı modellerin sınıflandırma başarısını artırmadaki potansiyelini vurgulamaktadır.

4. Sonuç ve Öneriler

Sağlık verileri, veri ön işleme tekniklerinin yoğun olarak kullanıldığı alanlardan biridir. Bu verilerde en sık karşılaşılan sorunlar, eksik veri, sınıf dengesizliği ve aykırı değerlerdir. Bu tür sorunlar, sınıflandırma işlemlerinde makine öğrenmesi algoritmalarının başarısını olumsuz etkileyebilir. Bu nedenle, sağlık verilerinin analizi ve sınıflandırılması öncesinde kapsamlı bir veri ön işleme süreci uygulamak büyük önem taşır.

Bu çalışmada, karaciğer iltihaplanması (hepatit) hastalığına ait bir sınıflandırma veri seti üzerinde kapsamlı veri ön işleme adımları uygulanarak eksik veri giderme, dengesiz veri seti problemi, aykırı veri tespiti, normalizasyon ve özellik seçimi tekniklerinin sınıflandırma performansına olan etkisi incelenmiştir. Her bir veri ön işleme adımı sonrasında veri seti, *KNN*, *LR*, *RF*, *SVM* ve *ANN* algoritmaları ile sınıflandırılmış ve doğruluk, hassasiyet, duyarlılık ve *F₁-skoru* ölçütlerine göre performans değerlendirilmiştir.

Deneysel sonuçlar, veri ön işleme tekniklerinin tüm sınıflandırma algoritmaları üzerinde genel olarak olumlu bir etkiye sahip olduğunu göstermiştir. Özellikle sınıf dengesizliği giderildikten ve aykırı veri tespiti yapıldıktan sonra *RF*, *SVM* ve *ANN* algoritmalarında %93 doğruluk oranına ulaşılmış ve genel performansta tutarlı bir artış sağlanmıştır. Bununla birlikte, eksik veri giderme ve normalizasyon

gibi tekniklerin etkisinin veri setinin özelliklerine göre deđişkenlik gösterdiği, sınıflandırma algoritmalarının performansında farklı derecelerde etki yarattığı gözlemlenmiştir.

Eksik veri giderme, veri setindeki örnek sayısını artırarak modelin daha fazla bilgiye dayalı öğrenmesini sağlamıştır. Ancak, özellikle sınıf dengesizliği sorunu olan veri setlerinde eksik verinin doldurulması, sınıflandırıcıların performansını sınırlayabilir. Aykırı veri tespiti, veri setinin doğal varyansını azaltarak sınıflandırıcılar üzerinde yanlılığı azaltmıştır. Bununla birlikte, bazı aykırı veriler veri setinin önemli bir parçası olabileceğinden, bu adım performansta beklenmedik düşüöşlere neden olabilir. SMOTE yöntemi ile sınıf dengesizliği giderilmiş ve modelin her iki sınıf hakkında dengeli bir öğrenme süreci geçirmesi sağlanmıştır. Bu adım, tüm algoritmalarda belirgin bir performans artışı sağlamış, özellikle *RF*, *SVM* ve *ANN* algoritmalarında yüksek doğruluk oranlarına ulaşılmıştır.

Özelliklerin aynı ölçüğe getirilmesi ile bazı algoritmaların performansında tutarlılık sağlanmıştır. Ancak, veri seti özelliklerinin başlangıçta ölçek olarak yakın olduğu durumlarda normalizasyonun etkisi sınırlı kalmıştır. Özellik seçimi ile veri setinden gereksiz öznitelikler çıkarılmış ve modelin öğrenme sürecine odaklanarak daha başarılı sonuçlar elde edilmiştir. Özellikle *ANN* algoritmasının %96 doğruluk oranına ulaşması, özellik seçiminin model performansına olumlu katkısını göstermektedir.

Bu çalışmanın sonucunda elde edilen bulgular, veri ön işlemenin özellikle sağlık veri kümelerinde sınıflandırma başarısını artırmada kritik bir rol oynadığını ve tüm adımların üst üste ardışık uygulanmasının model performansını büyük ölçüde iyileştirdiğini ortaya koymaktadır.

Bu çalışma kapsamında her bir ön işleme adımında tek bir yöntem tercih edilmiştir. Eksik veri gidermede ortalama ile doldurma yöntemi; aykırı veri tespitinde IQR yöntemi, dengesiz veri gidermede SMOTE yöntemi, normalizasyon kısmında min-max ölçeklendirme yöntemi ve son olarak özellik seçiminde SBS yöntemi kullanılmıştır. Gelecek çalışmalar için bunlar dışında kalan diğer ön işleme teknikleri kullanılabilir ve performans kıyaslaması yapılabilir. Aynı şekilde çalışmada kullanılan *KNN*, *LR*, *RF*, *SVM* ve *ANN* makine öğrenmesi yöntemleri dışında diğer sınıflandırma yöntemleri de tercih edilerek model başarıları tespit edilebilir.

Katkı Beyanı

Yazarların çalışmadaki katkı içerikleri aşağıda belirtilmiştir.

Feyza Erdođan: Literatür taraması, yöntemlerin belirlenmesi ve uygulanması, makale yazımı

Vahit Tongur: Yöntemlerin belirlenmesi, bulguların yorumlanması, makale yazımı,

Betül Uzbař: Araştırma tasarımı ve fikir, bulguların yorumlanması

Çıkar Çatışması Beyanı

Makale yazarları herhangi bir kurum, kuruluş, kişi ile kişisel ve finansal çıkar çatışması olmadığını beyan etmektedirler.

Kaynaklar

- [1] Erdođan F. İkili gri kurt optimizasyon algoritmasının ikili optimizasyon problemlerine uygulanması. Yüksek lisans tezi. Konya: Necmettin Erbakan Üniversitesi; 2023.
- [2] Li J, Cheng K, Wang S, Morstatter F, Trevino RP, Tang J, Liu H. Feature selection: A data perspective. *ACM Computing Surveys (CSUR)* 2017; 50(6): 1-45.
- [3] Dogan A, Birant D. Machine learning and data mining in manufacturing. *Expert Systems with Applications* 2021; 166: 1-22.

- [4] Ođuzlar A. Veri ön iřleme. Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakóltesi Dergisi 2003; 21: 67-76.
- [5] Nart A. Kalp hastalıklarını tahmin etmede veri madenciliđi teknikleriyle etkili algoritmanın tespit edilmesi. Yüksek lisans tezi. Ankara: Gazi Üniversitesi; 2023.
- [6] García S, Luengo J, Herrera F. Data preprocessing in data mining. 72 Cham, Switzerland:Springer; 2015.
- [7] García S, Ramírez-Gallego S, Luengo J, Benítez JM, Herrera F. Big data preprocessing: methods and prospects. Big Data Analytics 2016; 1: 1-22.
- [8] Zelaya CVG. Towards explaining the effects of data preprocessing on machine learning. In: IEEE 35th International Conference on Data Engineering (ICDE), Macau SAR, China; 2019.
- [9] Özođur HN, Orman Z. Sađlık verilerinin analizinde veri ön iřleme adımlarının makine öđrenmesi yöntemlerinin performansına etkisi. Türkiye Biliřim Vakfı Bilgisayar Bilimleri ve Mühendisliđi Dergisi 2023; 16(1): 23-33.
- [10] Saygın E, Baykara M. Karaciđer yetmezliđi teřhisinde özellik seçimi kullanarak makine öđrenmesi yöntemlerinin başarılarının ölçülmesi. Fırat Üniversitesi Mühendislik Bilimleri Dergisi 2021; 33(2): 367-377.
- [11] Nahzat S, Yađanođlu M. Diabetes prediction using machine learning classification algorithms. Avrupa Bilim ve Teknoloji Dergisi 2021; 24: 53-59.
- [12] Mitra M, Samanta RK. A study on UCI hepatitis disease dataset using soft computing. Model. Meas. Control C 2017; 78(4): 467-477.
- [13] Orooji A, Kermani F. Machine learning based methods for handling imbalanced data in hepatitis diagnosis. Frontiers in Health Informatics 2021; 10: 1-6.
- [14] Bache K, Lichman M. UCI machine learning repository. University of California, Irvine, School of Information and Computer Sciences 2013.
- [15] UCI Machine Learning Repository. <https://doi.org/10.24432/C5Q59J> (Eriřim tarihi: 21.12.2024).
- [16] Rosly R, Makhtar M, Awang MK, Awang MI, Rahman MNA. Analyzing performance of classifiers for medical datasets. International Journal of Engineering & Technology 2018; 7: 136-138.
- [17] Boukerche A, Zheng L, Alfandi O. Outlier detection: Methods, models, and classification. ACM Computing Surveys (CSUR) 2020; 53(3): 1-37.
- [18] Alimohammadi H, Chen SN. Performance evaluation of outlier detection techniques in production timeseries: A systematic review and meta-analysis. Expert Systems with Applications 2022; 191: 1-10.
- [19] Xu H, Zhang L, Li P, Zhu F. Outlier detection algorithm based on k-nearest neighbors-local outlier factor. Journal of Algorithms & Computational Technology 2022; 16: 1-12.
- [20] Dash CSK, Behera AK, Dehuri S, Ghosh A. An outliers detection and elimination framework in classification task of data mining. Decision Analytics Journal 2023; 6: 1-8.
- [21] Fredianto F, Putri DAP. Comparison of the interquartile range algorithm and local outlier factor on Australian weather data sets. In: Proceeding of International Summit on Education, Technology, and Humanity 2021, Surakarta, Indonesia; 2021.
- [22] Bölükbařı İB. Dengesiz bir diyabet veri setinde makine öđrenmesi yöntemlerini kullanarak diyabet hastalıđının teřhisi. Yüksek lisans tezi. Bursa: Uludağ Üniversitesi; 2023.
- [23] Dablain D, Krawczyk B, Chawla NV. DeepSMOTE: Fusing deep learning and SMOTE for imbalanced data. IEEE Transactions on Neural Networks and Learning Systems 2022; 34(9): 6390-6404.
- [24] Pradipta GA, Wardoyo R, Musdholifah A, Sanjaya INH, Ismail M. SMOTE for handling imbalanced data problem: A review. In: Sixth international conference on informatics and computing (ICIC) Jakarta, Indonesia; 2021.
- [25] Henderi H, Wahyuningsih T, Rahwanto E. Comparison of Min-Max normalization and Z-Score Normalization in the K-nearest neighbor (kNN) Algorithm to Test the Accuracy of Types of Breast Cancer. International Journal of Informatics and Information Systems 2021; 4(1): 13-20.
- [26] Yavuz S, Deveci M. İstatiksel normalizasyon tekniklerinin yapay sinir ađın performansına etkisi. Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakóltesi Dergisi 2012; (40): 167-187.
- [27] Dash M, Liu H. Feature selection for classification. Intelligent data analysis 1997; 1(1-4): 131-156.

- [28] Kumar V, Minz S. Feature selection: A literature review. *Smart Computing Review* 2014; 4: 211–229.
- [29] Al-Wajih R, Abdulkadir SJ, Aziz N, Al-Tashi Q, Talpur N. Hybrid binary grey wolf with Harris hawks optimizer for feature selection. *IEEE Access* 2021; 9: 31662-31677.
- [30] Agrawal P, Ganesh T, Mohamed AW. Chaotic gaining sharing knowledge-based optimization algorithm: An improved metaheuristic algorithm for feature selection. *Soft Computing* 2021; 25(14): 9505-9528.
- [31] Alnowami MR, Abolaban FA, Taha E. A wrapper-based feature selection approach to investigate potential biomarkers for early detection of breast cancer. *Journal of Radiation Research and Applied Sciences* 2022; 15(1): 104-110.
- [32] Yao G, Hu X, Wang G. A novel ensemble feature selection method by integrating multiple ranking information combined with an SVM ensemble model for enterprise credit risk prediction in the supply chain. *Expert Systems with Applications* 2022; 200: 1-23.
- [33] Cengil E, Çınar A. Göğüs verileri metrikleri üzerinden kanser sınıflandırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi* 2020; 11(2): 513-519.

ANN KULLANARAK ÇELİK FİBERLİ GEOPOLİMER BETONLARIN EĞİLME DAYANIMININ TAHMİNİ

Necip Altay EREN*

Gaziantep Üniversitesi, İslahiye MYO, İnşaat Bölümü, Gaziantep, 27800, Türkiye

Geliş Tarihi/Received Date: 24.04.2024 Kabul Tarihi/Accepted Date: 28.11.2024 DOI: 10.54365/adyumbd.1473171

ÖZET

Geopolimer mekanik özellikler, işlenebilirlik ve uzun süreli kullanımdan sonra dayanıklılıktaki iyi performansları nedeniyle birçok inşaat alanında incelenmiş ve uygulanmıştır. Geopolimer betonun eğilme dayanımının belirlenmesi için genellikle pahalı laboratuvar testleri gerekmektedir. Bu çalışmanın amacı eğilme dayanımını daha hızlı, doğru, ucuz ve zahmetsiz tahmin edilmesidir. Yapay zekanın geliştirilmesi, deneysel veriler aracılığıyla beton yapıların performansını verimli bir şekilde tahmin edebilen ve belirleyebilen bazı yöntemler önermektedir. Bu çalışmada, makine öğrenimi ile çelik fiber takviyeli geopolimer betonların eğilme dayanım performansının tahmini ve doğrulanması değerlendirilmiştir. Literatürdeki geopolimer betonun eğilme dayanımına ilişkin çalışmalarda deneysel veriler kullanılarak toplamda 104 deney verisi içeren bir veri seti oluşturulmuş ve modellemeye hazır hale getirilmiştir. Bu veri seti, Yapay Sinir Ağı yöntemi kullanılarak Python programlama diliyle modellenmiş ve analiz edilmiştir. Yapılan çalışma sonucunda R^2 değeri 0,994183 olarak elde edilmiştir. Bu sonuçlar, Yapay Sinir Ağı modelinin çelik fiberli geopolimer betonun eğilme dayanımını tahmin etmede oldukça başarılı olduğunu göstermektedir. Sonuç olarak, yapay zekâ teknikleri eğilme dayanım sonuçlarının daha hızlı tahmin edebilecek ve maliyetleri önemli ölçüde azaltacak imkânlar sunmaktadır. Bu çalışmanın bulguları, inşaat sektöründe gelecekteki araştırma ve uygulamalar için umut verici bir yöntem sunmaktadır.

Anahtar Kelimeler: Geopolimer, Eğilme Dayanımı, Yapay Sinir Ağı, Çelik Fiber

ESTIMATION OF FLEXURAL STRENGTH OF STEEL FIBER GEOPOLYMER CONCRETE USING ANN

ABSTRACT

Geopolymer has been studied and applied in many construction areas due to its good performances in mechanical properties, workability and durability after long-term use. Expensive laboratory tests are usually required to determine the flexural strength of geopolymer concrete. The aim of this study is to estimate the flexural strength more quickly, accurately, cheaply and effortlessly. The development of artificial intelligence suggests some methods that can efficiently predict and determine the performance of concrete structures through experimental data. In this research, the flexural strength performance prediction and verification of steel fiber reinforced geopolymer concretes were evaluated with machine learning. A data set containing a total of 104 experimental data was created using experimental data from studies on the flexural strength of geopolymer concrete in the literature and made ready for modeling. This data set was modeled and analyzed with the Python programming language using the Artificial Neural Network method. As a result of the study, the R^2 value was obtained as 0.994183. These results show that the Artificial Neural Network model is quite successful in predicting the flexural strength of steel fiber geopolymer concrete. In conclusion, artificial intelligence techniques offer the opportunity to predict flexural strength results faster and significantly reduce costs. The findings of this study provide a promising method for future research and applications in the construction industry.

Keywords: Geopolymer, Flexural Strength, ANN, Steel Fiber

* *e-posta¹ : altayeren@gantep.edu.tr ORCID ID: <https://orcid.org/0000-0003-1421-4619>

1. Giriş

Geleneksel beton, dünyada sudan sonra en çok kullanılan ikinci malzemedir. Çimento, beton üretimi için önemli bir malzemedir. Ancak çimento üretimi sırasında CO₂ yayılır, bu da atmosferdeki sera gazı etkisini artırır [1]. CO₂ yayılımının %54'ü çimento üretimi sırasında ortaya çıkan kalsinasyona ve %46'sı yakıtların yakılmasından kaynaklanıyor [2]. Ayrıca inşaat sektöründe beton kullanımı giderek artmaktadır. Bunda dolayı artan CO₂ emisyonunu azaltmak için inşaat sektöründeki uygulamalarında geleneksel çimento kullanımının azaltılması giderek daha önemli hale gelmektedir. Bundan dolayı ,bu çevresel kaygıyı azaltmak için inşaat sektöründe daha çevre dostu malzemelere olan ihtiyaç giderek artmaktadır ve bu da yenilikçi alternatif malzemelere yönelik araştırmalara neden olmaktadır. Geopolimer Beton (GPB), gelecek vaat eden daha çevre dostu özelliklere sahip alternatif bir malzeme olarak ortaya çıkmaktadır. GPB metakaolin, cüruf, uçucu kül gibi bol miktarda alümina silikat malzemesi kaynağı ile kombinasyon halinde alkalın bir çözelti kullanılarak üretilmektedir. Bu yaklaşım sadece çimento üretimiyle ilişkili karbon ayak izini azaltmakla kalmıyor, aynı zamanda inşaat projeleri için de sürdürülebilir bir çözüm sunmaktadır. Bu düşüncelerden dolayı, GPB son yıllarda büyük ilgi görmektedir ve giderek geleneksel Portland çimentosuna alternatif bir malzeme olarak kabul edilmektedir [3-5]. Geopolimer farklı şekillerde üretilebilir, yüksek yakıt maliyeti ve yüksek sıcaklıkta fırın gerektirmez. Geopolimer için gerekli kaynaklar oldukça fazladır. Bu nedenle geopolimer kullanımı malzeme ve fabrika yatırımı gerektirmez. Düşük CO₂ emisyonlu geopolimer kullanımı çevre dostu olmasının yanı sıra inşaat sektörü ve beton sektörünün CO₂ emisyonlarını da %80 oranında azaltmaktadır [6]. Ayrıca, betonun eğilme dayanımını belirlenmesi için genellikle pahalı laboratuvar testleri gerekmektedir. Eğilme dayanımını daha hızlı, doğru, ucuz ve zahmetsiz tahmin edilmesi gerekmektedir. Bundan dolayı yapay zekâ teknikleri, beton gibi malzeme testlerinde harcanan zaman, emek ve maliyetten tasarruf sağlayarak sürdürülebilir inşaatla katkı sağlayabilir. Çeşitli makine öğrenme algoritmaları yardımıyla tahmin modelleri geliştirilerek betonun özellikleri belirlenebilir [7].


Beton alanında gerçekleştirilen bir diğer çağdaş gelişme ise fiber takviyeli betondur. Fiberin kullanılması, matrisin mekanik özelliklerini ve bütünlüğünü arttırdığı bulunmuştur. Beton içerisinde rastgele dağılan fiberler, betonda farklı aşamalarda oluşan çatlakların oluşmasını ve gelişmesini engeller, böylece içyapısında oluşan gerilimleri dağıtarak betonun enerji yutabilme kapasitesini artırır. Beton karışımında kullanılan fiberlerin etkinliği, fiberin en/boy oranına, geometrisine, çekme dayanımına, türüne ve kullanılan miktarına göre değişmektedir [8]. Beton karışımında kullanılan fiber çeşitlerinde biri Çelik fiberler (ÇF) dir. ÇF betonunun eğilme dayanıklılığını ve sünekliğini artırır. ÇF'lerin katkısı esas olarak betondaki matris çatlamasından sonra gözlemlenebilir, çünkü fiberler çatlakların ilerlemesine engel olur [9]. Bu nedenle, betonun kırılma dayanımı azalır ve enerji yutma kapasitesi artar.

Makine öğrenimi, insan etkileşimi olmadan öğrenme, akıl yürütme ve karar verme için veri kalıplarını ve yapılarını analiz eden ve yorumlayan bir hesaplamalı bilim alanı olan yapay zekânın bir parçasıdır. Bu noktada makine öğrenmesi, ÇF'li GPB'un eğilme dayanımını daha kısa sürede elde etmek için GPB'nun molaritesine, kullanılan ÇF miktarına, geometrik ve mekanik özelliklerine, ve numunenin geometrisi üzerinden GPB'un eğilme dayanımını tahmin edebilir. Bu çalışma, Yapay Sinir Ağları (ANN) modeli kullanılarak GPB'un eğilme dayanımını tahmininde uygulanabilirliğini keşfetmeyi amaçlamaktadır. ANN modeli oluşturmak için herhangi bir standart deneysel tasarım veya varsayım veya belirli bir denkleme ihtiyaç duymadan bilgileri hızla işleyen güçlü bir tahmin aracıdır [10]. ANN, düğümleri arasındaki sayısal ilişkiyi yakalar ve model içinde resmi bir formül kullanılmaz; ANN'lar, yönergeler ve veriler arasındaki ilişkilere göre eğitilir [11]. ANN, uygun uyum fonksiyonunun önceden belirlenmesine gerek kalmadan, ikinci dereceden fonksiyonlar da dahil olmak üzere hemen hemen her türlü doğrusal olmayan fonksiyonu tahmin etme evrensel yeteneğine sahiptir [12]. Bu araştırmadaki ANN modeli Python programlama dili kullanılarak oluşturulmuştur. Python, kolayca okunup uygulanabilecek şekilde tasarlanmış, açık kaynaklı, yüksek performanslı bir programlama dilidir [13].

GPB'nun eğilme dayanımının belirlenmesi için genellikle pahalı laboratuvar testleri gerekmektedir. Bu çalışmanın amacı, ÇF takviyeli GPB 'un eğilme dayanımını makine öğrenme algoritması kullanarak daha hızlı, doğru, ucuz ve zahmetsiz tahmin edilmesidir. Literatürde ÇF takviyeli GPB'un eğilme dayanım makine öğrenme teknikleri kullanarak tahmin etmek için çok az sayıda çalışma mevcuttur. Ayrıca, bu çalışma ÇF içeren GPB'nun eğilme dayanımını ANN kullanarak hızlı, doğru ve verimli bir tahmin modeli geliştirmektedir. Çalışma, GPB'nun çevre dostu yapısını ve çelik fiberlerin mekanik dayanım üzerindeki etkilerini inceleyerek, geleneksel yöntemlere kıyasla yenilikçi ve sürdürülebilir mühendislik çözümleri sunmayı hedefler. Ayrıca, daha dayanıklı ve çevresel açıdan avantajlı beton türlerinin geliştirilmesine, ve GPB kullanımının yaygınlaşmasına katkı sağlamayı amaçlar. Bu nedenle literatürde GPB'un eğilme dayanıklılığını araştıran çalışmalar kapsamlı incelenmiştir. Bu çalışmaların sonuçları, makine öğrenmesi algoritması olan ANN modeli için bağımlı ve bağımsız parametreler belirlendi. Belirlenen bu parametrelere göre incelenen çalışmalardan veriler toplanarak 104 veriden oluşan bir veri seti elde edildi. Elde edilen bu veri seti kullanılarak ANN modeli eğitildi. Bu model kullanılarak tahmin edilen sonuçlar, veri setindeki deneysel sonuçları ile karşılaştırılmıştır. Bulgular, makine öğrenimi algoritmasının, GPB'nun eğilme dayanımını doğru bir şekilde tahmin etmede önemli ölçüde umut vaat ettiğini göstermektedir.

2. Materyal ve Metod

Bu bölümde çalışmada kullanılan materyal ve yöntemler anlatılmıştır. Bu bağlamda öncelikle verilerin nasıl derlendiği ve hangi methodlar ile modellemeye hazır hale getirildiği açıklanmıştır. Daha sonra kullanılan makine öğrenmesi algoritmasından bahsedilmiştir. Son olarak modelin nasıl oluşturulduğuna ve sonuçlara yer verilmiştir. Çalışmanın stratejisini gösteren aşağıdaki grafik Şekil 1.'de gösterilmiştir.



Şekil 1. Çalışma yönteminin akış şeması

2.1. Veri Hazırlanması

Bir makine öğrenmesi modeli elde etmek için veri setinin kalitesi oldukça önemlidir ve ayrıca Makine öğrenimi modelleri temiz ölçülmüş veriler olmalıdır. Bu nedenle veri setinin doğru bir şekilde toplanması ve makine öğrenmesi modellerine uygun hale getirilmesi oldukça önemlidir. Bu amaçla


literatürde daha önce yapılan çalışmalar incelenmiş ve GPB numunelerinin eğilme dayanıklılığını inceleyen çalışmalardan toplam 104 veri içeren bir veri seti toplanmıştır ve elde edilen veri seti oluşturulurken kullanılan eğilme dayanımı değerleri Çizelge 1.'de verilmiştir. Ayrıca, GPB numunelerinin eğilme dayanımı da dahil olmak üzere tüm sayısal parametrelerin istatistiksel değerleri Çizelge 2.'de gösterilmiştir. Toplanan veri setinde eksik veriler mevcut olup, daha iyi bir sonuç elde etmek amacıyla bu veriler ortalama değerler kullanılarak belirlenmiştir. Ayrıca veri setine ait frekans dağılımı grafikleri Şekil 2.'de gösterilmiştir.

Çizelge 1. Veri seti oluşturulurken kullanılan eğilme dayanımı değerleri


Kaynaklar	Eğilme Dayanımı (MPa)	Kaynaklar	Eğilme Dayanımı (MPa)
[14]	3.1	[25]	4.43
	3.6		4.56
	4.3		3.21
[15]	1.23		4.69
	2.55		5.28
	4.23		5.52
	5.89		5.19
	6.82		6.08
[16]	8.48		6.72
	9.65		4.9
	7.02		5.6
	9.78		5.4
	10.22		4.8
	11.2		5.3
[17]	11.7		5.1
	12.4	7.83	
	12.8	8.47	
	13.3	9.25	
	13.7	10.58	
[18]	5.35	12.15	
	6.4	7.41	
	7.45	11.12	
	8.5	10.25	
	9.55	9.83	
[19]	3.297	6.57	
	3.858	9.42	
	4.971	8.13	
[20]	12.1	7.91	
	16	5.2	
	18.9	8.75	
[21]	3.89	12.53	
	6.13	4.88	
	6.72	9.06	
[22]	11	10.66	
	19	3.94	
	24	4.61	
	16.6	4.1	
	25.8	6.15	
	31.9	4.9	
	17.9	5.1	
	31.4	5.5	
	33.3	5.6	
	14.2	6.5	
20.7	6.8		
[23]	30.5	7.1	
	6	7.4	
	7.8	7.2	
[24]	8.4	1.38	
	3.35	1.75	
	3.95	1.59	
	4.16	20.6	
	4.05	1.86	
		1.84	

Çizelge 2. Veri setinin istatistiksel değerleri


	Veri Sayısı	Minimum Değer	Maximum Değer	Ortalama	Standard Sapma
ÇF Uzunluğu (mm)	104	6	61	30.29	17.56
ÇF En/Boy Oranı	104	25	125	64.27	25.5
ÇF Oranı (%)	104	0.25	5	1.6	1.22
ÇF Çekme Dayanımı	104	800	3000	1611.96	682.24
Numunenin Eni (mm)	104	40	150	90.08	22.11
Numunenin Yüksekliği	104	40	125	87.1	24.28
Numunenin Uzunluğu	104	100	515	379.52	143.17
Molarite (M)	104	1.125	14	8.21	4.76




(a)




(b)




(c)




(d)




(e)




(f)



(g)




(h)



(i)

Şekil 2. Veri setine ait frekans dağılımı grafikleri:(a) SF Uzunluğu, (b) SF En/Boy Oranı (c) SF %, (d) SF Çekme Dayanımı, (e) Numunenin Eni, (f) Numunenin Boyu, (g) Numunenin Uzunluğu, (h) Molarity, (i) Eğilme Dayanımı

Veri setinin bağımsız değişkenleri arasında Şekil 3.'te gösterildiği gibi korelasyonlar mevcuttur. Korelasyon katsayılarıyla analiz yapmak veri setinin anlaşılmasını kolaylaştırır. Bir korelasyon katsayısının sıfırdan büyük olması değişkenler arasında pozitif, sıfırdan küçük olması ise değişkenler arasında negatif bir ilişkinin olduğunu işaret eder. Ayrıca korelasyon katsayısının sıfır olması bu değişkenlerin bağımsız olduğu anlamına gelir. Eğer, korelasyon katsayısı 1'e eşit ise, değişkenler arasında mükemmel bir ilişkinin olduğunu gösterir.




Şekil 3. Veri setinin korelasyon katsayıları Isı Haritası

2.2. Yapay Sinir Ağları (ANN):


Yapay sinir ağı (ANN), insan beyninin yapısından ilham alan, birbirine bağlı unsurlardan oluşan bir hesaplama sistemidir. Özel bir öğrenme aşamasında sağlanan girdiler üzerinde eğitim alarak çıktıları tahmin etme yeteneğini kazanır [35]. Karmaşık doğrusal olmayan problemlerle başa çıkma potansiyeli yüksek olduğundan en yaygın kullanılan makine öğrenmesi modellerinden biridir [36]. ANN'nin ana görevi, tıpkı bir beyin nöronunun çalışma şekline benzer şekilde, sisteme verilen bir dizi girdiye yanıt olarak bir dizi çıktı üretmektir. Şekil 4.'te görüldüğü gibi ANN üç katmandan oluşur ve bu katmanlar bir araya gelerek sinir ağını oluşturur. ANN'ler girdi, çıktı ve gizli katmanlardan oluşur. İlk katman girdi katmanıdır ve veriler girdi katmanının aracılığıyla sisteme girer. Sonuçlarda çıktı katmanından elde edilir. Girdi ve çıktı katmanları arasında gizli katman vardır. Gizli katmanlar giriş ve çıkış katmanlarını birbirine bağlar. Birden fazla gizli katmana sahip bir sinir ağına çok katmanlı algılayıcı denir.

Bu araştırmadaki ANN modeli Python programlama dili kullanılarak oluşturulmuştur. Python, kolayca okunup uygulanabilecek şekilde tasarlanmış, açık kaynaklı, yüksek performanslı bir programlama dilidir [13]. Ayrıca çoklu işletim yazılımlarında kullanım açısından yüksek esneklik sağlar. Python, NumPy, Pandas, Keras ve TensorFlow gibi ANN modellerini oluşturmak için birleştirilmiş çok sayıda kütüphane içerir. Pandalar, NumPy'nin yüksek performanslı dizi bilişimini esnek elektronik tablo veri yönetimiyle birleştirerek Python'un veri analizi için güçlü bir araç olmasını sağlar [37]. Keras, ANN modellerini oluşturmak için kullanılan bir sinir ağı kütüphanesidir, TensorFlow ise makine öğrenimi görevlerini gerçekleştirmek için kullanılan kütüphanedir [38].



Şekil 4. Yapay sinir ağları işlem elemanı [39]

Ayrıca, ANN algoritması için giriş ve çıkış yol haritası Şekil 5.'te gösterilmiştir.



Şekil 5. ANN algoritması için giriş ve çıkış yol haritası

3. Araştırma Bulguları

Bu bölümde, performansların değerlendirilmesi amacıyla ortalama hata (test/tahmin), ortalama mutlak hata (MAE), ortalama karesel hata (MSE), kök ortalama kare hata (RMSE), korelasyon katsayısı (R) ve tanımlama katsayısı (R^2) değerleri hesaplanmıştır. Eğitilen modeli daha objektif bir şekilde değerlendirmek için ortalama hata değerinden yararlanılabilir. Ortalama hata değeri modelin yaptığı tahminlerin genel olarak gerçek değerden daha büyük mü yoksa daha küçük mü olduğunu anlamamıza yardımcı olur. Ortalama (test/tahmin) verebileceği en iyi sonuç 1'dir. Yani ortalama (test/tahmin) değeri 1'e yaklaştıkça modelin tahminleri de gerçek değerlere yaklaşmaktadır. Çizelge 3.'te eğitilen ANN modelinin ortalama (test/tahmin), MAE, MSE, RMSE, R ve R^2 değerleri gösterilmektedir. Bu değerlere göre; model oldukça etkileyici sonuçlar gösteriyor. MSE değeriniz 0,21255, yani model gerçek ve tahmin edilen değerler arasındaki ortalama karesel fark oldukça düşük. Benzer şekilde, MAE değeriniz 0,259399, yani gerçek ve tahmin edilen değerler arasındaki ortalama mutlak fark da oldukça düşük. Bu, modelin verilere oldukça yakın tahminlerde bulunduğunu gösterir. R^2 değeriniz oldukça yüksek, 0,994183. Bu, modelin bağımsız değişkenlerin açıkladığı toplam varyansın büyük bir kısmını açıkladığını gösterir. Yani, modelin verileri oldukça iyi uyduğu söylenebilir. RMSE değeriniz 4,22549. Bu, modelin hatalarının standart sapmasını gösterir. Düşük bir RMSE değeri, modelin tahminlerinin gerçek değerlere yakın olduğunu gösterir. R değeriniz 0,889114, yani gerçek ve tahmin edilen değerler arasında güçlü bir pozitif ilişki olduğunu gösterir. Bu, modelin tahminlerinin gerçek değerlerle güçlü bir şekilde uyumlu olduğunu gösterir. Son olarak, ortalama (test/tahmin) oranı 0,99872. Bu, test değerlerinin tahmin değerlerinden yaklaşık olarak %0,128 daha küçük olduğunu gösterir. Tüm bu değerler göz önüne alındığında, oluşturduğunuz modelin oldukça güvenilir ve doğru tahminler yaptığını

söyleyebiliriz. Bu sonuçlar, modelin veri setinizdeki desenleri iyi anladığını ve doğru bir şekilde tahmin ettiğini gösterir. Ayrıca, Çizelge 4’te modelde kullanılan test değerleri, modelin tahmin ettiği değerler ve test/tahmin oranları verilmiştir.


Çizelge 3. ANN Model değerlendirme metriklerine ait değerler

Model	Ortalama (Test/Tahmin)	MAE	MSE	RMSE	R	R ²
ANN	0.99872	0.2593	0.21255	4.250625	0.889114	0.994183

Çizelge 4. ANN Modeli için Test, Tahmin değerleri ve Test/Tahmin oranları

Test Değerleri	Tahmin Edilen Değerler	Test/Tahmin Oranı
93	94.16989136	0.9875768
58.41	61.7665863	0.945656924
35.92	32.76969528	1.096134697
47	42.85481644	1.0967262
42.86	34.11994934	1.256156613
42	40.61688232	1.034052778
40.95	33.75628662	1.213107368
23.81	33.70458984	0.706431976
53.45	55.64156342	0.960612835
38.1	38.97790527	0.977476848
53	56.64014435	0.935732079
150	151.5242157	0.989940778
54.32	52.16409302	1.041329329
144	148.1098022	0.972251653
89.5	92.71949768	0.965277016
74.97	68.0504303	1.101682968
38.57	36.56162643	1.054931188
61.5	58.09827423	1.058551236
70	60.0834465	1.165046349
77.8	74.36544037	1.046184889
38.46	38.31471634	1.00379185
38.46	38.101017	1.009421875
73.56	67.21195221	1.094448198
22.38	38.19934845	0.585873867
36.2	36.04360199	1.004339134
43.09	42.78999329	1.007011142
47.1	45.14181519	1.043378513
45.83	42.1729393	1.086715813
40.98	40.70159531	1.006840142
50.1	51.27976227	0.976993609
24.76	43.01924896	0.575556306
89	82.79144287	1.074990324
41.32	41.32405853	0.999901788
52.83	51.2417717	1.030994797
59.64	58.14741516	1.02566898
43.04	43.67703247	0.985414932
90.1	91.30731964	0.986777406
54.41	55.49445343	0.980458346
162	151.9851685	1.065893479
67.76	64.64296722	1.048219209
22.13	37.32938385	0.592830573
37.6	33.7326622	1.114646682
55.69	55.44241333	1.004465655
42.44	41.04401016	1.034012023

Şekil 6. ANN tarafından üretilen tahmin ayrıntılarını göstermektedir. Mavi çizgi gerçek verileri, kırmızı çizgi ise tahmin edilen verileri temsil eder. Aslında GPB'nun eğilme dayanımı gösteriyor ve iki çizgi genel olarak çok benzer, yani ANN ile yapılan tahmin modelinin çok doğru olduğu ve çok iyi çalıştığı anlamına geliyor.



Şekil 6. GPB'nun Eğilme Dayanımı tahmin grafiği

4. Sonuçlar

Bu çalışmanın konusu, çelik fiberli geopolimer betonun eğilme dayanımının ANN kullanılarak modellenmesi olmuştur. Geopolimer betonun geleneksel çimentolu betonun alternatifi olabileceği düşünüldüğünde, bu malzemenin özelliklerinin ve davranışlarının doğru bir şekilde modellenmesi oldukça önemlidir. Bu amaçla literatür kapsamlı incelenmiş ve modellemede kullanılacak olan veri seti oluşturulmuştur. ANN makine öğrenmesi algoritması kullanılarak model eğitilmiştir. Çalışma kapsamında, literatür kapsamlı bir şekilde incelenerek modelleme için uygun bir veri seti oluşturulmuştur. Ardından, ANN makine öğrenmesi algoritması kullanılarak bu veri setiyle bir model eğitilmiştir. Elde edilen model, farklı değerlendirme yöntemleri kullanılarak incelenmiş ve sonuçlar değerlendirilmiştir. Yapılan değerlendirmelerin sonucunda elde edilen bulgular ve öneriler aşağıdaki gibidir:

- Tahmin modelinin performansını değerlendirme yöntemlerinden biri modelin tanımlayıcılık katsayısıdır. R^2 değeri ANN modeli için 0,994183 olarak elde edilmiştir, yani ANN modeli %99,4183 doğrulukla tahmin yapmıştır. Buda, ANN modelinin eğilme dayanımının tahminlerinde başarılı sonuçlar verdiği görülmüş ve kullanılabilirliği test edilmiştir.
- Tahmin modellerinin performansını değerlendirmede kullanılan bir diğer yöntemde ortalama hata (ortalama (test/tahmin)) değerleridir. Ortalama hata değeri ANN modeli için 0.99872 olarak elde edilmiştir. Ortalama hata değeri 1 yaklaştıkça modelin daha doğru sonuç verdiği anlaşılır. ANN modelinin ortalama hata değeri 1 yakın olduğu için model iyi performans göstermiştir.
- ANN için RMSE değeri 4,250625'dur, bu da modelin tahminlerinin gerçek değerlere yakın olduğunu gösterirken, R değeriniz 0,889114'dir, bu da gerçek ve tahmin edilen değerler arasında güçlü bir pozitif ilişki olduğunu gösterir. Son olarak, ortalama (test/tahmin) oranı 0.99872'tür, bu da test değerlerinin tahmin değerlerinden yaklaşık %0,128 daha küçük olduğunu gösterir.
- Veri setinin korelasyon katsayıları ısı haritasına göre Numune Uzunluğu ve Numune Boyu arasında yüksek bir pozitif korelasyon görülmektedir. Ayrıca, Numune Eni ile Numune Boyu arasında yüksek bir pozitif ilişki bulunmaktadır. Buna ek olarak, Eğilme Dayanımı ile

Çekme Dayanımı arasında orta düzeyde bir pozitif ilişki bulunmaktadır. Bu iki dayanım özelliğinin kısmen ilişkili olduğunu ancak tamamen aynı şeyi ölçmediğini göstermektedir.

- Veri setinin korelasyon katsayıları ısı haritasına göre ÇF Uzunluğu ve ÇF Çekme Dayanımı arasında negatif bir korelasyon vardır. Bu, ÇF Uzunluğunun artmasının ÇF Çekme Dayanımını olumsuz etkileyebileceğini göstermektedir. Buna ek olarak, ÇF Uzunluğu ile Eğilme Dayanımı arasında da zayıf bir negatif korelasyon bulunur. Ayrıca, Molarity ile ÇF Çekme Dayanımı arasında düşük bir negatif korelasyon vardır. Bu, çözelti molaritesinin çekme dayanımı üzerindeki etkisinin belirgin olmadığını göstermektedir.
- Veri setinin korelasyon katsayıları ısı haritasına göre ÇF En/Boy Oranı ve diğer özellikler arasında genel olarak düşük korelasyon görülmektedir. Bu özelliğin diğerleriyle ilişkisinin zayıf olduğunu ve bağımsız bilgi sağlayabileceğini göstermektedir.
- Çelik fiberli geopolimer betonun eğilme dayanımının tahmininde ANN makine öğrenmesi algoritmasının başarılı sonuçlar verdiği ve modelin kullanılabilirliğinin test edildiği gözlemlenmiştir.
- ANN makine öğrenmesi algoritmasının tahmin ettiği değerlerin gerçek değerlere çok yakın olduğu gözlemlenmiştir. Bu yüzden geopolimer beton ile yapılacak yapıların maliyetleri önceden daha doğru belirlenebileceği öngörülmüştür.
- Kullanılan ANN'nin ve veri seti'nin özelliklerinin eğitilen modelin tahmin ettiği değerlerin üzerinde etki ettiği, ayrıca Python tabanlı programlama ile ANN makine öğrenmesi algoritmasının kurulumu ve kullanımının kolay olduğu sonucuna varılmıştır.
- Sunulan model yalnızca çelik fiberli geopolimer betonun eğilme dayanımını dikkate almıştır; farklı mekanik testler içeren daha büyük bir girdi veri seti, ANN modelinin tahmin yeteneğini arttırmak için kullanılabilir.

Kaynaklar

- [1] Niveditha M, Koniki S. Effect of Durability properties on Geopolymer concrete—A Review. E3S Web of Conferences EDP Sciences 2020; Vol. 184. <https://doi.org/10.1051/e3sconf/202018401092>
- [2] Eren NA. Punching shear behavior of geopolymer concrete two-way flat slabs incorporating a combination of nano silica and steel fibers. Construction and Building Materials 2022; Volume 346, 128351. <https://doi.org/10.1016/j.conbuildmat.2022.128351>
- [3] Bernal SA, Rodri'guez ED, Meji'a de Gutie'rrez R, Marisol Gordillo M, Provis JL. Mechanical and thermal characterisation of geopolymers based on silicate-activated metakaolin/slag blends. Journal of Materials Science 2011; volume 46, pages 5477–5486.
- [4] Davidovits J. Geopolymers and geopolymeric materials. Journal of thermal analysis, 1989; volume 35, pages 429–441.
- [5] Duxson P, Provis JL, Lukey GC, Deventer JSJ. The role of inorganic polymer technology in the development of 'green concrete'. Cement and Concrete Research 2007; 37 1590–1597.
- [6] Davidovits J. Properties of Geopolymer Cements. In First International Conference on Alkaline Cements and Concretes 1994; 131–149.
- [7] Deng F, He Y, Zhou S, Yu Y, Cheng H, Wu X. Compressive strength prediction of recycled concrete based on deep learning. Construction and Building Materials 2018; Vol. 175, pp. 562-569. <https://doi.org/10.1016/j.conbuildmat.2018.04.169>
- [8] Şimşek O. Beton ve Beton Teknolojisi, Seçkin Yayınevi, 2016; ISBN: 9789750261930, Türkiye.
- [9] Arunkumar K, Muthukannan M, Sureshkumar A. Experimental Behaviour of Fiber Reinforced Reactive Powder Concrete International Journal of Engineering and Advanced Technology (IJEAT) 2019; 9 (1S4) (2019) 454-459.
- [10] Aggarwal P, Aggarwal Y, Siddique R, Gupta S and Garg H. Fuzzy logic modeling of compressive strength of high-strength concrete (HSC) with supplementary cementitious material. Journal of Sustainable Cement-Based Materials, 2013; pp.1-16

- [11] Razavi SU, Jumaat MZ and El-Shafie AH. Load-deflection Analysis of CFRF strengthened RC slab using focused feedforward time delay neural network. *Concrete Research Letters*, 5(3), 2014; pp.858-872.
- [12] Moghaddam MG and Khajeh M. Comparison of Response Surface Methodology and Artificial Network in predicting microwave-assisted extraction procedure to determine zinc in fish muscles. *Food and Nutrition Sciences*, 2, 2011; pp.803- 808.
- [13] Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Duchesnay É. Scikit-learn: Machine learning in Python. *The Journal of Machine Learning Research*, 2011; 12, 2825-2830.
- [14] Gomes RF, Dias DP, Silva FA. Determination of the fracture parameters of steel fiber-reinforced geopolymer concrete, *Theoretical and Applied Fracture Mechanics*, 2020; Volume 107, <https://doi.org/10.1016/j.tafmec.2020.102568>
- [15] Ding Y, Bai YL. Fracture properties and softening curves of steel fiber-reinforced slag-based geopolymer mortar and concrete. *Materials* 2018; 11(8), 1445.
- [16] Pham KV, Nguyen TK, Le TA, Han SW, Lee G, Lee K. Assessment of performance of fiber reinforced geopolymer composites by experiment and simulation analysis. *Applied Sciences* 2019; 9(16), 3424.
- [17] Aisheh YIA, Atrushi DS, Akeed MH, Qaidi S, Tayeh BA. Influence of polypropylene and steel fibers on the mechanical properties of ultra-high-performance fiber-reinforced geopolymer concrete. *Case Studies in Construction Materials* 2022; 17, e01234.
- [18] Zhang P, Wang J, Li Q, Wan J, Ling Y. Mechanical and fracture properties of steel fiber-reinforced geopolymer concrete. *Science and Engineering of Composite Materials* 2021; 28(1), 299-313.
- [19] Sukontasukkul P, Pongsopha P, Chindaprasirt P, Songpiriyakij S. Flexural performance and toughness of hybrid steel and polypropylene fibre reinforced geopolymer. *Construction and Building Materials* 2018; 161, 37-44.
- [20] Liu Y, Shi C, Zhang Z, Li N, Shi D. Mechanical and fracture properties of ultra-high performance geopolymer concrete: Effects of steel fiber and silica fume. *Cement and Concrete Composites* 2020; 112, 103665.
- [21] Khan MZN, Hao Y, Hao H, Shaikh FUA. Mechanical properties of ambient cured high strength hybrid steel and synthetic fibers reinforced geopolymer composites. *Cement and Concrete Composites* 2018; 85, 133-152.
- [22] Liu Y, Zhang Z, Shi C, Zhu D, Li N, Deng Y. Development of ultra-high performance geopolymer concrete (UHPC): Influence of steel fiber on mechanical properties. *Cement and Concrete Composites* 2020; 112:103670. <https://doi.org/10.1016/j.cemconcomp.2020.103670>
- [23] Vijai K, Kumutha R, Vishnuram BG. Effect of Inclusion of Steel Fibres on The Properties of Geopolymer Concrete Composites. *Asian Journal of Civil Engineering (Building and Housing)* 2012; 13(3), 381-389. <https://sid.ir/paper/298940/en>
- [24] Zaid O, Martínez-García R, Abadel AA, Fraile-Fernández FJ, Alshaikh IM, Palencia-Coto C. To determine the performance of metakaolin-based fiber-reinforced geopolymer concrete with recycled aggregates. *Archives of Civil and Mechanical Engineering* 2022; 22(3), 114.
- [25] Sanjayan JG, Nazari A, Pouraliakbar H. FEA modelling of fracture toughness of steel fibre-reinforced geopolymer composites. *Materials & Design* 2015; 76, 215-222.
- [26] Rabiaa E, Mohamed RAS, Sofi WH, Tawfik TA. Developing geopolymer concrete properties by using nanomaterials and steel fibers. *Advances in Materials Science and Engineering* 2020; 2020, 1-12.
- [27] Bellum RR. Influence of steel and PP fibers on mechanical and microstructural properties of fly ash-GGBFS based geopolymer composites. *Ceramics International* 2022; 48(5), 6808-6818.
- [28] Faris MA, Abdullah MMAB, Muniandy R, Abu Hashim MF, Błoch K, Jeż B, Garus S, Palutkiewicz P, Mohd Mortar NA, Ghazali MF. Comparison of Hook and Straight Steel Fibers Addition on Malaysian Fly Ash-Based Geopolymer Concrete on the Slump, Density, Water Absorption and Mechanical Properties. *Materials*. 2021; 14(5):1310. <https://doi.org/10.3390/ma14051310>
- [29] Wang Y, Aslani F, Valizadeh A. An investigation into the mechanical behaviour of fibre-reinforced geopolymer concrete incorporating NiTi shape memory alloy, steel and polypropylene fibres.

- Construction and Building Materials 2020; Volume 259, 119765
<https://doi.org/10.1016/j.conbuildmat.2020.119765>
- [30] Bernal S, De Gutierrez R, Delvasto S, Rodriguez E. Performance of an alkali-activated slag concrete reinforced with steel fibers. Construction and Building Materials 2010; 24(2), 208-214.
- [31] Eren NA, Alzeebaree R, Çevik A, Niş A, Mohammedameen A, Gülşan ME. Fresh and hardened state performance of self-compacting slag based alkali activated concrete using nanosilica and steel fiber. Journal of Composite Materials 2021; 55(28):4125-4139. doi:10.1177/00219983211032390
- [32] Shah SFA, Chen B, Oderji SY, Haque MA, Ahmad MR. Comparative study on the effect of fiber type and content on the performance of one-part alkali-activated mortar. Construction and Building Materials 2020; 243:118221. <https://doi.org/10.1016/j.conbuildmat.2020.118221>
- [33] Ganesh AC, Sowmiya K, Muthukannan M. Investigation on the effect of steel fibers in geopolymer concrete. In IOP Conference Series: Materials Science and Engineering 2020; Vol. 872, No. 1, p. 012156. IOP Publishing. doi:10.1088/1757-899X/872/1/012156
- [34] Bhutta A, Borges PH, Zanotti C, Farooq M, Banthia N. Flexural behavior of geopolymer composites reinforced with steel and polypropylene macro fibers. Cement and Concrete Composites 2017; 80, 31-40. <http://dx.doi.org/10.1016/j.cemconcomp.2016.11.014>
- [35] Simon H. Neural networks: a comprehensive foundation. Prentice Hall PTR, 1998.
- [36] Mohammad R, Toufigh V. Evaluation of geopolymer concrete at high temperatures: An experimental study using machine learning. Journal of Cleaner Production 2022; 372: 133608. <https://doi.org/10.1016/j.jclepro.2022.133608>
- [37] Al-Jabery, K.K., Obafemi-Ajayi, T., Olbricht, G.R. and Wunsch Ii, D.C. (2020), “9 – Data analysis and machine learning tools in MATLAB and python”, in Al-Jabery, K.K., Obafemi-Ajayi, T., Olbricht, G.R. and Wunsch Ii, D.C., (Eds), Computational Learning Approaches to Data Analytics in Biomedical Applications, Academic Press, pp. 231-290.
- [38] Géron A. Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems, O'Reilly Media 2019.
- [39] Kaya M. Geopolimer Betonun Yangın Dayanımının Makine Öğrenmesi Algoritmaları Kullanılarak Modellenmesi. Yüksek Lisans Tezi, Iğdır Üniversitesi İnşaat Mühendisliği Ana Bilim Dalı 2023.

CAM SANAYİ ATIĞININ ÜÇLÜ ALKALI AKTİVATÖR SİSTEMİYLE ÜRETİLEN ÇÜRUF ESASLI GEOPOLİMER KOMPOZİTLERİN FİZİKSEL, MEKANİK VE DURABILİTE ÖZELLİKLERİNE ETKİSİ

Mahfuz PEKGÖZ^{1*}, İlker TEKİN²

^{1,2}Karabük Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Karabük, 78000, Türkiye

Geliş Tarihi/Received Date: 23.04.2024 Kabul Tarihi/Accepted Date: 13.12.2024 DOI:10.54365/adyumbd.1590079

ÖZET

Demir-çelik endüstrisi ve cam sanayisinden elde edilen atıkların çevresel etkilerinin azaltılması amacıyla yapılan bu çalışmada, cam sanayi atığının üçlü alkali aktivatör sistemiyle üretilen çüruf esaslı geopolimer kompozitlerin fiziksel, mekanik ve durabilite özelliklerine etkisi incelenmiştir. Bu kapsamda, cam sanayi atığı olan silis tozu, belirli oranlarda öğütülmüş yüksek fırın çürufu yerine ikame edilmiştir. Üçlü alkali aktivatör olarak; 10M NaOH, Na₂SiO_{3(aq)} çözeltisi ve Na₂SO₄ içerikli atık sinter külü kullanılmıştır. Deneysel çalışmada üretilen geopolimer kompozitlerin yayılma, su emme, büzülme, kapiler su emme, basınç dayanımı ve asit direnci deneyleri yapılmıştır. %5 oranında silis tozu ikame edilmesi, geopolimer kompozitlerin fiziksel, mekanik ve durabilite özelliklerini belirgin bir şekilde iyileştirdiğini göstermektedir. Silis tozu, kompozitlerin işlenebilirliğini %40-45 oranında artırmış; ayrıca büzülme, kapiler su emme katsayısı ve poroziteyi azaltarak asidik ortamlara karşı dayanıklılığı artırmıştır. Bu bulgular, endüstriyel atıkların geopolimer malzemelerde etkin bir şekilde kullanılarak çevresel etkilerinin minimize edilebileceği ve sürdürülebilir, ekonomik açıdan verimli malzemelerin üretilebileceği yönünde önemli bir potansiyel sunmaktadır.

Anahtar Kelimeler: Çüruf, Sinter Külü, Silis Tozu, Fiziksel ve Mekanik özellikler, Asit Direnci

EFFECT OF GLASS INDUSTRY WASTE ON THE PHYSICAL, MECHANICAL, AND DURABILITY PROPERTIES OF SLAG-BASED GEOPOLYMER COMPOSITES PRODUCED WITH A TERNARY ALKALI ACTIVATOR SYSTEM

ABSTRACT

This study, aimed at reducing the environmental impact of industrial waste from the steel and glass industries, investigates the effect of glass industry waste on the physical, mechanical and durability properties of slag-based geopolymer composites produced with a ternary alkali activator system. Silica powder, a waste product from the glass industry, was substituted for ground blastfurnace slag in specific proportions. The ternary alkali activator system used consists of 10M NaOH, Na₂SiO_{3(aq)} solution and sinter ash containing Na₂SO₄. Experimental tests were carried out on the produced geopolymer composites, including spread, water absorption, shrinkage, capillary water absorption, compressive strength and acid resistance. The substitution of 5% silica powder significantly improved the physical, mechanical and durability properties of the geopolymer composites. Silica powder increased the workability of the composites by 40-45% and reduced shrinkage, capillary water absorption and porosity while improving resistance to acidic media. These results represent a significant potential for the effective use of industrial waste in geopolymer materials, helping to minimise environmental impact and produce sustainable, economically efficient materials.

Keywords: Slag, Sinter Ash, Silica Powder, Physical and Mechanical Properties, Acid Resistance

*e-posta¹ : mahfuzpekgoz@karabuk.edu.tr ORCID ID: <https://orcid.org/0000-0002-9529-8537> (Sorumlu Yazar)

e-posta² : ilkertekin@karabuk.edu.tr ORCID ID: <https://orcid.org/0000-0001-7400-4790>

1. Introduction

The glass industry is a crucial component of modern construction and technology sectors. However, its production processes generate waste that presents significant environmental and economic challenges. Among these wastes, silica powder (SP) is notable for its high SiO_2 content and is typically disposed of through waste management methods [1-2]. However, these disposal methods contribute to environmental issues and lead to the waste of an economically valuable resource [3]. In recent years, there has been increasing research into alternative uses for waste SP. Its high reactivity and fine particulate structure make it a valuable additive in the production of geopolymers [4-5]. Geopolymers, with their low carbon emissions and sustainability benefits, offer an environmentally friendly alternative to traditional binders. Their properties also make them an ideal matrix for waste recovery [6-7]. Studies have shown that the incorporation of SP into geopolymers positively affects mechanical strength, chemical resistance, and microstructural development [8-9]. Notable improvements in acid resistance and strength properties have been observed in SP-based geopolymers [10]. Furthermore, these applications contribute to achieving sustainable waste management goals by facilitating the recovery of glass industry waste [11-12].

The iron and steel industry generates substantial amounts of waste through various processes. Among these, steel slag (SS) and ground granulated blast furnace slag (GGBFS) are particularly notable due to their significant environmental and economic implications. SS contains high concentrations of calcium oxide (CaO), iron oxides (Fe_2O_3), and other oxide components, whereas GGBFS primarily comprises silica (SiO_2), alumina (Al_2O_3), and CaO. Both materials are highly compatible with alkaline activation, making them suitable binders in geopolymer systems and supporting the production of sustainable construction materials. Additionally, China is the world's largest steel producer, producing 137 million tonnes of stainless steel in 2022. However, the utilisation rate is less than 30%, which is significantly lower than in developed countries such as Japan, the United States and the United Kingdom, where the utilisation rate reaches 70% [13]. In Turkey alone, the cumulative amount of SS discarded has reached 5.5 million tonnes, with less than 30% of SS used in low value-added applications such as aggregates in asphalt mixes [14-15], fillers in foundation construction, cementitious additives in concrete and other applications [16-18]. GGBFS, a granulated by-product of iron ore reduction, features an amorphous structure that makes it an effective binder in geopolymer matrices. Its inclusion improves the mechanical strength of geopolymer systems while enhancing their resistance to acidic environments. Research indicates that geopolymers incorporating these materials demonstrate enhanced physical and mechanical properties, including improved water absorption, compressive strength, and shrinkage behavior [19-21]. Studies on the application of SS and GGBFS in geopolymer systems emphasize their considerable potential for both sustainability and performance improvement. SS, owing to its free CaO and MgO content, enhances the curing and hardening properties of geopolymers. Meanwhile, GGBFS contributes to superior physico-mechanical characteristics, such as lower water absorption rates and higher strength values [22]. Further investigations are needed to assess the potential incorporation of sinter ash (SA) wastes into geopolymer systems. This study highlights the novel use of waste SA containing 82% Na_2SO_4 as an activator, alongside traditional NaOH and Na_2SiO_3 activators, addressing a gap in the current literature. Sodium sulfate and sodium carbonate, naturally occurring compounds, effectively enhance the reaction mechanisms in slag-based systems [23-24]. The activation process of slag with Na_2SO_4 involves the dissolution of SiO_4 and AlO_4 units in the slag, facilitated by Na^+ and SO_4^{2-} ions, which actively participate in hydration reactions [25]. The primary hydration products identified in Na_2SO_4 -activated slag systems are C-S-H gel and ettringite, contributing to the material's strength and stability [26].

The use of geopolymers presents notable challenges concerning shrinkage and acid resistance, which are vital for their long-term performance in a variety of applications. Shrinkage, which occurs during both the curing and drying stages, is frequently attributable to the densification and hardening of the polymeric network, which results in a reduction in volume. Such shrinkage can have a detrimental

impact on the material's dimensional stability, leading to the formation of cracks and a subsequent compromise in the structural integrity of the geopolymer. Recent studies have emphasised the significance of regulating the mixture design, curing procedures and the incorporation of additives, such as fibres or chemical agents, to minimise shrinkage and enhance the durability of geopolymers [27]. With regard to acid resistance, geopolymers display greater resilience to acidic environments than traditional cement-based materials, due to the strong aluminosilicate network they possess. Nevertheless, prolonged exposure to highly corrosive acids, particularly at elevated temperatures or in concentrated solutions, can still result in degradation of geopolymers. The extent of this degradation is contingent upon a number of factors, including the specific raw materials employed, the curing conditions, and the structural characteristics of the geopolymer [28]. To enhance acid resistance, recent studies have concentrated on optimising geopolymer composition and incorporating supplementary materials, such as industrial by-products, which can augment their durability in harsh chemical environments [29].

In this study, SP, a glass industry waste with a chemical composition of 95% SiO₂, was used to compensate for the effects of free CaO present in SS and to improve the physical, mechanical and durability properties of GCs. SP was substituted for GGBFS at weight ratios of 5%, 10%, 15%, 20% and 25% to reduce costs and increase waste recycling. The performance of the GCs was evaluated through tests measuring workability (flowability), water absorption, shrinkage, capillary water absorption, compressive strength and acid resistance.

2. Materials and Methods

In this study, a variety of materials were used to prepare geopolymer composites (GCs), including ground granulated blast furnace slag (GGBFS), steel slag (SS), sinter ash (SA), and silica powder (SP). The GGBFS is a by-product of the iron manufacturing process and is employed as a binder in geopolymer production due to its pozzolanic properties, which contribute significantly to the strength and durability of the GCs. The SS (sieved <1 mm), a by-product of steelmaking, was incorporated with the objective of enhancing the mechanical properties of the GCs. This incorporation provides additional calcium and iron components that improve the material's overall stability. Subsequently, the SP was incorporated into the mixture to augment the silica content, thereby facilitating the formation of the aluminosilicate gel that endows the GCs with their distinctive chemical and mechanical properties. These materials were selected for their complementary roles in optimising the performance of the GCs, with detailed specifications provided in the following sections. The overall mixture design is depicted in Figure 1. Figure 2 shows the particle size distributions of the raw components, determined using a Laser Particle Sizer.




Figure 1. Images of a) GGBFS, b) SS, c) SA and d) SP




Figure 2. GGBFS, SA, SS and SP particle size distributions used in study

The particle size distributions of GGBFS, SS and SA were analysed and showed different characteristics. GGBFS had D_{90} , D_{50} and D_{10} values of 37.5 μm , 14.9 μm and 2.52 μm respectively. In comparison, SS had much coarser D_{90} , D_{50} and D_{10} values of 309 μm , 76.1 μm and 9.84 μm . The SA showed intermediate particle sizes with D_{90} , D_{50} and D_{10} values of 32.6 μm , 14.6 μm and 4.89 μm . The SP showed intermediate particle sizes with D_{90} , D_{50} and D_{10} values of 161 μm , 91 μm and 43.5 μm . SS, after sieving to exclude particles larger than 1 mm, showed a particle size distribution primarily concentrated between 18 μm and 300 μm , as shown in Figure 2. In terms of specific surface area, GGBFS had a value of 403.4 m^2/kg , SS had 308.4 m^2/kg , SP had 173.7 m^2/kg and SA had the highest value of 576.1 m^2/kg . The respective densities of these materials were 2.98 kg/m^3 for GGBFS, 2.38 kg/m^3 for SS, 2.71 kg/m^3 for SP and 2.97 kg/m^3 for SA. Table 1 gives a detailed comparison of the chemical compositions of SS and GGBFS. It is noteworthy that SS has a higher free CaO content than GGBFS, which would suggest a higher reactivity. However, the higher Fe_2O_3 content in SS reduces its overall reactivity, distinguishing it from the finer and more active GGBFS.

Table 1. Chemical composition of SS and GGBFS

Oxides (%)	CaO	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	MgO	SO ₃	K ₂ O	Na ₂ O	Mn ₂ O ₃	LOI
SS	48.01	12.82	2.58	13.9	3.19	2.09	0.04	-	3.48	13.31
GGBFS	30.13	36.01	11.49	1.65	8.66	0.63	0.84	0.60	5.66	-

In this study, high-purity NaOH (99.9%) at a concentration of 10 M and an aqueous sodium silicate solution (Na_2SiO_3) with a silica modulus (Ms) of 0.5 were utilized as activators in combination with SA. The 10M NaOH solution was selected based on the indication in the literature that the optimal mechanical and physical properties of geopolymers are typically observed with NaOH concentrations ranging from 10M to 14M [30]. The $\text{Na}_2\text{SiO}_3(\text{aq})$ consisted of 12% Na_2O , 24% SiO_2 , and 64% water. Additionally, waste by-products from the MEROS® process, carried out at the Karabük Iron and Steel Factory, were employed as an activator and surfactant in slag-based GCs. The MEROS® system in the iron and steel industry uses sodium bicarbonate to capture and solidify sulphates at elevated temperatures, producing a by-product known as SA. Kardemir Iron and Steel Factory generates approximately 50,000 tonnes of this material annually, making it a significant resource. XRD analysis of SA indicated its composition as 77% sodium sulfate (Na_2SO_4), 5% thenardite, and 17.6% nahcolite, as determined by Rietveld refinement. Furthermore, the alkalinity of a 5% SA solution was measured to be within a pH range of 7.5–8 according to ISO 6353/2:1983 standards. Ion chromatography and ICP-MS analyses revealed the metallic content in SA, with concentrations of 0.44% Na, 0.47% Al, 0.46% Cu, 0.32% Zn, 0.26% Mg, 0.16% Mn, 0.0021% As, and 0.001% Pb. These chemical and metallic characteristics make SA a potential candidate for integration into geopolymer systems as an alternative activator.

The mixture designs of the GCs in this experiment are shown in Table 2. A total of 6 groups of mixtures with different ratios were designed. The SS content was used at 40 wt% and the GGBFS content at 60 wt% in all mixes, maintaining a constant ratio across all designs. The amount of SA was used in the ratio SS+GGBFS at 5 wt%. The effect of the SP content was investigated using 5%, 10%, 15%, 15%, 20% and 25% by weight of GGBFS. For all GCs, the solution/powder (S/P) ratio was chosen to be 0.25 to ensure adequate workability and high compressive strength.

Table 2. Experimental design (g)

Codes	SS	GGBFS	SP	SA	NaOH (10M)	Na ₂ SiO ₃ (aq)
S0	40	60	0	5	5	20
S5	40	55	5	5	5	20
S10	40	50	10	5	5	20
S15	40	45	15	5	5	20
S20	40	40	20	5	5	20
S25	40	35	25	5	5	20

The steps involved in preparing GCs are illustrated in Figure 3. The triple activator solution (TAS) was created using NaOH, Na₂SiO₃(aq), sodium sulfate-based activator (SA), and tap water. The preparation process consisted of the following stages:

- Preparation of NaOH Solution: A 10 M sodium hydroxide solution was prepared by dissolving solid NaOH pellets in tap water. The solution was allowed to rest in a sealed glass container at room temperature for 24 hours to stabilize.
- Na₂SiO₃ Solution Preparation: A second solution was created by combining equal weights (50 wt%) of tap water due to its economy and workability and aqueous sodium silicate (Na₂SiO₃) in a glass beaker.
- Combining Solutions: For cost efficiency and ease of processing, the NaOH solution (20 wt%) and the water-Na₂SiO₃ solution (80 wt%) were blended using a magnetic stirrer. The combined solution served as the primary base for the TAS.
- Integration of SA: The sodium/silicate activator solution was then mixed with a constant proportion of SA using a hand mixer to ensure uniformity.

For the preparation of GCs, the specified amounts of SS, SP, and GGBFS for each group were weighed and initially combined in a JJ-5 mixing chamber. The materials were mixed at medium speed for 60 seconds to achieve a consistent blend. The preparation steps for the GCs involved two mixing phases:

- Phase 1: The TAS was added to the mixer, followed by the SS+SP+GGBFS mixture. These components were blended at a medium speed of 1400 rpm for 60 seconds.
- Phase 2: The mixture was further mixed at a higher speed of 2800 rpm for 300 seconds to ensure thorough homogenization.

This multi-step process was designed to optimize the quality and performance of the geopolymer composite mixtures.

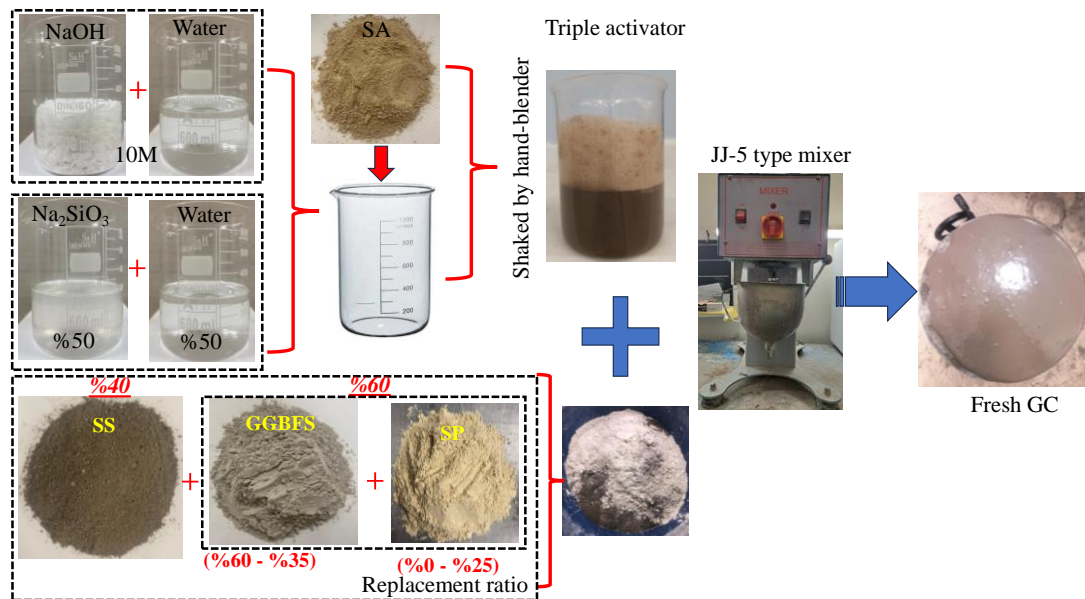


Figure 3. Manufacturing and preparation process of GCs

Following the guidelines of ASTM C1437-15 [31], the flowability of fresh GCs was determined using a material-loaded truncated cone mould. The mould was slightly raised, and the drop was activated 25 times. The workability of the GCs was assessed by recording the expansion diameter in two perpendicular directions and calculating the average. The GCs were then moulded into cubic shapes of 50x50x50 mm and cured under ambient laboratory conditions for 28 days in preparation for testing. The compressive strength test was carried out according to ASTM C109 [32] and the acid resistance test according to ASTM C267 [33] with GCs cast in 50x50x50 mm steel moulds. In order to perform the acid resistance test, a solution of 1% sulfuric acid was prepared by diluting concentrated sulfuric acid with distilled water. The specimens were stored under standard laboratory conditions for 28 days to provide sufficient curing time. Following the 28-day period, the specimens were immersed in the prepared sulfuric acid solution and left to soak for a further 30 days until the day of the experiment. The water absorption test was carried out according to ASTM C1585 [34]. The 40x40x160 mm specimens were subjected to shrinkage and capillary water absorption tests according to ASTM C596 - 18 [35] and ASTM C1585 [34]. The shrinkage measurements of the GCs were conducted at 1, 2, 3, 7, 14, 21, and 28 days. The measurements were taken using a micrometer on prisms measuring 40 x 40 x 160 mm at three points, and the mean of these three measurements was employed to calculate the shrinkage. The shrinkage was calculated using the following formula (1). The samples were cured in an oven at 80 °C for 2 hours before demoulding, as literature suggests that this condition yields the highest compressive strength [36-37] promoting early setting and improved early mechanical properties. All GCs were cured in the laboratory in ambient conditions (22±2 °C, 30±5 R.H.) for 28 days until the testing days. The hardened GCs were tested for compressive strength and water absorption on days 2 and 28 to evaluate the evolution of the mechanical properties over time.

$$\text{Shrinkage} = \frac{\text{Final Length} - \text{Initial Length}}{\text{Initial Length}} \quad (1)$$

3. Results and Discussions

3.1. Workability of GCs

The results of the workability test of the GC mixtures are shown in Figure 4. As the SP ratio increased, the slump values of the GCs also increased. In particular, when the SP ratio was 10% or higher, the workability was improved due to the inert nature of SP compared to GGBFS and its lower specific surface area. When evaluating the spread values based on the S0-series, it was observed that when the SP ratio was 5% and $\geq 10\%$, the increase was approximately 23% and 46% respectively.




Figure 4. The results of the workability of GCs

3.2. Compressive strength of GCs

The compressive strength results of the GCs are shown in Figure 5. The highest compressive strengths at 2 and 28 days were 46.48 MPa and 74.31 MPa respectively for the S0 series. However, the S5 series had compressive strengths that were 7% lower than the S0 series. The lowest compressive strength at 2 and 28 days was achieved by the S5 series with values of 13.28 MPa and 34.59 MPa respectively. For the S5, S10, S15, S20 and S25 grades, the 2-day compressive strengths decreased by 6.7%, 14.6%, 35.7%, 185.5% and 250% respectively compared to S0, while at 28 days the decreases were 3.9%, 16.6%, 32.9%, 52.1% and 114.8% respectively. The reduction in the reactive GGBFS content and the increase in the inert SP ratio resulted in a reduction in compressive strength. The decrease in strength was caused by a decrease in the formation of C-A-S-H gels, which are responsible for the increase in strength. Replacement of SP at 5% by weight did not disturb the stoichiometric ratio, whereas replacement above 10% SP disturbed the stoichiometric ratio. The stoichiometric ratio refers to the optimal balance between the alkaline activator and the aluminosilicate source required for the geopolymerization reaction. Maintaining this ratio is crucial for ensuring the complete reaction of the precursor materials and achieving the desired mechanical properties in the ultimate GCs. At 28 days, the compressive strengths for the S0, S5, S10, S15, S20 and S25 series increased by approximately 60%, 60%, 57%, 63%, 200% and 161% respectively compared to the 2-day values. The increase in SP content over time enhances gel formation, as SiO_2 dissolves in the alkaline medium, which contributes to the improved compressive strength development, as reported in the literature [30].




Figure 5. Results of the compressive strength of all GCs

3.3. Water absorption of GCs

The water absorption results for the GCs are shown in Figure 6. As the inert SP content increased, the reduction in reactive GGBFS resulted in a decrease in reactions, leading to an increase in visible porosity. In addition, the reduction in GGBFS resulted in a reduction in C-S-H, C(N)-A-S-H, gypsum or ettringite gel formation, which typically fills voids. Apparent porosity in the S5, S10, S15, S20 and S25 series increased by 4.8%, 12.63%, 18.19%, 29.59% and 33.08% respectively compared to the S0 series. Since the apparent porosity of the S5 series was 5% lower than that of the S0 series, its compressive strength was 7% lower. This aligns with the literature [38], which suggests that when apparent porosity is below 5%, its effect on compressive strength is minimal. As the amount of GGBFS, which has a higher specific gravity than SP, decreased, the dry bulk density also decreased. The lowest dry specific weight of 1.72 was found in the S5 range. There is a linear relationship between water absorption values and compressive strength.

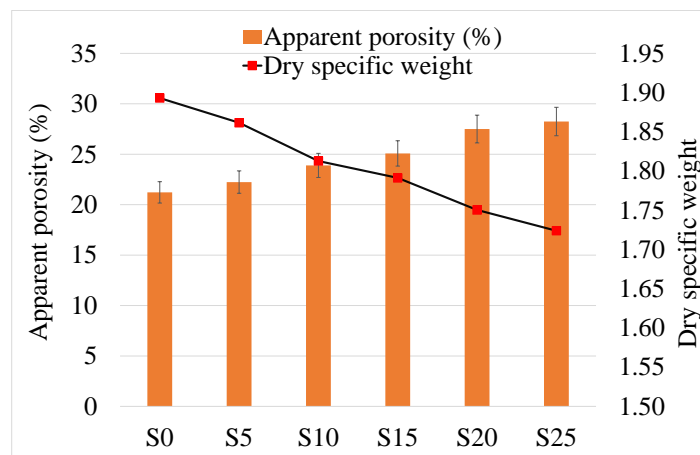


Figure 6. Results of apparent porosity and dry specific weight of GCs

3.4. Length change measurements of GCs

The results of the shrinkage test for the GCs are presented in Figure 7. The highest and lowest shrinkage values were observed in the S25 and S5 series, with values of 2.6% and 1.7%, respectively. The 5% replacement of SP interacts with the Ca^{2+} component present in sufficient quantities in the geopolymer composition, resulting in a reaction with SiO_2 that enhances gel formation. Consequently, the filling of micro and macro voids reduces shrinkage. Furthermore, an analysis of the apparent porosity

and capillarity coefficient indicates that the voids in the S5 series were filled through gelation. As the shrinkage values increased, the compressive strength decreased, and the apparent porosity increased. A review of the literature reveals that reaction products in GCs can significantly fill voids, thereby influencing both shrinkage and absorption. For instance, Xie etc. report in their review article that the formation of reaction products contributes to a reduction in porosity and void spaces, which in turn influences the material's shrinkage and absorption properties [39]. Apart from the S5 series, the shrinkage values of the remaining geopolymer composites were higher than those of the S0 series. When the SP replacement ratio exceeded 10%, the shrinkage values increased due to the reduction in gel formation caused by chemical reactions.




Figure 7. Shrinkage measurements of all GCs

3.5. Capillary water absorption of GCs

The results of the capillary water absorption test are presented in Figure 8. The lowest capillary coefficient, 0.89 ($\text{g}/\text{cm}^2\sqrt{\text{dk}}$), was observed in the S5 series. The replacement of 5% of the mixture with SP resulted in the dissolution and reaction of the silica with the Ca^{2+} components, which promoted gel formation and filled the capillary voids. Consequently, the capillary coefficient fell below 1. However, when the SP content exceeded 5%, the reduction in GGBFS content led to a decrease in Ca^{2+} , and the reduction in gel formation caused the capillary voids to remain unfilled, resulting in an increase in the capillary coefficient.




Figure 8. Results of capillary water absorption of GCs

The capillary water absorption test results presented in Figures 9a, b, and c are correlated with compressive strength, apparent porosity, and shrinkage values, with R^2 values of 0.93, 0.87, and 0.91, respectively. As the capillarity coefficient increased, the compressive strength decreased, the apparent porosity increased, and the shrinkage values also increased. These correlations indicate that higher capillary water absorption is linked to poorer mechanical properties and increased porosity, thereby highlighting the impact of capillary behaviour on the performance of GCs.

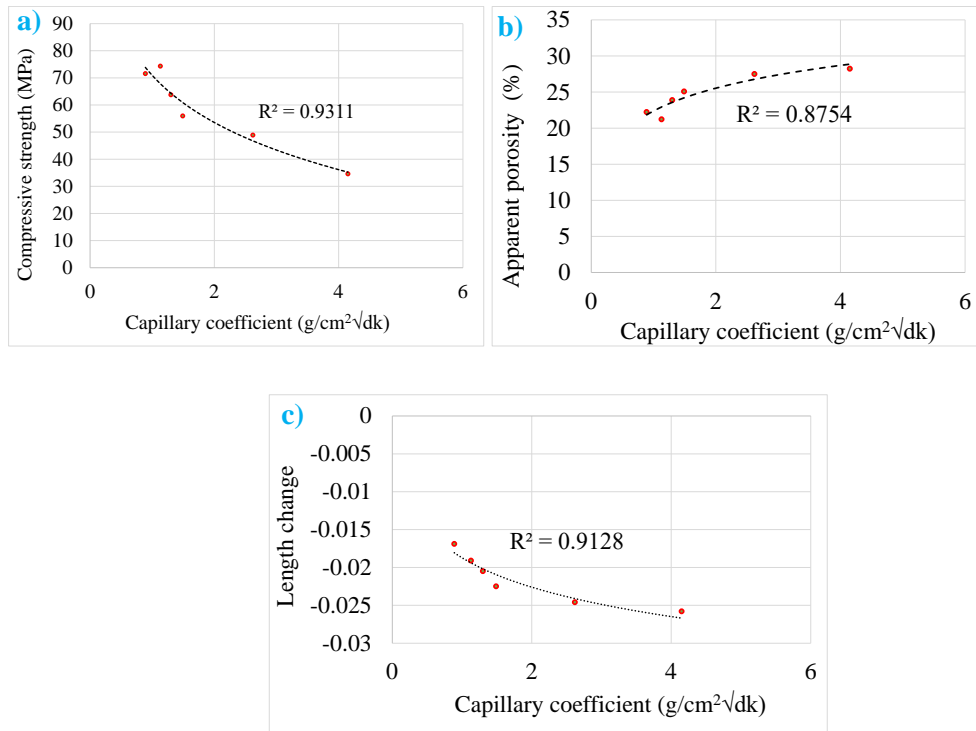


Figure 9. The capillary coefficient correlated with a) compressive strength, b) apparent porosity, and c) shrinkage values

3.6. Acid resistance of GCs

Figure 10a and b illustrate the acid resistance test results for GC specimens exposed to sulfuric acid for 30 days. The figures show mass loss and compressive strength loss, respectively. The geopolymers demonstrated volume stability and did not disintegrate after 30 days, indicating the formation of a geopolymer structure with robust characteristics, as shown in Figure 11. The lowest and highest mass losses, at 4.35% and 6.32%, respectively, were observed in the S0 and S25 series. As the SP content increased, a corresponding increase in mass loss was observed. In comparison to the S0 series, the mass loss for 5%, 10%, 15%, 20%, and 25% SP substitutions increased by 9.65%, 20.46%, 21.15%, 32.64%, and 45.29%, respectively. However, the mass losses observed in the S0 and S5 series remained below 5%. As illustrated in Figure 10b, the compressive strength exhibited a loss of 4.72%, 4.94%, and 5.56% for the S0, S5, and S10 series, respectively. The exposure of the material to sulfuric acid resulted in a reduction in pH, which led to the dissolution of C-S-H, ettringite, gypsum, and C(N)-A-S-H gels. This, in turn, led to a decrease in compressive strength. Nevertheless, the compressive strength losses in the S0, S5, and S10 series remained within the acceptable 5% limit. As the concentration of silica powder in the acidic medium increases, the amount of dissolved SiO_2 also increases in accordance with the solubility of the substance. The dissolution of SiO_2 enhances the formation of C(N)-A-S-H gels by reacting with free Ca^{2+} and Na^{2+} ions in the medium, thereby leading to an improvement in compressive strength in the S15, S20, and S25 series after sulfuric acid exposure.




Figure 10. Acid resistance experiment results of GCs




Figure 11. Images of GCs after 30 days of exposure to acid

4. Conclusions

The primary objective of this study is to evaluate the fresh, hardened and durability properties of steel slag based geopolymer composites, with particular emphasis on the effect of silica powder (SP) as a partial precursor in combination with ternary activators such as NaOH, Na₂SiO₃(aq) and sintered ash. The findings of this study demonstrated that the most optimal ratio was 5% SP. An increase in the SP ratio enhances the workability of the GCs. The GCs employing 5% SP exhibited the closest approximation to the highest early and late strengths, with values of approximately 44 MPa and 72 MPa, respectively. Compared to the S0 series, the compressive strength of the S10, S15, and S20 series decreased by approximately 17%, 33%, and 52%, respectively, while the apparent porosity increased by approximately 13%, 18%, and 30%, respectively. The utilization of 5% SP decreased the apparent porosity and capillary water absorption values, indicating that it reduced the impermeability of the GCs. In acid medium, as the SP ratio increased, GCs mass loss increased, while compressive strength increased in the series with 15%, 20% and 25% substituted SP.

Acknowledgment

The authors would like to thank the Scientific Research Project of Turkey (BAP) for supporting this study by funding it as a part of the Karabük University, KBÜBAP-23-KP-058 project. The authors would like to thank Kardemir Steel Industry A.Ş. for providing the waste materials for this study.

Author Contribution

The authors confirm responsibility for the following: study conception and design, data collection, analysis and interpretation of results, and manuscript preparation.

Conflict of Interest

The authors declare that they have no conflict of interest.

References

- [1] Mehta A, Ashish DK. Silica fume and waste glass in cement concrete production: A review. *Journal of Building Engineering* 2020; 29(5): 100888.
- [2] Jiang Y, Ling TC, Mo KH, Shi C. A critical review of waste glass powder – Multiple roles of utilization in cement-based materials and construction products. *Journal of Environmental Management* 2019; 242: 440–449.
- [3] Davidovits J. Geopolymers: Inorganic polymeric new materials. *Journal of Thermal Analysis and Calorimetry* 1989; 37(8): 1633–1656.
- [4] Alnahhal MF, Kim T, Hajimohammadi A. Waste-derived activators for alkali-activated materials: A review. *Cement and Concrete Composites* 2021; 118(4): 103980.
- [5] Abed FH, Zareei SA, Kurdi NH, Emami A. Enhancing geopolymer binder reactivity and performance via mechanochemical activation: A comprehensive study of rheological, mechanical, and microstructural properties. *Construction and Building Materials* 2024; 430(6): 136456.
- [6] Provis JL, Duxson P, van Deventer JSJ. The role of particle technology in developing sustainable construction materials. *Advanced Powder Technology* 2010; 21(1): 2–7.
- [7] Caldas PHCH, de Azevedo ARG, Marvila MT. Silica fume activated by NaOH and KOH in cement mortars: Rheological and mechanical study. *Construction and Building Materials* 2023; 400(10): 132623.
- [8] Mohajerani A, Vajna J, Cheung THH, Kurmus H, Arulrajah A, Horpibulsuk S. Practical recycling applications of crushed waste glass in construction materials: A review. *Construction and Building Materials* 2017; 156: 443–467.
- [9] Hamed YR, Elshikh MMY, Elshami AA, Matthana MHS, Youssef O. Mechanical properties of fly ash and silica fume based geopolymer concrete made with magnetized water activator. *Construction and Building Materials* 2024; 411(1): 134376.
- [10] Li B, Gao A, Li Y, Xiao H, Chen N, Xia D, Wang S, Li C. Effect of silica fume content on the mechanical strengths, compressive stress–strain behavior and microstructures of geopolymeric recycled aggregate concrete. *Construction and Building Materials* 2023; 384(6): 131417.
- [11] Tihomirovs P, De Maeijer PK, Korjakins A. Demolition waste glass usage in the construction industry. *Infrastructures* 2023; 8(12): 182.
- [12] Azad NM, Samarakoon SMK. Utilization of industrial by-products/waste to manufacture geopolymer cement/concrete. *Sustainability* 2021; 13(2): 873.
- [13] Zhang L, Wang Q, Zheng Y, Cang Z, Gisele K, Yu C, Cang D. Synergistic effect and mechanism of waste glass on the mechanical properties and autoclave stability of cementitious materials containing steel slag. *Construction and Building Materials* 2021; 311: 125295.

- [14] Özsoy M, Fırat S. Numerical analysis of road infrastructure layers made with steel slag. *Journal of Polytechnic* 2023; 24(6): 1661-1673.
- [15] Karadağ H, Fırat S, Işık NS. Utilization of steel slag as road base and subbase material. *Journal of Polytechnic* 2020; 23(3): 799-812.
- [16] Uysal FF, Bahar S. Slag types and utilization areas. *Trakya University Journal of Engineering Sciences* 2018; 19(1): 37-52.
- [17] Kua HW. Integrated policies to promote sustainable use of steel slag for construction—A consequential life cycle embodied energy and greenhouse gas emission perspective. *Energy and Buildings* 2015; 101: 133-143.
- [18] Yi H, Xu G, Cheng H, Wang J, Wan Y, Chen H. An Overview of utilization of steel slag. *Procedia Environmental Sciences* 2012; 16: 791-801.
- [19] Hasan MS, Najim K. Geopolymer concrete from steel slag: Mechanical and durability properties. *Construction and Building Materials* 2018; 190: 1152-1161.
- [20] Zheng Z, Deng P. Mechanical and fracture properties of slag/steel slag-based geopolymer fully recycled aggregate concrete. *Construction and Building Materials* 2024; 413: 134533.
- [21] Mansourghanaei MH, Biklaryan M, Mardookhpour A. Durability and mechanical properties of granulated blast furnace slag-based geopolymer concrete containing polyolefin fibers and nano silica. *KSCE Journal of Civil Engineering* 2024; 28: 209–219.
- [22] Ayim-Mensah G, Radosavljevic M. Influence of ground granulated blast furnace slag on the compressive strength and ductility of ultra high-performance fibre reinforced cementitious composites. *Cement* 2022; 8(6): 100030.
- [23] Peng MX, Wang ZH, Shen SH, Guo XQ, Jiang LL, Cheng YC, Lin HL. One-part geopolymeric cements cured at elevated temperature by comparison with two-part ones. *Construction and Building Materials* 2017; 130: 103-112.
- [24] Yu S, He J, Sang G, Yang SQ, Liu G. Study on hydration process of alkali-activated slag cement activated by weakly alkaline components. *Construction and Building Materials* 2024; 413: 134716.
- [25] Rashad AM, Bai Y, Basheer PAM, Milestone NB, Collier NC. Hydration and properties of sodium sulfate activated slag. *Cement and Concrete Composites* 2013; 37(1): 20-29.
- [26] Li Y, Lei W, Zhang Q, Yang Q, He X, Su Y, Tan H, Liu J, Wang G. Synergistic effects of steel slag and wet grinding on ambient cured ground granulated blast furnace slag activated by sodium sulfate. *Construction and Building Materials* 2022; 349: 128661.
- [27] Liu X, Li Y, Chen Z. Enhancing acid resistance of geopolymers through optimized raw material selection and curing conditions. *Journal of Sustainable Materials* 2024; 15(2): 227-237.
- [28] Mohamed OA, Al-Khattab R, Al-Hawat W. Resistance to acid degradation, sorptivity, and setting time of geopolymer mortars. *Front Struct Civ Eng* 2022; 16: 781–791.
- [29] Zhang B, Zhu H, Feng P, Zhang P. A review on shrinkage-reducing methods and mechanisms of alkali-activated/geopolymer systems: Effects of chemical additives. *Journal of Building Engineering* 2022; 49: 104056.
- [30] Smith A, Johnson B, Lee C. Effect of NaOH concentration on the mechanical and physical properties of geopolymers. *Journal of Materials Science* 2023; 58(12): 3245-3258.
- [31] ASTM C1437-15, Standard Test Method for Flow of Hydraulic Cement Mortar, PA, USA, 2015.
- [32] ASTM C109-16, Standard Test Method for Compressive Strength of Hydraulic Cement Mortars, American Society for Testing and Materials, ASTM, PA, USA, 2016.
- [33] ASTM C267-17, Standard Test Methods for Chemical Resistance of Mortars, Grouts, and Monolithic Surfacing, American Society for Testing and Materials, ASTM, PA, USA, 2017.
- [34] ASTM C1585-13, Standard Test Method for Measurement of Rate of Absorption of Water by Hydraulic-Cement Concretes, American Society for Testing and Materials, ASTM, PA, USA, 2013.
- [35] ASTM C596-18, Standard Test Method for Drying Shrinkage of Mortar Containing Hydraulic Cement, American Society for Testing and Materials, ASTM, PA, USA, 2018.
- [36] Pekgöz M, Tekin İ. The Effects of different origins naoh on the mechanical and microstructural properties of tuff-based alkali-activated pastes. *Turkish Journal of Engineering Research and Education* 2022; 1(1): 29-37. doi: 31.05.2022.

- [37] Tekin İ, Gencil O, Gholampour A, Oren OH, Koksal F. Recycling zeolitic tuff and marble waste in the production of eco-friendly geopolymer concretes. *Journal of Cleaner Production* 2020; 246: 119039.
- [38] Zhang X, Li Y, Wang Z. A Study on relationship between porosity and compressive strength for geopolymer paste. *Journal of Materials Science* 2023; 58(4): 1123-1135.
- [39] Xie W, Zhang M, Li S. A review on the effects of reaction products on the properties of geopolymer materials. *Construction and Building Materials* 2023; 345: 129558.

ARAZİ VE ARSA DÜZENLEMELERİNDE MAHKEME KARARLARINA DAYALI İPTAL İŞLEMLERİNDE GERİ DÖNÜŞ SÜREÇLERİNİN ANALİZİ: KONYA İLİ MERAM İLÇESİ ÖRNEĞİ

Yaşar İNCEYOL*

Adiyaman Üniversitesi Teknik Bilimler Meslek Yüksek Okulu, İnşaat Bölümü, Adiyaman, 02040, Türkiye
Geliş Tarihi/Received Date: 11.11.2024 Kabul Tarihi/Accepted Date:20.12.2024 DOI:10.54365/adyumbd.1583240

ÖZET

Kentleşme ve nüfus artışıyla birlikte sosyal donatı alanları, konut ihtiyacı ve sürdürülebilir bir çevre için etkili imar planı uygulamaları gereklidir. Arazi ve Arsa Düzenlemesi (AAD), kırsal alanları kentsel alanlara dönüştürerek kamu hizmet alanları ve altyapıyı sağlamak için etkili bir araçtır. Ancak, parsel tahsisi, Düzenleme Ortaklık Payı (DOP) kesintileri ve arazi sahiplerinin mülkiyet haklarının korunmasında ekonomik, hukuki ve teknik zorluklarla karşılaşmaktadır. AAD uygulamalarında yapılan hukuki ve teknik hatalar nedeniyle uygulamalar sıkça yargıya taşınmakta ve çoğu zaman iptalle sonuçlanmaktadır. Yargı kararıyla iptal edilen AAD uygulamaları geri dönüş süreçlerini zorunlu kılmakta; ancak, bu süreç için standart bir yasal prosedür olmaması uygulamaları daha karmaşık hale getirmektedir. Bu çalışma, Türkiye’de AAD uygulamalarındaki iptal nedenlerini ve geri dönüş süreçlerine etkilerini inceleyerek bu süreçlere ilişkin belirsizlikleri gidermeyi amaçlamaktadır. Üç örnek düzenleme sahasında gerçekleşen geri dönüş süreçlerinin analiziyle müstakil yerine hisseli parsel verilmesi, sınır hataları ve DOP kesintisi gibi sorunlar belirlenmiştir. İptal kararlarının azaltılmasına yönelik doğrudan tebliğat, çift yönlü iletişim, bedele dönüştürme ve uzman desteğini içeren alternatif çözüm önerileri sunulmuştur.

Anahtar Kelimeler: İmar Planı, Arazi ve Arsa Düzenlemesi, 18. Madde Uygulaması, Geri Dönüş, Geri Dönüş Süreci

ANALYSIS OF REVERSING PROCESSES IN CANCELLATION PROCEDURES BASED ON COURT DECISIONS IN LAND READJUSTMENT IMPLEMENTATIONS: THE CASE OF MERAM DISTRICT IN KONYA PROVINCE

ABSTRACT

With the rapid urbanization and population growth, effective zoning implementation is essential to meet the demand for social facilities, housing, and a sustainable environment. Land Readjustment (LR) serves as an effective tool for transforming rural areas into urban spaces by providing public service areas and infrastructure. However, economic, legal, and technical challenges arise in the allocation of parcels, deduction of, Development Readjustment Share (DRS), and protection of property rights. Legal and technical errors in LR implementations often lead to litigation, resulting in frequent cancellations. Cancellations mandated by court decisions necessitate a reversal process, yet the absence of a standardized legal procedure for this process complicates implementation. This study examines the grounds cancellations in LR processes in Turkey and their impact on reversal procedures, aiming to reduce uncertainties in these processes. By analyzing the reversal processes in three case study areas, problems such as granting shared parcels instead of individual ones, design boundary errors, and DRS deductions were identified. Alternative solutions such as direct notification, two-way communication, conversion to monetary value, and expert support have been offered to reduce cancellation decisions.

Keywords: Zoning plan, Land readjustment, implementation of the zoning plan 18th article, reversing, reversing process

* e-posta: yinceyol@adiyaman.edu.tr ORCID ID: <https://orcid.org/0000-0001-7455-2869>

1. Giriş

Günümüzde kentlerde hızla artan nüfus yoğunluğunun getirdiği sosyal donatı alanlarının oluşturulması ve buna bağlı konut ihtiyacı, etkili bir arazi yönetim sistemine ve imar planlarının mekânsal olarak uygulanmasına bağlıdır. İmar planlarının uygulama süreci kentsel planlamanın başarısını ve sürdürülebilirliğini doğrudan etkilemektedir. Şehircilik ilkelerine uygun etkili ve hızlı bir kentleşme önemli ölçüde özel sektörün ve kamunun taleplerine uygun parsellerin üretilmesine bağlıdır [1]. Kırsal alanları kentsel alana dönüştürerek kentsel altyapı sağlayan, insanların barınma ve diğer sosyal donatı ihtiyaçlarını karşılayan en temel araç “arazi ve arsa düzenlemesi” (AAD) [2,3] veya diğer adıyla “18.madde uygulaması”dır. AAD, daha çok arazi mülkiyeti tarafında olacak şekilde ve genellikle kamu kurumlarının arazi kullanım hedeflerini gerçekleştirmeleri için ekonomik olarak uygulanabilir tek alternatif olarak tasarlanmıştır [4]. AAD, dağınık ve düzensiz tarım arazilerinin mülkiyetinin bir araya getirildiği, yolların ve ana altyapının inşa edildiği ve daha sonra arazinin kentsel parsellere bölüdüğü bir yöntemdir [5]. Bu yöntem, sadece arazi sahiplerinin değil aynı zamanda şehir planlayıcılarının ve yerel idarelerin de sürece katılma olasılığının en yüksek olduğu bir tekniktir. Arazi sahipleri açısından çekiciliği, yeniden düzenleme sonucunda toprak miktarı azalsa da oluşan yeni parsellerin değerinin artması, kamu kuruluşları açısından çekiciliği ise hizmet verilen kentsel parsellerin arzı ve kamu hizmet alanları ile altyapı gereksinimlerinin karşılanmasıdır [6]. Planlama otoriteleri için çekici olan yönü, imar planlarının bütüncül uygulamasına imkân vermesi, kamu tesisleri için çoğunlukla bedelsiz arazi sağlaması ve arazilerdeki hisse çözümlerinin engel teşkil etmediği modern şehircilik ilkelerine uygun parsel üretimini modelleyebilmesidir. AAD, yalnızca tarım arazilerini kullanılabilir kentsel parsellere dönüştürmek için etkili bir planlama aracı değil, aynı zamanda kentsel arazilerin bakımsız alanları için yeniden geliştirme tekniği, işe yaramaz parselleri ekonomik olarak kullanılabilir parsellere dönüştüren etkili bir plan uygulama tekniği, düzenleme sahasındaki sakinlerin çevre ve yaşam kalitesini iyileştirmek için temel kamu arazileri sağlayan etkili bir araçtır [7,8]. Bu uygulamanın en önemli özelliği, çok geniş alanlarda pratik bir şekilde kullanılabilmesi ve plan uygulama süresini kısaltmasıdır [9]. Ayrıca ihtiyaç duyulan kamu arazi kullanımlarına sahip standart erişilebilir parseller oluşturulması, kolayca alınıp satılabilen daha yüksek standartlı ve istikrarlı arazi değerleri, net ve tanımlanmış mülkiyet yapısı ve en aza indirilmiş mülkiyet paylaşımı ile hem arazi sahiplerine hem de kamuya çeşitli avantajlar sağlar [10]. Bu avantajlar yerel idareler üzerindeki kamusal tesisler sağlama yönündeki mali baskıyı azaltır, kamulaştırma ödemeleri büyük ölçüde azalır, belediye bütçesinin kullanımını olumlu yönde etkilenir ve diğer arazi geliştirme faaliyetlerine kaydırılabilir [11].

AAD'nin bütün bu avantajlarına rağmen uygulanma süreçlerinde önemli kısıtların olduğu göz ardı edilemez [12,13]. Çünkü 18.madde uygulama süreci kendi içinde ekonomik, hukuki, fiili ve teknik olarak birtakım zorluklar içerir [11,14]. İlk olarak yerel idare tarafından düzenleme sahasında mümkün olduğunca Düzenleme Ortaklık Payı (DOP) %45'e çok yakın olacak şekilde düzenleme sınırı geçirilir. DOP için üst sınır %45'tir. Düzenleme sahasındaki ortak kamusal alanların miktarına bağlı olarak DOP'nın üst sınırdan uygulanma zorunluluğu bulunmamaktadır. Ancak farklı düzenleme sahaları için farklı DOP kesintilerinin yapılması hem adaletsizliğe hem de yerel idareye karşı bir güvensizliğe neden olacağı için, yerel idareler genellikle düzenleme sahalarında DOP'u üst sınır veya üst sınıra çok yakın olacak şekilde belirlemeye çalışmaktadır. Böylece yerel idare uygulama sahasındaki ortak kamusal araziler için, parsellerin düzenleme öncesi yüzölçümlerinin %45'ine herhangi bir kamulaştırma bedeli ödemeksizin el koyabilmektedir. Bunun karşılığında, ilgili mevzuat arazi sahiplerinin iyi planlanmış ve göreceli olarak değerlendirilmiş standart imar parsellerine sahip olmanın finansal avantajını elde ettiğini varsaymaktadır. İkinci olarak, kadastro parsellerinin standart imar parsellerine tahsisi, her arazi sahibine planlı bölünmede kendine özgü bir özel parsel sağlamamakta ve her birinin yeniden düzenleme öncesindeki aynı konumda bir arazi parçası almasını garanti etmemektedir. Uygulama sonrasında yeni oluşan parsellerin değer kazanma oranlarındaki farklılıklar gözetilmeksizin bu ölçüde yüksek oranda bir kesinti yapılması, uygulamaya karşı çeşitli itirazların ortaya çıkmasına neden olmaktadır. Ayrıca, yeniden tahsis edilen yeni parsellerin imar planındaki konum, şekil ve yapılaşma haklarındaki adaletsizlikler, arazi sahiplerinin hassasiyetini arttırmaktadır. İlgili mevzuatta yeniden tahsis kuralları

detaylı bir şekilde açıklanmış olmasına rağmen büyük anlaşmazlıklara neden olmakta ve çoğunlukla mahkemeye taşınmaktadır [7]. Uygun arazi tahsisi yapılamaması nedeniyle arazi sahipleri tarafından mahkemeye çok sayıda uygulamanın iptali ile ilgili başvuru yapılmaktadır [1]. Mülkiyet hakkına doğrudan müdahale eden AAD uygulamalarının, mülk sahiplerinin itirazları ve memnuniyetsizlikleriyle karşılaşması kaçınılmazdır [15]. 3194 sayılı imar kanununun 18. Madde uygulaması sırasında yapılan hukuki ve teknik hatalar ile eksiklikler yıllar sonra bile ortaya çıkabilmekte ve ilgilisi tarafından idari yargıda açılan davalar sonucunda, uygulamanın iptali ile sonuçlanabilmektedir [14,16,17,18]. Bu durum, düzenleme sahasındaki inşaat, konut ve altyapı gibi projelerin uygulanmasını geciktirmekte veya engellemektedir [19]. AAD'nin yerel idareler tarafından yapılan her işlem için farklı sonuçlar doğurması nedeniyle idareye duyulan güven ve idari istikrar ilkeleri zedelenmekte ve arazi sahiplerinin haklı beklentileri yerel idarelerce korunamamaktadır [20]. Bu uygulama ile birlikte yürütülmesi gereken arazi sahiplerinin katılımı ve izleme-geri besleme boyutları yetersiz kalmakta, düzenleme sahasındaki uygulamanın yargı tarafından iptal edilmesi sonucu çoğu zaman uzun yıllar süren gecikmeler yaşanmakta ve amaca ulaşılamamaktadır [14].

Yargı kararı ile iptal edilen 18.madde uygulamalarının yeniden tesisi için yapılan idari işlemler “geri dönüş” olarak adlandırılmaktadır. Mahkeme tarafından verilen iptal hükmü yerel idareye, bu işlem hiç tesis edilmemiş gibi eski duruma tamamen geri dönülmesi görevini yüklemektedir [20]. Mahkemenin iptal kararı hukuki bir sonuç iken; bu sonuç geriye dönüş amaçlı teknik bir yöntem geliştirilmesini de zorunlu kılmaktadır. Ayrıca, geri dönüş işlemine ilişkin yasal mevzuatın yetersiz oluşu hatta uygulama yönetmeliğinin olmayışı, uygulayıcıları zor durumda bırakmakta [21], iptal sonrası yapılacak işlemler konusunda tereddütlerin yaşanmasına neden olmaktadır [18]. Geri dönüş işlemlerine ilişkin bu tereddütler, Tapu Kadastro Genel Müdürlüğü ile Çevre ve Şehircilik Bakanlığı'na bağlı birimler tarafından “görüş” geliştirilmek suretiyle giderilmeye çalışılmaktadır [17]. Ancak bu konuda standart bir uygulamanın olmayışı ve yasal boşluklar, geri dönüş sonrası meydana gelen mülkiyete ilişkin sorunları çözmede yetersiz kalınmasına ve geri dönüş sürecinin daha da zorlaşmasına neden olmaktadır. Bu nedenle yargı kararları iptali sonrasında yapılacak geri dönüş işleminin doğru bir şekilde gerçekleştirilebilmesi için yol gösterici çalışmaların yapılmasına ihtiyaç duyulmaktadır.

AAD'lerde yargı kararına dayalı iptal süreciyle ilgili, bu çalışma kapsamında literatürde incelenen çalışmalar aşağıdaki şekilde özetlenebilir:

Erdem ve Meshur [22]; Türkiye'de yapılan AAD sürecinde sorunları araştırmış ve taşınmaz sahiplerinin katılımcı süreçten dışlanması, yeniden düzenlenen arazinin değer, büyüklük ve ölçek yerine alan cinsinden paylarının hesaplanması ve planlama süreçleriyle ilgisi olmayan mesleklerin mevzuatla yetkilendirilmesini temel sorunlar olarak belirleyerek çözüm önerileri geliştirmiştir. Koç ve Babaoğlu [1]; AAD'lerde yeniden dağıtımla ilgili yapay zekâ algoritmalarına dayalı model geliştirmiştir. Hacıosmanoğlu ve Demir [18]; geri dönüşüm işlemlerini teknik ve hukuki açıdan inceleyerek idari yargının iptal kararlarına dayalı öneriler geliştirilmiştir. Çepni [23]; geri dönüşüm süreçlerinde yol fazlalıklarının geri dönüşmemesi dolayısıyla malikler aleyhine oluşan farkın bedel ile telafisine yönelik bir yöntem geliştirmiş ve bu yöntem yeniden yapılan idari yargılama sürecinde hukuka uygun bulunmuştur. Aybal ve Pehlivan [24]; idari yargı tarafından iptal edilen bir AAD'yi teknik ve hukuki açıdan inceleyerek yeniden yapılan arazi düzenlemesi sonucunda, DOP oranında, yapı bloğu içindeki parsellerin tahsis edilen alanlarında ve sosyal tesisleri içeren parsel sayısında herhangi bir değişiklik olmadığını tespit etmiştir. Çelik [17]; iptal kararı sonrası geri dönüş sürecinde düzenleme sahasındaki parsellerin kök parsel dönüş işlemlerini inceleyerek arazi sahiplerinin müktesep haklarının korunması için çeşitli öneriler geliştirmiştir. Pamuk ve Demir [25]; 1987-2014 yılları arasında Danıştay tarafından incelenen 314 adet iptal kararını analiz ederek iptal kararlarının nedenlerini tespit etmiş ve bu kararların uygulanmasının imkânsız olduğu durumlar için öneriler geliştirmiştir. Şimşek ve Uzun [21]; geri dönüş sürecini hukuki temelleriyle birlikte ele alarak, iptal kararından sonra parsellerin kök parsel durumuna getirilmesi sürecini incelemiş ve oluşan kazanılmış hakların korunması amacıyla çeşitli alternatif çözümler geliştirmiştir. Mintemur ve Çepni [15]; 2015-2023 yıllarını kapsayan 397 adet AAD dava dosyasındaki davacıların itiraz konularını gruplandırarak, itirazların nedenleri ve yargının iptal gerekçeleriyle olan ilişkilerini değerlendirmiştir.

Bu çalışma kapsamında incelenen literatürdeki çalışmalarda; Türkiye’de yapılan AAD’lerdeki sorunlar, yeniden dağıtım ile ilgili model geliştirme, geri dönüşüm işlemlerinin teknik ve hukuki açıdan incelenmesi, idari yargı tarafından iptal edilen AAD’lerin teknik ve hukuki açıdan incelenmesi, iptal kararı sonrası geri dönüş sürecinde düzenleme sahasındaki parsellerin kök parsel dönüş işlemlerinin incelenmesi, uygulamanın verimliliğini etkileyen temel kısıtlamalar ve idari yargının iptal kararları üzerinde durulmuştur. Bu çalışmada ise; geri dönüş işlemleri ile ilgili uygulamada karşılaşılan sorunlar ele alınarak, iptale konu olan yerel AAD uygulamaları üzerinden geri dönüş işlemlerinin nasıl yapıldığı incelenmiştir. Çalışmada üç farklı uygulama sahasında iptale neden olan teknik ve hukuki hatalar belirlenerek, geri dönüş süreçlerinin nasıl yapıldığı analiz edilmiştir. Bu dosyalarda iptale neden olan gerekçeler incelenerek geri dönüş sürecinde bulunan teknik çözümlerin iptal gerekçelerini giderip gideremediği ve arazi sahiplerinin taleplerini karşılama durumu analiz edilmiştir. Böylece, geri dönüş süreci ile ilgili uygulayıcılar açısından oluşan tereddütlerin ortadan kaldırılması ve iptal kararlarının azaltılmasına katkı sağlanması amaçlanmıştır.


2. Materyal ve Metod

2.1. Çalışma Sahası

Konya/Meram Belediyesi sınırları içinde mahkeme kararıyla iptal edilen 3 adet yerel örnek AAD dosyası çalışma sahası olarak seçilmiştir. Bu dosyalar seçilirken yaygın olarak iptale konu olan “müstakil parsel tahsisi mümkün iken yapılmaması”, “hazine parseli ile hisseli olma durumu” ve “düzenleme sınırının yanlış geçirilmesi” ile ilgili iptal gerekçeleri dikkate alınmıştır. Çalışma sahası verileri ilgili yerel idareden temin edilmiştir.

2.2. Yöntem

Çalışma sahasındaki seçilen 3 adet karakteristik geri dönüş dosyası ilgili mevzuata göre ayrıntılı olarak analiz edilerek, geliştirilen çözüm yaklaşımları ilgili mevzuat, arazi sahiplerinin hak kayıpları, kamunun kazanımları ve geri dönüşlerde beklentilerin karşılanması açısından değerlendirilmiştir. Ayrıca seçilen geri dönüş dosyalarındaki işlemler, iptalden itibaren ikinci uygulamanın yapılıp tapu tescillerinin oluşturulmasına kadar geçen süreçler Şekil 1’deki akış şemasına göre yapılmıştır.

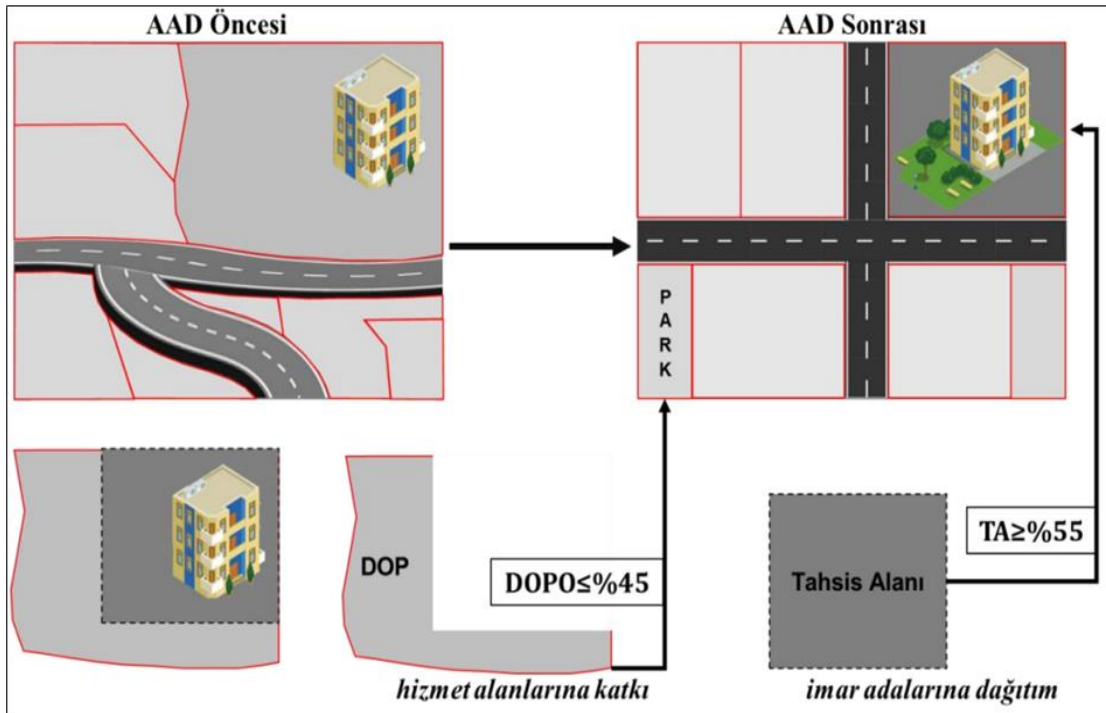


Şekil 1. Geri dönüş süreçlerindeki iş akışı [17]

2.3. Arazi ve Arsa Düzenlemelerinde Geri Dönüş Süreci

2.3.1. Arazi ve Arsa düzenlemesi (18. Madde Uygulaması)

AAD'lerde düzenleme sahası olarak belirlenen bölgede ortak kamusal alanlar (Yol, park, eğitim, spor alanları, kamu binaları vb.) için parsellerden %45 kesinti yapılarak mülkiyet dokusu imar planına uyumlu hale getirilir. AAD'ler 3194 sayılı imar kanununun 18. Maddesine göre re'sen (arazi sahiplerine sorulmadan) gerçekleştirilen bir uygulamadır. Bu uygulamanın amacı (1) kentlerde konut yapımı için yeterli imar parseli hazırlamak, planlı ve düzenli yerleşime yönelik yapıların imar planına, (2) sağlık ve çevresel şartlara uygun olarak oluşturulmasını sağlamak ve (3) imar planındaki ortak kamusal alanları (Yol, park, eğitim, spor alanları kamu binaları vb.) eş zamanlı olarak oluşturmaktır. 3194 sayılı imar kanununun 18. Madde uygulama süreci şekil 2'de gösterilmiştir.




Şekil 2. 3194 sayılı imar kanununun 18. Madde uygulama süreci [2]

AAD uygulamalarında uygulama mevzuatının eksik ve yeterince açık olmaması, uygulamanın alternatif çözümünün çokluğu, uygulayıcıların bilgi veya tecrübe eksikliği, taşınmaz maliklerinin bilinçsiz oluşu, haklarını zamanında savunamamaları, itirazları ilk inceleyen mahkemenin çok çeşitli davalara bakması ve bu konuda uzman olmayışı, bilirkişi heyetlerinin ehil nitelikte olmayışı ve usul yönünden yapılan hatalar bu konudaki önemli faktörlerdir [16,26].

18.madde uygulaması sürecindeki ekonomik, hukuki, fiili ve teknik zorluklar içeren uygulama adımlarının [14,21] beklenen şekilde gerçekleştirilememesi çoğunlukla ilgili yasal mevzuat hükümlerine aykırılık şeklinde ortaya çıkmaktadır. 18.madde uygulamasının yerel idareler tarafından yapılan her işlem için farklı sonuçlar doğurması nedeniyle idari istikrar ilkelerinin zedelenmesi ve bu süreçte arazi sahiplerinin haklı beklentilerinin yerel idarelerce karşılanmaması [27], uygulamaların yoğun bir şekilde idari yargıya götürülmesine neden olmaktadır [14]. Bu davalar, çoğunlukla ve haklı gerekçelerle yürütmenin durdurulması, 18. Madde uygulamalarının iptal edilmesi ve geri dönüş kararları ile sonuçlanmaktadır. Pamuk ve Demir [25] tarafından yapılan çalışmada; 1987-2014 yılları arasında AAD'nin iptal talebi ile ilgili idari yargıda Danıştay tarafından karara bağlanmış 233 adet dosya

incelemiş ve bunların %68'inin (158 adet AAD) iptal edildiği, %32'sinin (75 adet AAD) ise iptal talebinin red edildiği tespit edilmiştir. İdari yargıda iptal edilen elli yedi adet 18. madde uygulamalarının iptal nedenleri ve oransal dağılımı [17] Şekil 3'de gösterilmiştir.



Şekil 3. 18. madde uygulamalarının idari yargıda iptal nedenleri ve oransal dağılımı [17]

2.3.2. Geri Dönüş Süreci

Bir bölgede yapılan 18. Madde uygulamasının yargı kararı ile iptali sonucu, iptal kararının yerine getirilmesi için uygulama öncesi hukuki duruma yani kök parsellere yeniden dönülmesi işlemi "geri dönüş" [21] olarak kabul edilmektedir. Geri dönüş sürecinde hiçbir standardın hatta uygulama yönetmeliğinin bile olmaması [25], oldukça karmaşık bir işlem olan "kök parsele dönüş" işlemi daha da zorlaştırmaktadır. Kök parsele dönülse bile yıllar içinde değişen mülkiyet durumu, hisselilik, yapılaşma, kat mülkiyetlerinin kurulması ve buna benzer birçok değişim, ikinci uygulamada yapılacak dağıtımın daha da karmaşık bir hal almasına neden olmaktadır [16].

Yargı kararı ile iptal edilen 3194 Sayılı İmar Kanunu'nun 18. Madde uygulaması için geri dönüş işlemleri, 22.02.2020 tarih ve 31047 sayılı "Arazi ve Arsa Düzenlemeleri Hakkında Yönetmelik" in 37. ve 38. Maddelerine göre yapılmaktadır. Geri dönüş için verilen İptal hükmü yerel idareye, bu işlem hiç tesis edilmemiş gibi, uygulama öncesi durumu tamamen tesis ve iade etmek görevini yükler [20]. Yargının iptal kararı hukuki bir sonuç iken; bu sonuç geriye dönüş amaçlı teknik bir yöntem geliştirilmesini de zorunlu kılmaktadır. İdare Hukukunun temel ilkelerden biri olan "Yetki ve Usulde Paralellik İlkesi", yasada aksine bir hüküm bulunmadıkça, bir işlemin tesisinde uygulanan yetki ve usul koşullarının, aynı işlemin geri alınması ve iptalinde de aynen uygulanması zorunluluğunu vurgulamaktadır [28]. Bu durumda temel soru şudur; ilgili yerel idare eski durumu nasıl tesis edecektir? Yaygın olarak kullanılan görüşe göre, geri dönüş süreci iki şekilde gerçekleştirilmektedir [18,21]:

- İptal kararına konu olan veya iptal kararından etkilenen parseller hakkında "geri dönüşüm cetvelleri" düzenleyip, imar parselleri 18. Madde uygulaması öncesindeki mülkiyet durumuna çevrilir,
- "Geri dönüşüm cetvelleri" hazırlanarak imar parselleri eski haline çevrildikten sonra, iptal gerekçeleri de dikkate alınarak geri dönüşüm çalışması ile birlikte eş zamanlı olarak yeni bir 18. Madde uygulaması yapılır.

Gerçek dönüş cetvelinin görünümü Tablo 1'de gösterilmiştir.

Tablo 1 Geri dönüş cetveli görünümü [17]

Pafta-Ada No	Kad. Parsel No	D. Giren Senet Alanı	Bağış-Terk	Son Senet Alanı	DOP	Tahsis Alanı	KOP	İmar Tahsisi	DOP İadesi (1)	KOP İadesi (2)	İmar parseli İadesi (3)	Toplam İade (1+2+3)	Maliğin Adı-Soyadı
	15	7895.35		7895.35	3172.88	4812.47	584.54	4263.93	2811.23		4263.93	7075.16	
									361.65	548.54		910.19	
Toplam												7985.35	
	16	2623.78		2623.78	1042.53	1581.26	180.24	1401.02	923.70		1401.02	2324.72	
									118.83	180.24		299.07	
	17	11866.00		11866.00	4714.81	7151.19	815.11	6336.08	4177.40		6336.08	10513.50	
									537.41	815.11		1352.52	
	18	9380.62		9380.62	3727.28	5653.34	644.38	5008.96	3302.44			8311.40	
									4424.84		5008.96	1069.22	
										644.38			
Toplam		31855.75										31855.75	

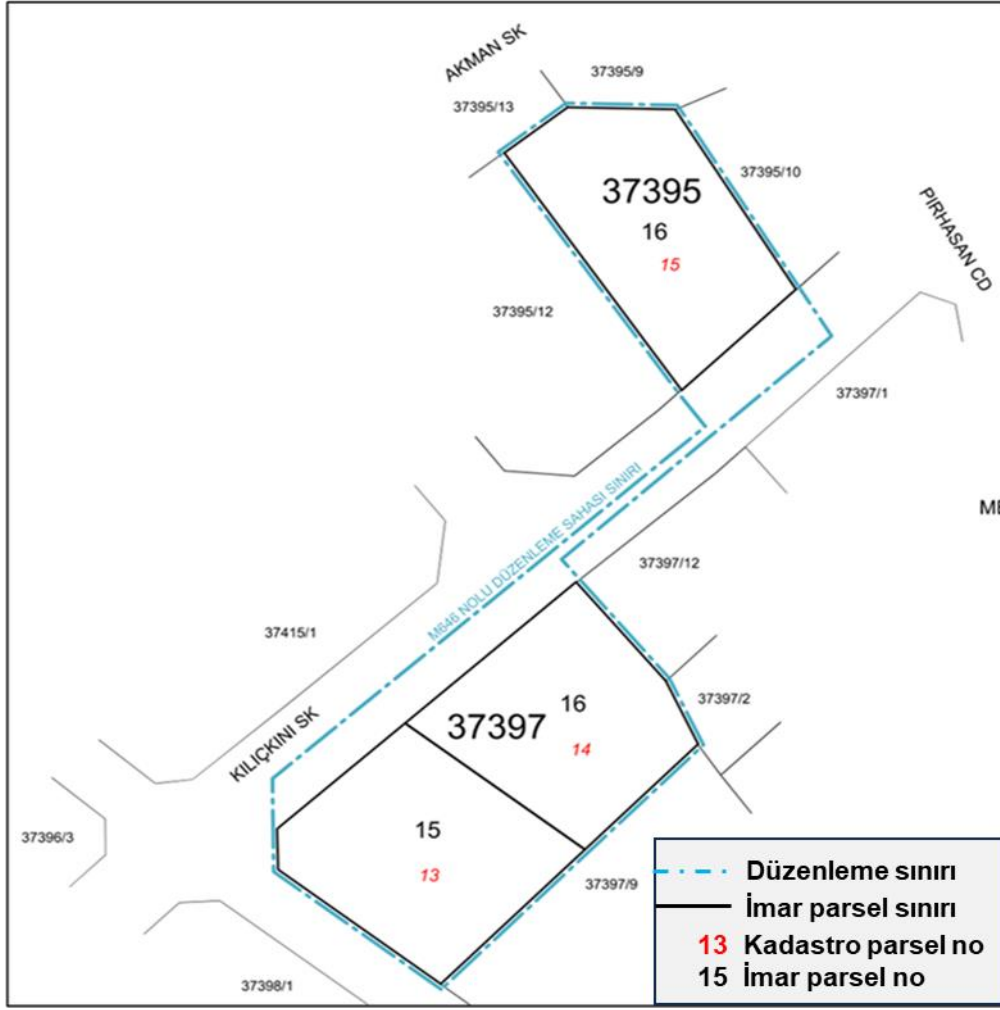
3. Bulgular ve Tartışma

Çalışma sahasında seçilen M646, M685 ve M677 nolu düzenleme sahaslarında veriler, idari yargının iptal gerekçeleri, yerel idarenin yaptığı yeni uygulamalar ve geri dönüş sonrası yapılan yeni düzenlemenin sonuçları ayrıntılı bir şekilde analiz edilmiştir. Elde edilen bulgular ile idari yargının iptal gerekçelerinin ortadan kaldırılıp kaldırılmadığı her dosya için ayrı ayrı tartışılmıştır.

M646 nolu düzenleme sahası verileri ve iptal gerekçeleri:


- **Konum:** Konya/Meram/ Karahüyük Mah.
- **Kadastro parselleri:** 13, 14, 15 nolu parseller
- **18 uygulaması sonucu iptal kararından etkilenen parseller:** 37395 ada 15 nolu, 37397 ada 13 ve 14 nolu parseller
- **18.madde uygulaması tescil tarihi:** 29/08/2018
- **İdari yargı kararı:** Konya 1. İdare Mahkemesinin 25/06/2019 tarih 2019/660 sayılı kararı ve Konya Bölge İdare Mahkemesi 2. İdari Dava Dairesinin 14/10/2020 tarih 2020/2226 sayılı kararı ile düzenleme sahasında yapılan uygulama iptal edilmiştir.
- **İptal için başvuran parsel:** 13 nolu kadaströ parseli
- **İptalden etkilenen parseller:** 13, 14, 15 nolu kadaströ parselleri ve 37397/15, 37397/16 ve 37395/16 nolu imar parselleri
- **İptal nedeni:** Uygulamadan önce 13 ve 14 müstakil parsel iken 13 nolu parselin bir miktar hissesi 37395/15 ile hisselendirilmiştir. Konya 1. İdare Mahkemesinin 25/06/2019 tarih 2019/660 sayılı kararı ve Konya Bölge İdare Mahkemesi 2. İdari Dava Dairesinin 14/10/2020 tarih 2020/2226 sayılı kararı ile M554 Nolu Düzenleme Sahasında yapılan uygulama, 13 nolu parsel müstakil verilebilecekken, verilmediği için uygulama iptal edilmiştir.

M646 nolu düzenleme sahası Şekil 4'de gösterilmiştir.



Şekil 4. M646 nolu düzenleme sahası

M646 nolu düzenleme sahasındaki geri dönüş süreci, yeniden yapılan uygulama ve tartışma: Bu düzenleme sahasında öncelikle iptalden etkilenen parselleri içine alan yeni bir düzenleme sınırı (M646) geçirilmiştir (Şekil 5). Daha sonra 37397/15, 37397/16 ve 37395/16 nolu imar parselleri Tablo 1’de gösterilen geri dönüş cetvelleri hazırlanarak kök parsel yani 13, 14, 15 nolu kadastro parsellerinin düzenleme öncesi haline dönüş işlemi yapılmıştır. Bu işlemden sonra da iptalden etkilenen parseller için ikinci kez 18. Madde uygulaması yapılmıştır. İkinci kez yapılan 18. Madde uygulamasında arazi sahiplerinin de görüşleri alınarak, 13 nolu parselin yola gelen kısmı DOP ‘tan fazla olduğu ve aradaki sınır, mevcut yapılardan dolayı kaydırılmadığı için (fiili ve hukuki zorunluluk) 37395/15’e verilen hisse, tekrar 13 nolu parselde verilerek bu parsel müstakil hale getirilmiştir. Bunun için 13 ve 14 nolu parsellerin arasındaki sınır, DOP’u kurtaracak şekilde 14 nolu parseldeki yapı sınırına kadar kaydırılmış (Şekil 5), ve 14 nolu parsel de müstakil hale getirilmiştir. 14 nolu parselden eksilen miktar ise 15 nolu parselde verilerek 14 nolu parsel, 15 nolu parsel ile hisseli hale getirilmiştir. Sonuçta 2 müstakil, 1 hisseli parsel oluşturulmuştur. Uygulamanın iptali sonrası yapılan yeni düzenlemede görüldüğü gibi 13 nolu parselin müstakil parsel olarak verilebilmesi mümkündür. Bu nedenle M646 nolu düzenleme sahasında 13 nolu parselin yaptığı itirazın haklı bir nedene dayandığı söylenebilir. Yeni düzenlemede uygulanan bu çözüm ile 13 nolu parselin haklı talebi yerine getirilmiştir. Ayrıca yeni yapılan uygulamada 14 nolu parsel de müstakil hale getirilmiş ancak bir miktar hissesi fiili ve hukuki zorunluluklardan dolayı 15 nolu parselde kaydırılmıştır. Bu durumda 14 nolu parsel için de daha uygun bir çözüm üretilmiştir.

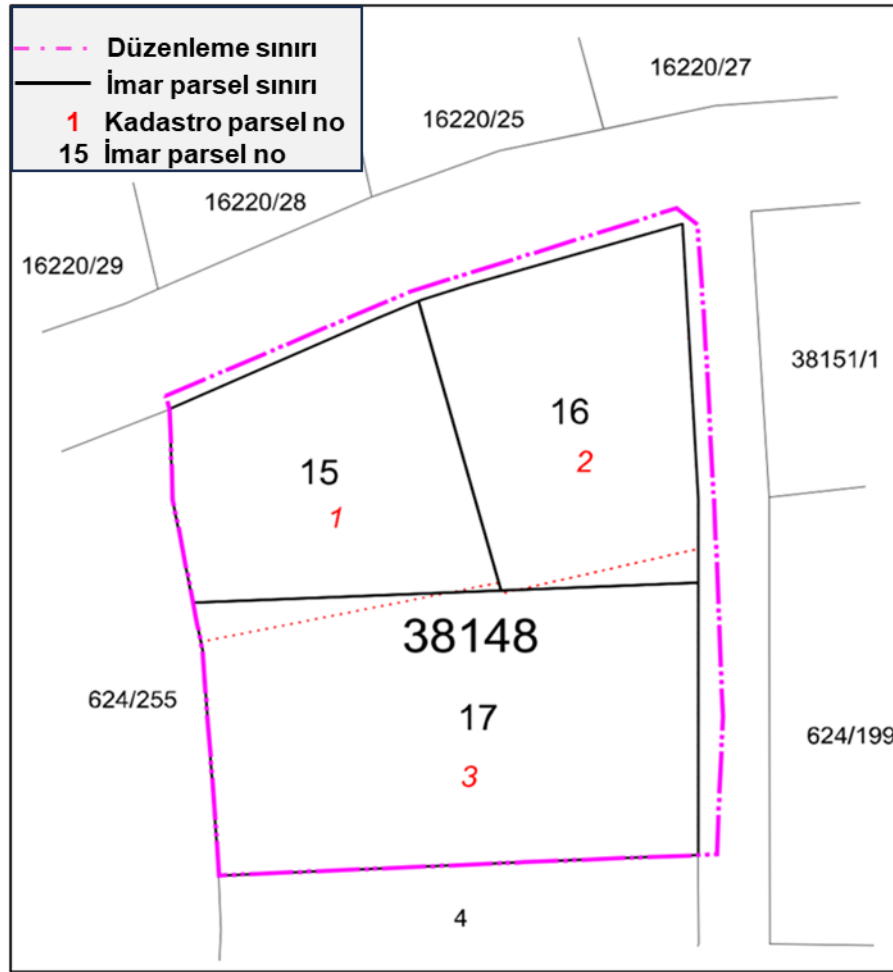


Şekil 5. M646 nolu düzenleme sahası ve yeni uygulama sonrası durum

M685 nolu düzenleme sahası verileri ve iptal gerekçeleri:

- **Konum:** Konya/Meram/ Hacışaban Mah.
- **Kadastro parselleri:** 1, 12, 3 nolu parseller
- **18 uygulaması sonucu iptal kararından etkilenen parseller:** 38148 ada 15, 16 ve 17 nolu parseller
- **Parsel:** 38148 ada 1, 2 ve 3 nolu parseller
- **18.madde uygulaması tescil tarihi:** 05/10/2020
- **İdari yargı kararı:** Konya 2. İdare Mahkemesi'nin 31/03/2022 tarih 2022/370 sayılı kararı ile düzenleme Sahasında yapılan uygulama iptal edilmiştir.
- **İptal için başvuran parsel:** 1 nolu kadastro parseli
- **İptalden etkilenen parseller:** 1, 2, 3 nolu kadastro parselleri ve 3148/15, 3148/16 ve 3148/17 nolu imar parselleri
- **İptal nedeni:** Uygulamadan önce 1 nolu kadastro parseli, hazine + 2 nolu kadastro parseli ile hisseli, 2 nolu kadastro parseli müstakil, 3 nolu kadastro parseli ise hazine ile hisselidir. 1 nolu parsel, ağaçlarının bir kısmının 3'ün sınırlarında kaldığını ve hem sınırının düzeltilmesini hem de parselinin müstakil hale getirilmesini istemektedir. Mahkeme, 1 nolu parseli "düzenleme öncesi hisse yapısı korunmak üzere tam hisse ile müstakil bir imar parseli tahsis edilmesi işleminin teknik olarak

mümkün olduğu halde bunun yapılmadığı” gerekçesiyle uygulamayı iptal etmiştir. M685 nolu düzenleme sahası Şekil 6’de gösterilmiştir.



Şekil 6. M685 nolu düzenleme sahası

M685 nolu düzenleme sahasındaki geri dönüş süreci ve tartışma: Bu düzenleme sahasında önce 3148/15, 3148/16 ve 3148/17 nolu imar parselleri, kök parsel yani 1, 2, 3 nolu kadaströ parsellerinin düzenleme öncesi haline dönüş işlemi yapılmıştır. Sonra iptalden etkilenen parseller için ikinci kez 18. Madde uygulaması yapılmıştır. İkinci kez yapılan 18. Madde uygulamasında arazi sahiplerinin de görüşleri alınarak 1 nolu parseldeki hazine hissesi (3 nolu parselin hazine ile ortak olmayı kabul ettiği teyit edilerek) 3 nolu parsel, 2 nolu parselin 1 nolu parseldeki hissesi 2 nolu parsel eklenerek, 1 nolu parsel müstakil hale getirilmiştir. Ancak DOP kesintisinden dolayı aradaki sınır eski yerine getirilememektedir. Çünkü 1 ve 3 nolu parsel arasındaki sınır eski haline getirilirse kuzeydeki sınırın güneye doğru geri çekilmesi gerekmektedir. Bu durum, Şekil 7’de gösterilen 1 nolu parseldeki mevcut yapıyı etkileyecektir. Teknik zorunluluktan dolayı bu sınır geriye çekilememiştir. Doğudaki sınırın geriye çekilmesini ise mevcut ağaçlarının doğudaki parselde kalacağı nedeniyle arazi sahibi tarafından kabul edilmemiştir. Sonuçta mahkeme kazanılmış olsa bile, fiili ve hukuki zorunluluklardan dolayı 1 nolu parselin müstakil olma talebi karşılanmış ancak sınırın eski haline getirilmesi ile ilgili talebi karşılanamamıştır. Ayrıca 1 ve 3 nolu parseller arasındaki sınırın fiili ve hukuki zorunluluklardan dolayı eski haline getirilemeyeceği arazi sahibi tarafından kabul edilmiştir. Şekil 7’de görüldüğü üzere 1 ve 2 nolu parsel arasındaki sınır, 2 nolu parselde kalacaktır. 2 nolu parsel sahibi yeni

uygulama gereğince söz konusu yapının yıkılmasını, yapının oldukça eski olması ve müstakil parsel olma kazanımı nedeniyle kabul etmiştir. Böylece 2 nolu parsel de müstakil hale getirilmiştir. Yeni dağıtımda 1 nolu parsel sahibine 3148/15 nolu imar parseli, 2 nolu parsel sahibine 3148/16 nolu imar parseli, 3 nolu parsel sahibine ise 3148/17 nolu imar parseli tahsis edilmiştir. Yeni yapılan uygulama sonucunda 1 nolu parselin talebi kısmen karşılanırken, 2 nolu parsel müstakil hale getirilmiş, 3 nolu parsel ise hazine ile hisselendirilmiştir. Bu durumda 2 ve 3 nolu parseller için de daha uygun bir çözüm üretilmiştir.



Şekil 7. M685 nolu düzenleme sahası ve yeni uygulama sonrası durum

M677 nolu düzenleme sahası verileri ve iptal gerekçeleri:

- **Konum:** Konya/Meram/ Büyükkovanağzı Mah.
- **Parsel:** M677 nolu düzenleme sahasının tamamı
- **18.madde uygulaması tescil tarihi:** süreç devam ediyor
- **18.madde uygulaması 2. Askı:** 14/09/2022
- **İdari yargı kararı:** 2501/85 nolu parsel sahibinin başvurusuna istinaden Konya İdare Mahkemesi başvuru sahibinin talebini dikkate almamış ancak düzenleme sınırının yanlış geçirildiği gerekçesiyle M677 nolu düzenleme sahasının tamamında yapılan uygulama iptal edilmiştir. Yerel idare karara itiraz etmiş olup süreç devam etmektedir.
- **İptal için başvuran parsel:** 2501/85
- **İptalden etkilenen parseller:** Düzenleme sahasındaki bütün parseller

- **Davada talep edilen:** Düzenleme sınırı içindeki parseller, daha önce parselasyon uygulaması görmüş olup %32 DOP kesintisi ile terk yapılarak oluşturulmuş parsellerdir. Plan tadilatı nedeniyle yapılan 18. Madde uygulamasında ikinci defa DOP kesintisi yapılmaması talep edilmektedir.
- **İptal nedeni:** Düzenleme sınırının yanlış geçirilmesi.

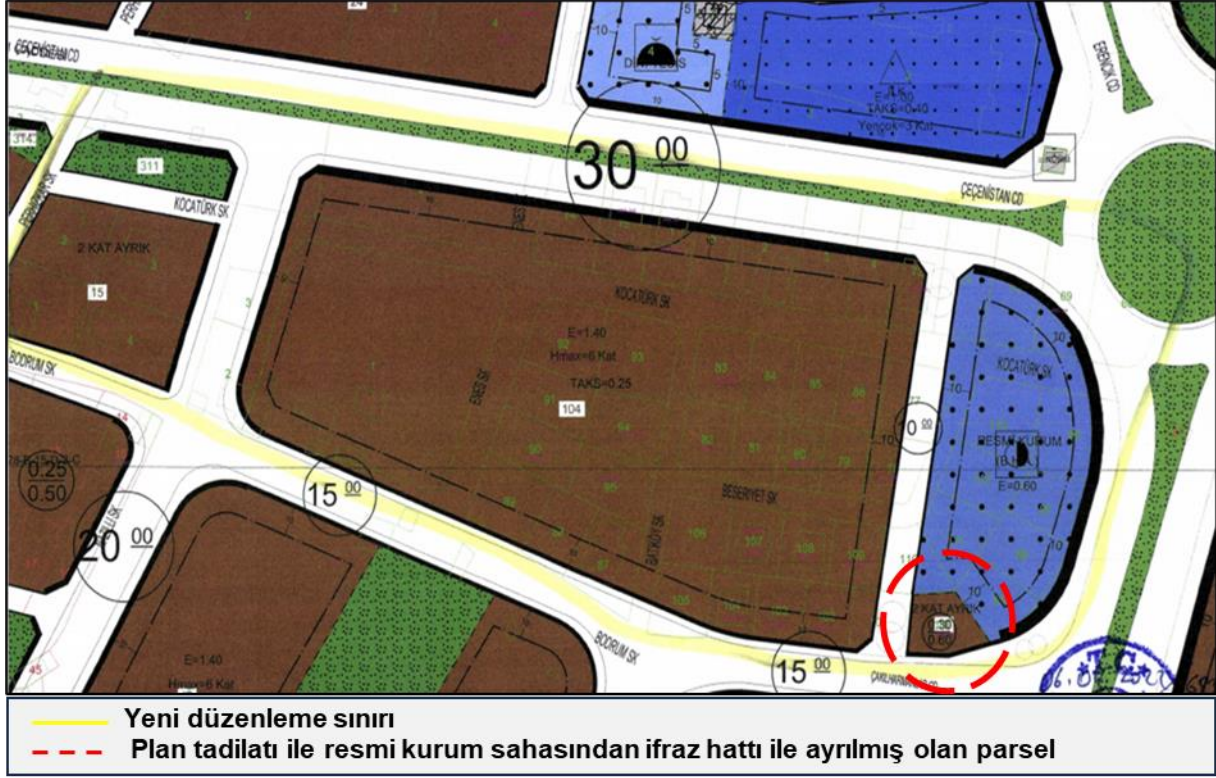
M677 nolu düzenleme sahasının iptal kararı öncesi düzenleme sınırı Şekil 8’de gösterilmiştir.



Şekil 8. M677 nolu düzenleme sahasının iptal kararı öncesi düzenleme sınırı

M677 nolu düzenleme sahasındaki iptal kararının irdelenmesi ve yeni düzenleme süreci: Şekil 8’de gösterilen M677 nolu düzenleme sahasında, ikinci defa DOP kesintisi yapılmaması talep edilmesine rağmen, ilgili mahkeme düzenleme sınırının yanlış geçirilmesi nedeniyle bu düzenleme sahasındaki uygulamayı iptal etmiştir. Mahkemenin kararı ilgili mevzuata göre doğru olmakla birlikte, yerel idare bu düzenleme sahasının sınırını yürürlükteki imar planında mevcut olan fiili bir durumu dikkate alarak geçirdiği için mevzuata aykırılık meydana gelmiştir. 3194 sayılı İmar Kanunu’nun 22.02.2020 tarihli Arazi ve Arsa Düzenlemeleri Hakkında Yönetmeliğin 10/2 maddesine göre; düzenleme sınırı “*Yola cephesi olmayan parsel oluşturmamak kaydıyla iskân sahası içindeki yollardan*” geçerilir. Buna göre düzenleme sınırı yollardan geçirilmeli, imar adasını bölmemelidir. Ancak Şekil 8’de görüldüğü üzere M677 nolu düzenleme sahasının sınırı 48240 nolu adayı bölecek şekilde geçirilmiştir. Ancak bu durum Şekil 9’da gösterilen yürürlükteki imar planında 48240/100 nolu parselin plan tadilatı ile resmi kurum sahasından ifraz hattı ile ayrılmış olmasından kaynaklanmaktadır. Bu parsel Şekil 8’de görüldüğü üzere yapılaşmasını tamamlamış ve diğer parseller gibi parselasyon görmüş bir parseldir. 48240/100 nolu parsel, tadilat öncesi 48240 nolu adanın içinde ve planda resmi kurum sahası olarak yer almaktadır. Yerel idare yapılaşmış bir parselin yüksek kamulaştırma maliyetinden kaçınmak istemesi nedeniyle bu parseli ifraz hattı ile adadan ayırmış ve adanın geriye kalan kısmını resmi kurum için yeterli görmüştür. Düzenleme sınırı belirlenirken planda var olan ifraz hattı dikkate alınarak, bu parsel düzenleme sahasının dışında bırakılmıştır. Ayrıca plan tadilatında bu parselin yapılaşma koşullarında herhangi bir değişiklik yapılmadığı için (2 kat, emsal:0.60), herhangi

bir yapılaşma kazanımı ve değer artışı da söz konusu değildir. Uygulayıcı bu durumu dikkate alarak bu parseli düzenleme sahasının dışında bırakmıştır. Bu parsel eğer düzenlemeye dahil edilirse DOP kesintisi de yapılacaktır. Fakat DOP kesintisi plandan ve yapılaşma koşullarının iyileştirilmesinden gelen değer artışları sonucunda kesildiği için yapılacak yeni uygulamanın iptal edilme olasılığı çok daha yüksek olacaktır.



Şekil 9. Yürürlükteki imar planında 48240/100 nolu parselin plan tadilatı ile resmi kurum sahasından ifraz hattı ile ayrılmış hali ve M677 nolu düzenleme sahasının yeni sınırı

Yerel idare mahkeme kararını dikkate alarak 48240/100 nolu parseli şekil 9'da gösterildiği şekliyle düzenleme sahasına dahil etmiştir. Ancak yeni düzenleme sınırına göre bu parselden de DOP kesintisinin yapılması gerekmektedir. Bu parselin yürürlükteki plan verilerine göre yapılaşmasını tamamlamış olduğu ve parselin geometrisinden dolayı fiili olarak DOP kesintisi yapılmasının mümkün olmadığı Şekil 9'da görülmektedir. Bu nedenle bu parsel için yapılacak DOP kesintisinin bedele dönüştürülerek alınması söz konusu olacaktır (3194 sayılı İmar Kanunu'nun 22.02.2020 tarihli Arazi ve Arsa Düzenlemeleri Hakkında Yönetmeliği md. 16/1). Yerel idare diğer 3194 Sayılı İmar Kanunu'nun 18. Madde uygulamalarının iptal kararlarında olduğu gibi, bu süreçle ilgili olarak parsel sahibini bilgilendirmiştir. Ancak parsel sahibi DOP'un bedele dönüştürülerek alınmasını kabul etmemiş ve böyle bir durum olması durumunda mahkemeye başvuracağını belirtmiştir. Uygulamayı yapan yerel idare bu durumu yerel mahkemenin kararına yaptığı itirazda ayrıntılı olarak belirtmiştir. Yerel idare, ilgili parsel sahibinin yeni uygulamayı kabul etmemesi nedeniyle süreci durdurmuş, yerel ve üst mahkemelerdeki itiraz süreci sonuçlarının beklenmesine karar vermiştir. Bu durum yeni uygulama sürecini oldukça uzatacağı için düzenleme sahası içindeki diğer parsel sahiplerinin mağduriyeti ve kamusal kayıpların olması kaçınılmaz olacaktır.

Çalışma sahasındaki dosyaların geri dönüş süreçlerinden elde edilen bulgular için genel bir değerlendirme yapmak gerekirse; M646 nolu düzenleme sahasındaki geri dönüş sürecinde 13 nolu parselin haklı talebi yerine getirilmiştir. Ayrıca yeni yapılan uygulamada 14 nolu parsel de müstakil hale

getirilmiş ancak bir miktar hissesi fiili ve hukuki zorunluluklardan dolayı 15 nolu parsel kaydırılmıştır. Bu durumda 14 nolu parsel için de daha uygun bir çözüm üretilmiştir. M685 nolu düzenleme sahasındaki geri dönüş sürecinde 1 nolu parselin talebi kısmen karşılanırken, 2 nolu parsel müstakil hale getirilmiş, 3 nolu parsel ise hazine ile hisselendirilmiştir. Bu durumda 2 ve 3 nolu parseller için de daha uygun bir çözüm üretilmiştir. M677 nolu düzenleme sahasındaki geri dönüş sürecinde ise, imar planındaki fiili durumdan dolayı iptal kararına neden olan düzenleme sınırı yeniden mevzuata uygun olarak geçirilmiştir. Ancak yeni düzenleme sınırına dahil edilen 48240/100 nolu parselden kesilecek olan DOP'un plandaki fiili durumdan dolayı bedele dönüştürülerek tahsil edilecek olması, ilgili parsel sahibi tarafından kabul edilmemiştir. Yerel idare, parsel sahibinin yeni yapılacak geri dönüş uygulamasına itirazı durumunda, ilgili mevzuata göre haklı çıkacağını ve yeni uygulamanın da iptal edileceğini öngörerek geri dönüş sürecini durdurmuştur. Ayrıca yerel idare, iptal öncesi düzenleme sınırının plandaki fiili durumdan kaynaklandığını ayrıntılı olarak raporlayarak mahkeme kararına itiraz etmiştir. Bu durum geri dönüş sürecini oldukça uzatacağı için düzenleme sahası içindeki diğer parsel sahiplerinin mağduriyeti ve kamusal kayıpların olması kaçınılmaz olacaktır.

4. Sonuç ve Öneriler

3194 Sayılı İmar Kanunu'nun 18. Madde uygulamasının yürürlükteki kurallara uygun biçimde yapıp yapılmadığı idari yargı ile denetlenmektedir. Arazi sahipleri, 18. Madde uygulamasında yapılan hukuki ve teknik hatalar ile, menfaatlerinin ihlal edildiği gerekçesiyle idari yargıda hak arama yoluna gitmektedir. Açılan davalar çoğunlukla "iptal ve geri dönüş" kararları ile sonuçlanmaktadır. Geri dönüş kararlarının nasıl uygulanacağı ile ilgili yasal mevzuatta yeterince bir açıklık olmaması, kazanılmış haklarla ve mülkiyetle ilgili ciddi bazı sorunlara neden olmaktadır. Bu çalışmada idari yargıda 3194 Sayılı İmar Kanunu'nun 18. Madde uygulamasında yapılan hukuki ve teknik hatalar ile, arazi sahiplerinin menfaatlerinin ihlal edildiği gerekçesiyle iptal edilen düzenleme sahalari, örnek uygulamalar üzerinden ayrıntılı olarak analiz edilmiştir. Çalışmada örneklenen geri dönüş süreçleri ve tespit edilen iptale konu teknik ve hukuki hatalar, uygulayıcılara yeni bakış açıları kazandırarak 18. Madde uygulamalarının iptalini önemli oranda azaltabilir. İptal kararlarının %50 den fazlası DOP ve yeniden tahsiste yapılan teknik hatalarla ilgilidir. Mağduriyetlerin ve kamu zararlarının önlenmesi için yasal mevzuat iptal kararları dikkate alınarak yeniden düzenlenebilir. Yerel idare 1 aylık askı süreci yerine doğrudan tebligatı esas alarak arazi sahiplerinin katılımını ve çift yönlü iletişimi sağlamalıdır. Özellikle geri dönüş işleminin tekrar idari dava konusu olmaması için uygulayıcılar çözüm önerilerini ilgili arazi sahipleri ile paylaşmalıdır. Uygulamanın idari bir işlem olması, re'sen yapılması ve %45 oranındaki bedelsiz DOP kesintisi, arazi sahiplerinin hassasiyetini arttırmaktadır. Ancak, söz konusu bedelsiz kesintinin yeni oluşan imar parsellerindeki düzenleme dolayısıyla olan değer artışına karşılık olduğu belirtilmesine karşın, değer tespitine ilişkin bir düzenlemenin hala yapılmamış olması ve tüm taşınmazların eşit oranda değerlendirildiği varsayılarak, dağıtım yapılması önemli bir sorun olarak ortada durmaktadır. Bu sorun, yapılan uygulamalarda geri dönüşle sonuçlanan iptal kararlarının en temel nedenidir ve bu düzenlemenin uygulama yeteneğini giderek azaltmaktadır. Bu nedenle birçok araştırmaya konu olan "Değer Esaslı Dağıtım" ile ilgili düzenlemelerin bir an önce yapılması elzemdir. Geri dönüşün hukuki veya fiili nedenlerle mümkün olmadığı durumlarda (satış, ruhsatlandırma, fiili yapılaşma vb.), kazanılmış hakların rayiç bedel üzerinden karşılanması yolu tercih edilebilir (İmar Kanunu, 1985, Değişiklik, 2019, 18/10). Ayrıca yerel idarelerin 3194 sayılı imar kanununun 18. Madde uygulamalarında üniversitelerdeki ilgili uzmanlardan teknik destek almaları, iptallerin azaltılmasında önemli katkı sağlayabilir.

Teşekkür

Konya Meram Belediyesi ve Harita Mühendisi Vahap Sevindik'e bu çalışmaya katkılarından dolayı teşekkür ederim.

Çıkar Çatışması Beyanı

Makalenin yazar/yazarları, çalışma kapsamında herhangi bir kişisel ve finansal çıkar çatışması olmadığını beyan etmektedirler.

Kaynaklar

- [1] Koc I, Babaoglu I. A comparative study of swarm intelligence and evolutionary algorithms on urban land readjustment problem. *Applied Soft Computing* 2021; 99: 106753.
- [2] Uzun B, Yıldırım V, Terzi F, Atasoy BA, Uzun S. Arazi ve Arsa Düzenlemesi Uygulamalarında Bedele Dönüştürme Miktarının Tespiti. *Karadeniz Fen Bilimleri Dergisi* 2024; 14(3):1604-1622.
- [3] Yilmaz A, Çağdaş V, Demir H. An evaluation framework for land readjustment practices. *Land Use Policy* 2015; 44: 153-68.
- [4] Gielen DM. Proposal of Land Readjustment for the Netherlands: An analysis of its effectiveness from an international perspective. *Cities* 2016; 53:78–86.
- [5] Sorensen A. Conflict, consensus or consent: Implications of Japanese land readjustment practice for developing countries. *Habitat international* 2000; 24(1):51–73.
- [6] Turk SS. Land readjustment: An examination of its application in Turkey. *Cities* 2005; 22(1):29–42.
- [7] Kucukmehmetoglu M, Geymen A. Optimization models for urban land readjustment practices in Turkey. *Habitat international* 2016; 53:517-533.
- [8] Yilmaz A, Çağdaş V, Demir H. An evaluation framework for land readjustment practices. *Land Use Policy* 2015; 44:153–68.
- [9] Turk SS. An analysis on the efficient applicability of the land readjustment (LR) method in Turkey. *Habitat Int.* 2007; 31(1):53–64.
- [10] Türk ŞŞ. Arazi ve arsa düzenlemesi yöntemi ve uluslar arası çerçevede etkin uygulanabilirliği. *ITU Journal Series A: Architecture, Planning, Design* 2009; 8(1):117–126.
- [11] Uzun B, Celik Simsek N. Land readjustment for minimizing public expenditures on school lands: a case study of Turkey. *Arabian Journal of Geosciences* 2018; 11:228.
- [12] Alp E. 3194 Sayılı İmar Kanunu 18. Madde İmar Uygulamaları ve Karşılaşılan Sorunlar: Van Örneği. Yüksek lisans tezi. Gebze: Gebze Teknik Üniversitesi; 2019.
- [13] Türk ŞŞ. Türkiye’de imar planı uygulamalarında yeni bir sistem yaklaşımı. Doktora tezi. İstanbul: İstanbul Teknik Üniversitesi; 2003.
- [14] Akdeniz H. Kent Planlarının Uygulama Aracı Olarak Arazi ve Arsa Düzenlemesi. *İdealkent* 2022; 13(37):1753–71.
- [15] Mintemur ŞS, Çepni MS. Arazi ve arsa düzenlemesine yapılan itirazların davacı dilekçeleri esas alınarak incelenmesi. *Geomatik* 2024; 9(2):164–74.
- [16] Atasoy M, Demir O, Uzun B, Nişancı R. İmar Uygulamalarının İptal Nedenleri ve Öneriler. Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Öğretiminde 30. Yıl Sempozyumu, Konya, Türkiye; 2002.
- [17] Çelik N. İptale konu imar planı uygulamalarında geri dönüş işleminin irdelenmesi ve çözüm önerileri yaklaşımı. Yüksek lisans tezi. Trabzon: Karadeniz Teknik Üniversitesi; 2013.
- [18] Hacıosmanoğlu S, Demir H. Arazi ve arsa düzenlemelerinin geri dönüşüm işlemlerinde yargı kararlarına dayalı öneriler. *Jeodezi ve Jeoinformasyon Dergisi* 2020; 7(1):47-69.
- [19] Güngör R, İnam Ş. İmar Uygulamalarında Farklı Dağıtım Metotlarının Karşılaştırılması. *Geomatik* 2019; 4(3):254-63.

- [20] Ergen C. İmar planları. Seçkin Yayıncılık; 2009.
- [21] Şimşek NÇ, Uzun B. İptale Konu İmar Planı Uygulamalarında Geri Dönüş İşleminin İrdelenmesi. Türkiye Adalet Akademisi Dergisi 2018; 33:709-720.
- [22] Erdem R, Meshur MC. Problems of land readjustment process in Turkey. Scientific Research and Essays 2009; 4(8):720-727.
- [23] Çepni, MS. İdari yargıda yol fazlalıklarının belediye lehine kullanımı gerekçesiyle iptal edilmiş imar uygulamalarında çözüm önerisi. Geomatik 2023; 8(2):192-199.
- [24] Aybal S, Pehlivan H. Evaluation of a land readjustment cancelled by a court decision from a technical perspective: A case study in Türkiye. Advanced Land Management 2023; 3(2):90-96
- [25] Pamuk H, Demir H. Türkiye’de Arazi ve Arsa Düzenlemelerinin İptal Nedenleri. 16. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara, Türkiye; 2017.
- [26] Atasoy, M. İmar Uygulamalarına İlişkin Hukuki Kararların İrdelenmesi, Yüksek lisans tezi, Trabzon: Karadeniz Teknik Üniversitesi; 1997.
- [27] Karaca AG. İmar Planı Uygulama Yöntemlerinden Arazi ve Arsa Düzenlemesinin İlgili Mevzuat Çerçevesinde İncelenmesi. Uyuşmazlık Mahkemesi Dergisi. 2018; 11:217-261.
- [28] Hasoğlu A. Danıştay Kararları Işığında Yetki ve Usulde Paralellik İlkesi. Türkiye Adalet Akademisi Dergisi 2018; 33:123-42.

İÇMESUYU SİSTEMLERİNDE BASINÇ YÖNETİMİ UYGULAMALARININ MALİYET FAYDA ANALİZİ

Merve AKDEMİR¹, Salih YILMAZ^{2*}

^{1,2} Çankırı Karatekin Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Çankırı, Türkiye
Geliş Tarihi/Received Date: 01.11.2024 Kabul Tarihi/Accepted Date: 25.12.2024 DOI: 10.54365/adyumbd.1577489

ÖZET

İçmesuyu yönetiminde kayıplarla mücadele günümüzde en önemli çalışmalardan biri olmuştur. Artan su ihtiyaçları ile birlikte azalan temiz su kaynakları içmesuyu sistemlerinde su kayıplarıyla mücadelenin önemini artırmıştır. Basınç yönetimi ise uluslararası literatürde en önemli su kayıp mücadele yöntemi olarak görülmektedir. Bu çalışmada su kayıp yönetimi kapsamında 4 farklı izole alt bölgede basınç yönetimi uygulanmıştır. Basınç yönetimi uygulaması yapılan izole alt bölgeler birbirinden farklı basınç düzenleme yöntemleriyle Kayseri Su ve Kanalizasyon İdaresi (KASKİ) tarafından işletilen şebekelerden seçilmiştir. Basınç düzenlemesi yapılmasının finansal olarak ne kadar fayda sağlayacağı oluşturulan algoritmalarla teorik olarak hesaplanmıştır. Teorik hesaplamaların doğruluğu gerçek saha uygulaması sonuçlarıyla kıyaslanarak algoritmanın doğruluğu test edilmiştir. Teorik hesaplamaların doğruluğunun analiz edilmesinin ardından maliyetler de hesaplanarak fayda ve maliyet analizi yapılmış ve yatırımın geri dönüş süresi hesaplanmıştır.

Anahtar Kelimeler: İçme suyu dağıtım sistemi, basınç yönetimi, sızıntı, fayda maliyet analizi, su kaybı.

COST-BENEFIT ANALYSIS OF PRESSURE MANAGEMENT PRACTICES IN DRINKING WATER SYSTEMS

ABSTRACT

Combating losses in drinking water has become one of the most essential freedoms today. With increasing water problems, the decreasing clean water resources have increased the fight against water losses in drinking water systems. In international literature, pressure management is the most important method of fighting against water loss. In this study, pressure management was applied in 4 different isolated sub-regions within the scope of water loss management. The isolated sub-regions under pressure management were selected from the networks operated by the Kayseri Water and Wastewater Administration (KASKİ) with different pressure regulation methods. The financial benefits of pressure regulation were theoretically calculated using algorithms. The algorithm's accuracy was tested by comparing the accuracy of the theoretical calculations with the actual field practice results. After analyzing the accuracy of the theoretical calculation, the costs were also calculated, and the return period of the investment was calculated by making a benefit and cost analysis.

Keywords: Water distribution systems, pressure management, leakage, cost-benefit analysis, water loss.

e-posta¹: merveakdemir0618@gmail.com ORCID ID: <https://orcid.org/0000-0002-8982-6698>

* e-posta²: salihyilmaz@karatekin.edu.tr ORCID ID: <https://orcid.org/0000-0002-3206-1225> (Sorumlu Yazar)

1. Introduction

Today, the amount of clean drinking water is decreasing day by day due to reasons such as the increase in population, industrialization and urbanization rate, pollution of clean water resources as a result of unconscious use of water resources, and the negative impact of climate change on water resources [1]. Our world consists of 71% water and 29% land. Only 2.5% of these waters are freshwater resources that can be used for drinking water supply. 68.9% of freshwater resources are glacial, 30.8% are groundwater, and 0.3% are accessible clean drinking water resources [2]. It is a danger on a global scale that the amount of water resources used for drinking water supply is low and decreasing daily due to increasing population, urbanization, and industrialization [3].

Utilities are responsible for delivering sufficient clean water to subscribers and supporting economic growth and environmental sustainability through their services [4]. In clean water supply, it is essential to prevent water loss in the network and return this water to the system. The difference between the water supplied to the distribution system and the water reaching the subscribers is defined as water loss. Water losses are divided into two groups: administrative and physical water losses. Cracks and fractures in the pipes due to damage to the pipes due to pressure fluctuations play a significant role in the formation of water losses [1,5]. Various methods, such as pressure management, active leakage control, passive leakage control, failure management, and pipe material management, reduce physical water losses.

The practice that gives the best results among these methods is pressure management [3,6]. To effectively regulate the water pressure in the networks, district metered areas (DMA) must have been previously established [7]. In addition to reducing leaks, pressure management has other benefits, such as reducing overpressure, reducing the number of pipe bursts, and reducing operating costs [8]. On the other hand, implementing pressure management in a real network involves significant labor, equipment, and installation costs [8]. For these reasons, before implementing pressure management in the field, a cost-benefit analysis is needed for the relevant administrations to decide whether or not to implement pressure management [9].

Adedeji et al. compared pressure management, pipe rehabilitation, active leakage control, and fault management practices among physical water loss reduction methods. They stated that pressure management is the best method in terms of cost-benefit analysis since it minimizes leakage in the long term [6].

Moslehi et al. evaluated the use of pressure-regulating valves (PRV) in terms of cost-benefit. They compared leakage by replacing a fixed outlet DMA with a timed, flow-regulated method. It reduced the average zone pressure (AZP) by 3.9 m with the timed method and 5.4 m with the flow-regulated method compared to the fixed outlet method. Leakage was reduced by 120 m³ per day with the timed method and 172 m³ per day with the flow-adjusted method. The results show that the benefit from leakage reduction is the most significant contribution to the total benefit, and the flow-regulated method is the most beneficial in the analyzed network [10].

Özdemir et al. analyzed the effect of system operating pressure on water losses and minimum night flow rate (MNF) according to field data and the FAVAD equation. Firstly, faults were eliminated by acoustic listening in the isolated zone, and the MNF rate was reduced from 12.5 l/s to 6.95 l/s, saving 441 m³ of water per day in the inlet volume. In the second stage, the pressure was reduced from 9.1 bar to 3.1 bar, and the MNF rate from 6.95 l/s to 3.29 l/s with pressure management and a daily water saving of 78.44 m³ was calculated in the inlet volume. As a result, the studies showed a difference of 1.70 l/s between the values obtained from the field and those calculated according to the FAVAD equation [11].

Akdemir and Yılmaz compared the theoretical results obtained by using the Fixed and Variable Area Discharges (FAVAD) equation, which provides a link between network pressure and leakage in the DMA where pressure management is applied, with field practices data. They stated that different

pressure regulation methods could not be predicted with the FAVAD equation and proposed a new method to calculate the final leakage in the network. The proposed method reduced the net benefit difference to 1.81% in the region with a net benefit difference of 58.06% in theory and practice. They found a result closer to the practice field [5].

Koşucu and Demirel aimed to compare four different pressure control methods in terms of cost-benefit by creating hydraulic models for networks with other characteristics. The study's results state that the most applicable pressure regulation method differs according to the unit water cost; in cases where the unit water cost is high, the closed circuit pressure control method will be the most appropriate choice, and as the unit water cost decreases, flow-regulated or time-regulated methods will be the most appropriate choice [12].

This study analyzes the benefits of pressure management and the potential costs of implementing this method. Unlike the literature, the study analyzed different types of pressure relief valves separately. Thus, water utilities will be able to make a more reliable cost-benefit analysis for pressure management, which is the most commonly used method of water loss management. The reliability of the algorithm is also tested by comparing the results obtained from the analysis with real data.

2. Materials and Methods

Cracks and fractures occur in the pipes that provide water transmission to the subscribers due to the decrease in the compressive strength of the pipe due to pressure fluctuation and pipe aging. No matter how well the drinking water distribution networks are designed, it is inevitable that water losses due to leakage will occur in the existing networks [1,6]. Depending on the location of the fault and the way it occurs, different levels of leakage occur in the distribution system and are divided into three groups [13].

Background leaks occur on the pipe's bottom surface and have a low leakage flow rate. Since the leakage flow rate is minimal, the faults do not rise to the surface, and the lost water directly enters the soil. Due to the small leakage flow rate, it is difficult to detect with acoustic listeners and system monitoring [14]. Unreported leaks occur at the pipe's bottom surface, producing a moderate loss with a leak flow rate greater than undetected leaks [5,14]. Reported leaks are the leaks that occur on the upper surface of the pipe, where the leaks come to the surface under the effect of pressure. The amount of leakage is higher than uncertain and unreported leaks, but the detection and repair times are shorter since they come to the surface [13,14].

May propose a relationship between pressure and seepage based on field measurements using the Fixed and Variable Area Discharge (FAVAD) equation (Equation 1.), which is based on pressure variations, flow rate variations, and pipe material coefficient [15].

$$(L1/L0) = (P1/P0)^{N1} \quad \text{Eq.1}$$

In the equation, L1 (l/s) is the leakage flow rate after pressure regulation, L0 (l/s) is the initial leakage flow rate, P1 (m) is the regulated average pressure value, P0 (m) is the initial pressure value, N1 is the pipe material coefficient.

The installation of pressure-regulating valves (PRV) at the inlet of networks operating at high operating pressure has proven to be an effective way to control leakage [16]. Four basic pressure control methods are defined according to the condition of pressure-regulating valves at the critical point [17]. These are conventional fixed outlet pressure control, time-modulated pressure control, and flow-modulated pressure control (Figure 1) [18].

Fixed outlet pressure control involves using a device, normally a pressure-reducing valve (PRV), to control the maximum pressure entering a zone (Figure 1). It is the simplest form of pressure management because it involves using a PRV without extra electronic equipment [18].

Time-modulated pressure management is a method that works in conjunction with an additional device that can further reduce pressure during off-peak periods of water use (Figure 1). The main disadvantage of time-modulated control is that it does not respond to water demand and can be problematic for firefighting [18].

Flow-modulating pressure control provides more control and flexibility than the time-modulating option (Figure 1). It offers more savings than other methods but is more expensive due to the use of extra electronics. An important advantage of the flow-modulated option is that it will not interfere with the water supply in case of fire [18].

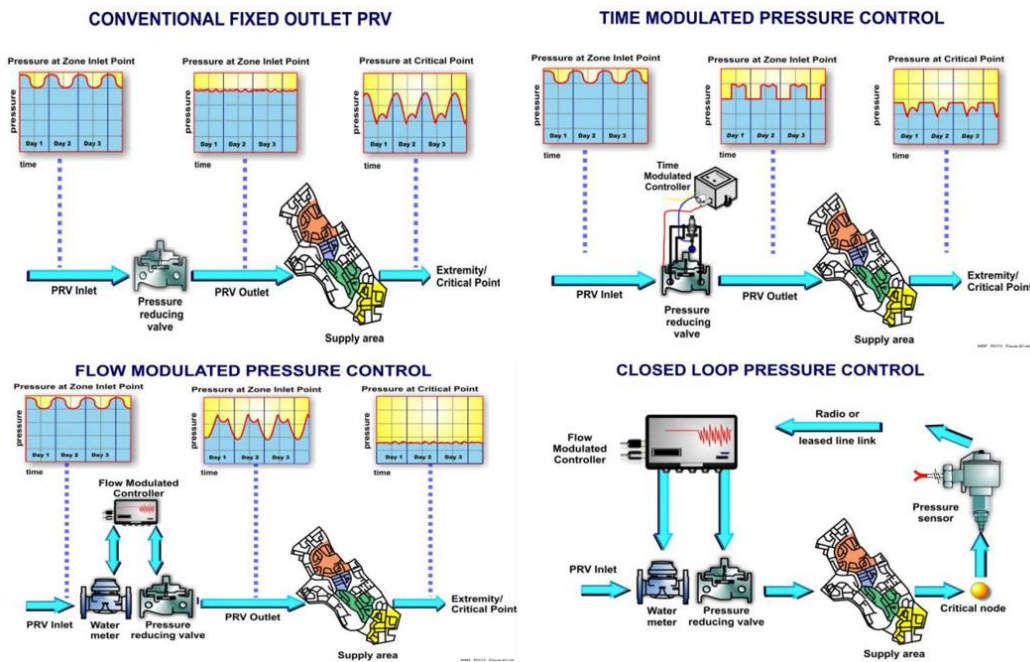


Figure 1. Pressure control methods [18]

Lambert and Thornton proposed an equation based on the FAVAD equation and dependent on the N2 coefficient to establish a relationship between pressure and number of failures [19].

$$(B1/B0) = (P1/P0)^{N2} \tag{Eq.2}$$

In the equation, B1 is the failure after pressure regulation, B0 is the failure before pressure regulation, P1 (m) is the regulated average pressure value, P0 (m) is the initial pressure value, and N2 is the failure frequency.

The FAVAD equation can calculate pressure management in drinking water distribution networks. This equation covers a single operating pressure value and gives results close to the practice area only for the constant output pressure control technique. It is inadequate for timed and flow-regulated methods operating at multiple operating pressures [3,5].

Considering the studies carried out to reduce water losses, it is clear that there is a need for a new method to calculate the economic benefits to provide a realistic result of the benefit and cost analysis

for all pressure control methods in a way close to the practices area. In this study, a new algorithm has been created for this need.

In order to test the models to be established within the scope of the study, 3 DMAs in Kayseri province were examined. In this context, basic data such as network length, number of subscriber connections, network pipe type, number of faults of the relevant DMAs were obtained. In addition, pressure management was applied with different methods in these DMAs and the decreases in night flow and number of failures were monitored.

3. Practices Area

The water distribution system of Kayseri province has been selected as the study area for the creation of the algorithm that calculates how much water loss will be prevented if pressure management is applied in the real water distribution network and performs cost-benefit analysis based on the calculated result [5].

Kayseri province is located in the Central Kızılırmak Region of the Central Anatolia Region of Turkey. Kayseri Water and Canal Administration (KASKİ), which has a total water network length of 309 km, has 670000 subscribers and provides an average of 370000 m³ of water supply service per day to a population. In the study area, distribution networks can be monitored remotely with the SCADA system and a new GIS programme with SCADA-CBS integration with 95% reliability was switched to in 2020 [3,20].

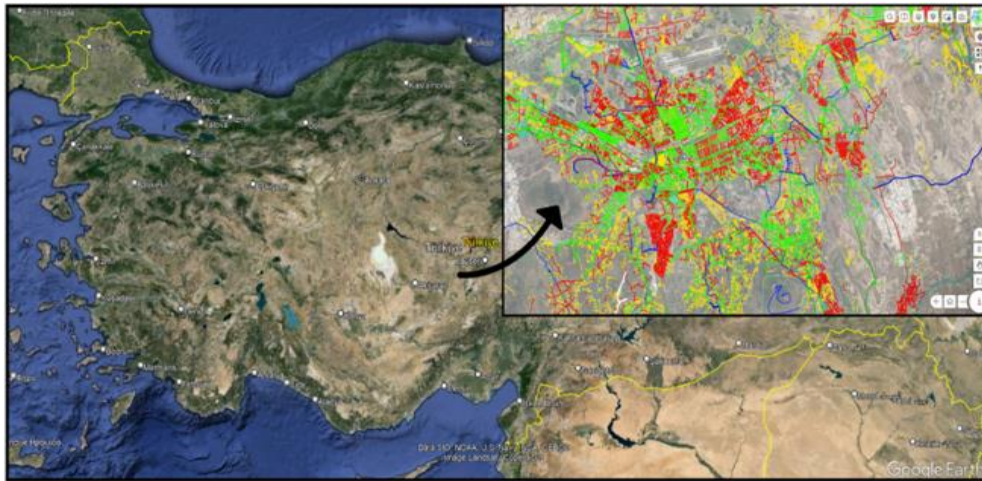


Figure 2. Practices area [3,20]



Figure 3. DMA areas [3,20]

Within the study's scope, data were taken according to measurements obtained from real isolated subregions, and the data obtained were compared with the theoretically calculated results. For this purpose, isolated subareas with different characteristics and pressures regulated by different methods were selected (Figure 2-3) [3].

4. Analyses and Assessments

Yıldırım Beyazıt 4-5 DMA operated by KASKİ was selected for the algorithm to calculate the final leakage in the fixed outlet pressure control practices. The results of the field practices and the algorithm are compared.




Figure 4. Yıldırım Beyazıt 4-5 DMA flow-pressure graph [3]

Before the pressure management practices in the DMA, the average inlet flow rate was 45.64 m³/h, and the average system pressure was 5.71 bar. After the pressure management practices in the

lower zone, the average outlet flow rate was 36.76 m³/h, and the average system pressure was 4.67 bar (Figure 4) [3].

```

%YILDIRIM BEYAZIT 4-5 DMA ANALYSES
%Calculation of the theoretical final flow rate
%unit m3/h
L0=45.64;
%unit bar
P0=5.71;
P1=4.67;
%unitless
N1=1.1;
%unit m3/h
L1=L0/(P0/P1)^N1;
%unit %
percentage_benefit=((L0-L1)*100/L0;
%unit m3/h
total_benefit=L0-L1;
%field application
%unit m3/h
application_L1=36.76;
application_total_benefit=8.88;
%comparison of theory and application
%unit m3/h
total_benefit_dif=total_benefit-application_total_benefit;
%unit %
benefit_dif=((total_benefit-application_total_benefit)*100/total_benefit;

```

Figure 5. Comparison of theory and practices, Yıldırım Beyazıt 4-5 DMA

Theoretically calculated results with actual field data result in comparison: The goal was to keep the difference below 5%. According to the results, the difference was 1.94%, which shows that the algorithm was successful (Figure 5).

Before the implementation of pressure management in the isolated sub-region, 46 failures occurred in 2020, and 48 failures occurred in 2021. Considering the average number of the last 2 years in the analyses, it is assumed that 47 failures occur annually in the network. In the isolated sub-region where pressure management with constant output was applied, 27 failures occurred after the pressure management practices (Figure 6) [3,20].




Figure 6. Yıldırım Beyazıt 4-5 DMA failure change graph [3]

In the theoretical calculation of the benefit obtained from the failure, the number of last failures in the network was calculated theoretically by considering the network's length and the annual number of first failures in the field practices (Figure 7).

<pre> %unit km pipe_length=31.64; %unit quantity B0=47; ref=(pipe_length*13)/100; s=((1-(ref/B0))*(1-(P1/P0)^3/(1-P1/P0))); %unit % percentage_s=(s*(1-P1/P0))*100; %unit quantity B1=round(B0-(B0*percentage_s/100)); %comparison of theory and application %birim quantity application_B1=27; total_failure_dif=B1-application_B1; %birim % failure_dif=((B1-application_B1)*100)/B1; </pre>	<pre> %benefit analysis/flow %unit TL/m3 unit_water_cost=9; %unit TL/year flow_benefit=L1*24*30*12*unit_water_cost; %benefit analysis/failure %unit quantity/year descending_failure=B1-B0; %unit TL/quantity repair_cost=39600; %unit TL/year repair_benefit=descending_failure*repair_cost; benefit_total=flow_benefit+repair_benefit; </pre>
<pre> %cost analysis %unit TL/quantity flow_meter_room=145000; dirt_trap=12000; border_valve=8500; zero_pressure_test=2000; monitoring_and_operation=52000; prv=49500; %unit TL total_cost=flow_meter_room+dirt_trap+(border_valve*4)+(zero_pressure_test* 2)+monitoring_and_operation+prv; </pre>	<pre> %cost benefit analysis if total_cost>benefit_total fprintf ('pressure management should be applied') else fprintf ('pressure management should not be applied') end %unit month recovery_period_of_investment=total_cost/benefit_cost; %unit day recovery_period_of_investment2=recovery_period_of_investment*30; </pre>

Figure 7. Comparison of theory and practices, Yıldırım Beyazıt 4-5 DMA

The actual field data results were compared with the theoretically calculated results, and the difference was 3.57%, thus achieving the set target. The cost and benefit analysis for the fixed outlet PRV determined that implementing pressure management in the drinking water distribution network was the right decision, and the return on investment was calculated as 2.44 months = 73 days (Figure 7).




Figure 8. Keykubat 1 DMA flow-pressure graph [3]

Keykubat 1 DMA operated by KASKİ was selected for the algorithm to calculate the final leakage in the timed pressure control practices. The results of the field practices and the algorithm are compared (Figure 8).


```

%KEYKUBAT 1 DMA ANALYSES
%calculation of the theoretical final flow rate
%unit m3/h
L0=61.05;
%unit bar
P0=8.13;
P1=4.03;
%unitless
N1=1.1;
%unit m3/h
L1=L0/(P0/P1)^N1;
%unit %
percentage_benefit=((L0-L1)*100/L0);
%unit m3/h
total_benefit=L0-L1;
%field application
%unit m3/h
application_L1=36.76;
application_total_benefit=8.88;
%comparison of theory and application
%unit m3/h
total_benefit_dif=total_benefit-application_total_benefit;
%unit %
benefit_dif=((total_benefit-application_total_benefit)*100/total_benefit);

```

Figure 9. Comparison of theory and practices, Keykubat 1 DMA

Before the pressure management practices in the DMA, the average inlet flow rate was 61.05 m³/h, and the average system pressure was 8.13 bar. After the pressure management practices in the lower zone, the average outlet flow rate was 39.25 m³/h, and the average system pressure was 4.03 bar (Figure 8) [3].

Theoretically calculated results with actual field data results comparison: The goal was to keep the difference below 5%. According to the results, the difference was 2.37%, which shows that the algorithm was successful (Figure 9).




Figure 10. Keykubat 1 DMA failure change graph [3]

In the DMA, 83 faults occurred before pressure management was implemented (Figure 10). Pressure management in the DMA it is seen that 25 failures occurred after the practices. These failures are self-induced malfunctions [3].

<pre> %benefit analysis/flow %unit TL/m3 unit_water_cost=9; %unit TL/year flow_benefit=L1*24*30*12*unit_water_cost; %benefit analysis/failure %unit quantity/year descending_failure=B1-B0; %unit TL/quantity repair_cost=39600; %unit TL/year repair_benefit=descending_failure*repair_cost; benefit_total=flow_benefit+repair_benefit; </pre>	<pre> %unit km pipe_length=12.81; %unit quantity B0=83; ref=(pipe_length*13)/100; s=((1-(ref/B0))*(1-(P1/P0)^3/(1-P1/P0))); %unit % percentage_s=(s*(1-P1/P0))*100; %unit quantity B1=round(B0-(B0*percentage_s/100)); %comparison of theory and application %birim quantity application_B1=25; total_failure_dif=B1-application_B1; %birim % failure_dif=((B1-application_B1)*100)/B1; </pre>
<pre> %cost analysis %unit TL/quantity flow_meter_room=145000; dirt_trap=12000; border_valve=8500; zero_pressure_test=2000; monitoring_and_operation=52000; prv=150000; %unit TL total_cost=flow_meter_room+dirt_trap+(border_valve*4)+(zero_pressure_test*2)+monitoring_and_operation+prv; </pre>	<pre> %cost benefit analysis if total_cost>benefit_total fprintf('pressure management should be applied') else fprintf('pressure management should not be applied') end %unit month recovery_period_of_investment=total_cost/benefit_cost; %unit day recovery_period_of_investment2=recovery_period_of_investment*30; </pre>

Figure 11. Comparison of theory and practices, Keykubat 1 DMA

The results of the real field data were compared with the theoretically calculated result, and no difference was observed. The algorithm and practice results overlapped, and the set target was achieved. As a result of the cost and benefit analysis for the timed PRV determined that implementing pressure management in the drinking water distribution network was the right decision, and the return on investment was calculated as 1.18 months = 36 days (Figure 11).




Figure 12. Yavuzlar 1 DMA flow-pressure graph [3]

Yavuzlar 1 DMA operated by KASKİ was selected for the algorithm to calculate the final leakage in the flow-sensitive pressure control practices (Figure 12). The results of the field practices and the algorithm are compared. The drinking water network was modelled in the isolated region's theoretical calculations. Graphical modeling of the network and calculations were performed with MATLAB (Figure 13).




Figure 13. Modeling of the before-after pressure management for Yavuzlar 1 DMA

Based on the graphs drawn and the equations obtained, the flow rate reaching the subscribers from the distribution network before and after pressure management was calculated. The calculation considered the water supplied to the subscribers in 1 day. By taking the integral of the equation, the condition of the network before pressure management was analyzed with the definite integral.

The calculation resulted in a 1584.61 l/s flow rate passing through the network before pressure management and a 1359.86 l/s flow rate passing through the network after pressure management.

Theoretically calculated results with actual field data results comparison, it was aimed to keep the difference below 5%. According to the results, the difference was 3.25%, which shows that the algorithm was successful. In the theoretical calculation of the benefit obtained from the failure, different operating conditions of the system pressure values and the number of failures occurring in the network were taken into consideration, and the theoretical final number of failures was calculated in Figure 14.

```
%unit km
pipe_length=44.81;
%unit quantity
B0=92;
ref=(pipe_length*13)/100;
s=((1-(ref/B0))*(1-(P1/P0)^3/(1-P1/P0)));
%unit %
percentage_s=(s*(1-P1/P0)*100);
%unit quantity
B1=round(B0-(B0*percentage_s/100));
%comparison of theory and application
%birim quantity
application_B1=24;
total_failure_dif=B1-application_B1;
%birim %
failure_dif=((B1-application_B1)*100)/B1;
```

Figure 14. Comparison of theory and practices, Yavuzlar 1 DMA

Failure results in real field data were compared with the theoretically calculated failure results, and the aim was to keep the difference below 5%. According to the results, the difference between the actual and theoretical results was 4.34%, and the set target was achieved. The costs of the flow-regulated pressure control method were determined as 447000 TL per year, and the benefits were determined as 455000 TL per month. As a result of the cost and benefit analysis for the flow-regulated PRV determined that implementing pressure management in the drinking water distribution network was the right decision, and the return on investment was calculated as 0.98 months = 29 days (Figure 14).

5. Results and Discussion

In the DMA where fixed outlet pressure management was applied, according to actual field data, the flow rate before pressure management was 45.64 m³/h and the pressure was 5.71 bar; after pressure management, the flow rate was 36.76 m³/h, and the pressure was 4.67 bar. Theoretically, the flow rate was calculated as 36.58 m³/h when pressure management was applied with the constant outlet method. Theoretically, the net benefit from the flow rate was 8.88 m³/h in field practices and 9.06 m³/h. When the actual and theoretical results are compared, a difference of 0.18 m³/h in the net benefit is obtained from the flow rate, which is 1.94% in percentage terms. The result is within the limits of $\pm 5\%$, sufficient for the algorithm to be successful (Table 1).

Pressure management has the additional benefit of reducing the number of faults in the network. When the benefits are analyzed, according to the actual field data, 47 faults occurred in the region according to the average of the last 2 years' data without pressure management practices in the network, and the number of faults decreased to 27 after pressure management was applied in the region. Theoretically, the number of failures in the region after pressure management is calculated as 28. When the actual field data results are compared with the theoretical results, the difference in the benefit obtained from the failure was 3.57%, and this value was within the desired $\pm 5\%$ limits. The first flow rate and the first number of failures were taken in the theoretical analyses according to the field practice results. Benefit and cost analyses were made according to the theoretically calculated flow rate and number of failures. As a result of the calculations, it was found that the practices of pressure management in the relevant distribution network have a monthly benefit of 121385 TL, and the cost of pressure management amortized in 2.44 months \sim 73 days.

According to the actual field data in the DMA where timed pressure management was applied, the flow rate before pressure management was 61.05 m³/h, and the pressure was 8.13 bar; after pressure management, the flow rate was 39.25 m³/h, and the pressure was 4.03 bar. Theoretically, the flow rate was calculated as 38.72 m³/h when pressure management was applied with the timed method. Theoretically, the net benefit from the flow rate was 21.8 m³/h in field practices and 22.33 m³/h. When the actual and theoretical results are compared, a difference of 0.53 m³/h in the net benefit is obtained from the flow rate of 2.37% in percentage terms. The result is within $\pm 5\%$, sufficient for the algorithm to be successful (Table 1).

When the benefits arising from the additional benefit of pressure management, which is the reduction of the number of faults in the network, are examined, according to the actual field data, 83 faults occurred in the region before pressure management was applied. The number of faults decreased to 25 after pressure management was applied in the region. Theoretically, the number of faults in the region after pressure management is calculated as 25. When the actual field data results are compared with the theoretical results, there is no difference in the benefit obtained from the failure. This result is within the desired $\pm 5\%$ limits.

The first flow rate and the first number of failures were taken in the theoretical analyses according to the field practice results. Benefit and cost analyses were made according to the theoretically calculated flow rate and number of faults. As a result of the calculations, it was found that pressure management practices in the relevant distribution network have a monthly benefit of 336095 TL, and the cost of pressure management is amortized in 1.18 months \sim 36 days.

According to the actual field data in the DMA where flow-adjusted pressure management was applied, the flow rate before pressure management was 163.44 m³/h, and the pressure was 7.0 bar; after pressure management, the flow rate was 127.08 m³/h, and the pressure was 4.1 bar. When pressure management was applied with the flow-regulated method, 36.36 m³/h net benefits were gained from the flow rate in field practices and 35.17 m³/h theoretically. When the actual and theoretical results are compared, a difference of 1.19 m³/h in the net benefit is obtained from the flow rate of 3.26% in percentage terms. The result is within the limits of $\pm 5\%$, sufficient for the algorithm to be successful.

According to the field practice results, the theoretical analysis takes the first flow rate and fault numbers (Table 1).

When the additional benefit of pressure management, which is due to the reduction in the number of faults in the network, is examined, according to the actual field data, 92 faults occurred in the region before the pressure management was applied. The number of faults decreased to 24 after pressure management was applied in the region. Theoretically, the number of faults in the region after pressure management is calculated as 23. When the actual field data results are compared with the theoretical results, the difference in the benefit obtained from the failure was -4.37% and remained within the desired $\pm 5\%$ limits.

Benefit and cost analyses were performed according to the theoretically calculated flow rate and number of faults. The calculations found that the monthly benefit of the pressure management practices in the relevant distribution network was 455635 TL, and the cost of the pressure management practices was amortized in 0.98 months ~ 29 days.

When the analysis results are analyzed,

- It is seen that the most costly method is the flow-regulated method, followed by time-regulated and fixed output methods.

- In addition to being the most costly method, it has been tested by analyses that the flow-adjusted method is the method that provides the most benefit. After the flow-adjusted method, the method that provides the highest financial benefit is the time-adjusted and constant output method, respectively.

The recommendations within the scope of this study are as follows:

- To decrease water resources, subscribers should take water-saving measures individually.
- The amount of water used in agriculture exceeds drinking and utility water. For this reason, conscious irrigation should be done in agriculture.
- Water channel administrations should prevent the losses that occur in the provision of water transmission from the source to the end user. The works out here prevent more water loss than the measures taken individually.
- Sustainability of the studies within the scope of water loss management should be ensured.
- Pressure management and the joint work of academic studies and water administration practices should be expanded.

Table 1. Field practices and theoretical calculation results of different pressure control practices

	Field Practices (YB-4/5)	Theoretical Calculation (YB-4/5)	Field Practices (K-1)	Theoretical Calculation (K-1)	Field Practices (Y-1)	Theoretical Calculation (Y-1)
Flow (L0)	45.64 m ³ /h	45.64 m ³ /h	61.05 m ³ /h	61.05 m ³ /h	163.44 m ³ /h	163.44 m ³ /h
Flow (L1)	36.76 m ³ /h	36.58 m ³ /h	39.25 m ³ /h	38.72 m ³ /h	127.08 m ³ /h	128.27 m ³ /h
Failure (B0)	47	47	83	83	92	92
Failure (B0)	27	28	25	25	24	23

Acknowledgment

This study is based on the master's thesis written by Merve AKDEMİR. We would like to thank KASKİ for their support in providing the data required for the analyses in this study.

Declaration of Ethical Standards

This article's author(s) declares that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

References

- [1] Mian HR, Hu G, Hewage K, Rodriguez MJ, Sadiq R. Drinking water management strategies for distribution networks: An integrated performance assessment framework. *J Environ Manage* 2023; 1-12.
- [2] Kyaw T. Adsorption desalination: theory & experiments. Ph.D. thesis. National University of Singapore; 2010.
- [3] Akdemir M. İçme suyu sistemlerinde farklı basınç düzenleyici vanaların fayda maliyet analizi. Master's thesis. Çankırı Karatekin Üniversitesi; 2024.
- [4] Brennan M, Rondón-Sulbarán J, Sabogal-Paz LP, Fernandez-Ibañez P, Galdos-Balzategui A. Conceptualising global water challenges: A transdisciplinary approach for understanding different discourses in sustainable development. *J Environ Manage* 2021; 298: 1–10.
- [5] Akdemir M, Yılmaz S, İçme suyu sistemlerinde sızıntıların uygulamalı ve teorik olarak karşılaştırılması. *İleri Teknolojilerde Çalışmalar Dergisi* 2023; 55-66.
- [6] Adedeji KB, Hamam Y, Abe BT, Abu-Mahfouz AM. pressure management strategies for water loss reduction in large-scale water piping networks: a review. 1st ed. *Advances in Hydroinformatics*: Springer Water; 2018.
- [7] Zhang T, Yao H, Chu S, Yu T, Shao Y. Optimized dma partition to reduce background leakage rate in water distribution networks. *J Water Resour Plan Management* 2021; 147: 1-14.
- [8] Darvini G, Soldini L. Pressure control for WDS management: a case study. *Procedia Eng.* 2015; 119: 984–993.
- [9] AL-Washali T, Sharma S, Kennedy M. methods of assessment of water losses in water supply systems: a review. *Water Resources Management* 2016; 14: 4985–5001.
- [10] Moslehi I, Jalili Ghazizadeh M, Yousefi-Khoshqalb E. An economic valuation model for alternative pressure management schemes in water distribution networks. *Util Policy* 2020; 67: 101–29.
- [11] Özdemir Ö, Fırat M, Yılmaz S, Usluer M. Analysis of the effect of pressure control on leakages in distribution systems by FAVAD equation and field applications. *Water Pract Technol.* 2021; 16(2): 320–332.
- [12] Koşucu MM, Demirel MC. Cost efficiency assessment of four pressure management methods in water distribution systems." *Journal of Water Resources Planning and Management* 2024;150(3): 1-16.
- [13] Thornton J, Sturm R, P.E. GK. *Water loss control*. 2nd ed. New York: The McGraw-Hill Companies; 2008.
- [14] Farley M, Trow S. *Losses in water distribution networks: a practitioners. Guide to Assessment, Monitoring and Control*: IWA Publishing; 2015.
- [15] John Henry M. *Pressure dependent leakage*. World Water and Environmental Engineering; 1994.
- [16] Burn LS, De Silva D, Shipton RJ. Effect of demand management and system operation on potable water infrastructure costs. *Urban Water* 2002; 4(3): 229–36.
- [17] Creaco E, Walski T. Economic analysis of pressure control for leakage and pipe burst reduction. *J Water Resour Plan Management* 2017;143(12): 1-18.
- [18] Mckenzie RS, Wegelin W. *Implementation of pressure management in municipal water supply systems*: IWA Publishing; 2009.
- [19] Lambert A, Thornton J. Pressure bursts relationships influence of pipe materials, validation of scheme results and implications of extended asset life. *Water Loss* 2012; 2(11):1-20.
- [20] Kayseri Su ve Kanal İdaresi Performans Raporu; 2024.

DERİN ÖĞRENME İLE ÇEVRESEL ATIKLARIN SINIFLANDIRILMASINA DAYALI AKILLI ÇÖP KONTEYNERİ TASARIMI VE PROTOTİPİNİN GELİŞTİRİLMESİ

Mehmet Umut SALUR^{1*}, Nermin ELMAS², Aybuke Nur KOÇAK³, Melike KAYMAZ⁴

^{1,2,3,4} Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, Gaziantep, 27470, Türkiye

Geliş Tarihi/Received Date: 28.09.2024 Kabul Tarihi/Accepted Date: 22.12.2024 DOI:10.54365/adyumbd.1557588

ÖZET

Günümüzde dünya nüfusunun artışıyla birlikte kentlerde ve sanayide yüksek oranda doğal kaynak kullanılmaktadır. Bu kaynak kullanımı, beraberinde tonlarca çevresel atığın oluşmasına neden olmaktadır. Bu kirlilik, gelecek nesiller için sürdürülebilir dünyanın varlığı konusunda ciddi tehdit oluşturmaktadır. Günümüz teknolojisiyle çevresel atıkların yönetimi için derin öğrenme ve görüntü işleme tabanlı çözümleri geliştirmek mümkündür. Bu çalışmada çevresel atıklardan geri dönüşümü mümkün olanların (kağıt, plastik, metal ve cam) yerinde ve otomatik bir şekilde sınıflandırılması ve ayrıştırılması için görüntü işleme ve Raspberry Pi tabanlı akıllı çöp konteyneri prototipi gerçekleştirilmiştir. Akıllı çöp konteynerine bırakılan bir atık; i- hareket algılama sensörüyle fark edilmekte, ii- atığın fotoğrafı çekilmekte, iii- çekilen fotoğraf derin öğrenmeyle sınıflandırılmakta, iv- atığın sınıfı belirlendikten sonra adım motoru yardımıyla çöp konteynerin içindeki ilgili bölüme taşımaktadır. Bu yönüyle insan müdahalesi olamadan dönüştürülebilen çevresel atıklar yerinde ve otomatik bir şekilde ayrıştırılmaktadır. Akıllı çöp konteyneri, çevresel atıkların geri dönüşüme kazandırılması ve yönetilmesi sürecini hem maliyet hem de insan iş gücü açısından iyileştirme potansiyeline sahiptir.

Anahtar Kelimeler: Çevresel Atıkların Sınıflandırılması, Derin Öğrenme, Raspberry Pi, Görüntü İşleme

DESIGN AND PROTOTYPE DEVELOPMENT OF A SMART GARBAGE CONTAINER BASED ON ENVIRONMENTAL WASTE CLASSIFICATION USING DEEP LEARNING

ABSTRACT

Today, with the population increase in the world, natural resources are used at a high rate in cities and industry. This resource use causes the formation of tonnes of environmental waste. This pollution poses a serious threat to the existence of a sustainable world for future generations. Today, it is possible to develop deep learning and image processing based solutions for environmental waste management. In this study, an image processing and Raspberry Pi based smart garbage container prototype has been realised for on-site and automatic classification and sorting of recyclable environmental wastes (paper, plastic, metal and glass). A waste left in the smart waste container is i- motion detected by a motion detection sensor, ii- image of the waste is taken, iii- image is classified by deep learning, iv- after the class of the waste is determined, it is moved to the relevant section in the waste container with the help of a stepper motor. This approach ensures that recyclable environmental waste is separated automatically without human intervention. The smart waste container has the potential to improve the recycling and management of environmental waste, offering benefits in terms of cost-efficiency and reduced human labor requirements.

Keywords: Classification of Environmental Waste, Deep Learning, Raspberry Pi, Image Processing

* e-posta¹: mehmetumut.salur@gibtu.edu.tr ORCID ID: <https://orcid.org/0000-0003-0296-6266> (Sorumlu Yazar)
e-posta²: nerminelmas02@gmail.com ORCID ID: <https://orcid.org/0009-0004-5617-6344>
e-posta³: aybukekck001@gmail.com ORCID ID: <https://orcid.org/0009-0005-2467-4477>
e-posta⁴: melikekaymaz0@gmail.com ORCID ID: <https://orcid.org/0009-0007-6142-2978>

1. Giriş

Her yıl milyarlarca tona ulaşan çevresel atıklar geri dönüştürülemeden doğada tehdit unsuru olarak dünya iklimi ve yaşam alanlarını olumsuz etkilemektedir. Sürdürülebilir bir yaşam ve çevre için öncelikli hedef, çevresel atık oluşumunu en aza indirmektir. İkinci bir çözüm ise, oluşan atıkların geri dönüşüm yoluyla doğadan temizlenmesi ve yeniden kullanıma kazandırılmasıdır. Bu kapsamda, çevresel atıkların geri dönüştürülmesi ülkemizde ve dünyada yeni politikalara ve teknolojilere açık bir araştırma alanıdır. Dünya nüfusunun her geçen yıl büyümesi bu alandaki araştırmalara olan ilgiyi de beraberinde getirmektedir. Gelecek kuşaklara daha sürdürülebilir bir dünya mirası bırakmak için çevresel atıkların geri dönüştürülmesi büyük önem taşımaktadır [1]. Çevresel atıkların sınıflandırılması ve geri dönüştürülebilir atıkların daha hızlı bir şekilde doğaya kazandırılması, sürdürülebilir bir gelecek için temel oluşturmaktadır. Ayrıca, ham madde üretiminin düşmesi enerji tasarrufu sağlamak ve doğal kaynakların korunmasına yardımcı olmaktadır. Geleneksel yöntemlerle çevresel atıkların toplanması ve ayrıştırılması süreci, manuel işlemlerle zaman alıcı bir süreçtir [2]. Ancak, günümüzde gelişen teknolojiyle Raspberry Pi gibi mikrobilgisayarlar ve derin öğrenme algoritmaları bu süreci hızlandırmak ve optimize etmek için önemli bir potansiyel sunmaktadır.

Günümüzde çevresel atıklar günlük periyotlarla çöp araçları tarafından toplanmakta ve çöp ayrıştırma merkezlerinde manuel yöntemlerle ayrıştırıldıktan sonra bir kısmı geri dönüşüme tabi tutulmaktadır. Ancak bu yöntem maliyet, zaman, süreç ve insan gücü açısından yüksek maliyetler gerektirmektedir. Bu çalışmada çevresel atıkların çöp toplama merkezlerine taşınmadan yerinde ayrıştırılması problemi için derin öğrenme ve Raspberry Pi tabanlı akıllı çöp konteyneri tasarımının gerçekleştirilmesi ele alınmıştır. Sistem prototipinin geliştirilmesiyle çevresel atıkların yönetimi hem maliyet hem de insan gücü açısından iyileştirilmiştir. Akıllı çöp konteyneri tasarımıyla çevresel atıklar çöp konteynerine bırakıldıktan sonra otomatik bir şekilde sınıflandırılmakta ve ilgili kategorileri (kağıt, metal, plastik vb.) temsil eden bölümlerde biriktirmektedir. Bunun sonucunda çöplerin toplanmasından sonra her kategori doğrudan çevresel atık geri dönüşüm merkezlerinde yeniden dönüştürülebilecektir. Bu şekilde çevresel atıkların yönetimi ve işletilmesi süreci iyileştirilmiş ve geliştirilmiştir. Bu da sürdürülebilir bir dünya ve dünyada yaşam çeşitliliği açısından önem arz etmektedir. Çevresel atıkların görüntü işleme yöntemleriyle sınıflandırılması son yıllarda önemli araştırma alanlarından biri olmuştur [1-3]. Görüntü işleme tabanlı ve entegre sistem olarak geri dönüştürülebilir nesnelere sınıflandıran ve nesneye göre kullanıcı bakiyesini arttıran sistem gerçekleştirilmiştir [4].

Bu çalışmada derin öğrenme ve Raspberry Pi tabanlı sistem bileşenlerinden oluşan akıllı çöp konteyneri tasarımı ve gerçekleştirilmesi yapılmıştır. Akıllı çöp konteyneri tasarımında çöpler tek bir noktadan konteynerin içine bırakılıp sistem tarafından otomatik bir şekilde sınıflandırıldıktan sonra ilgili kategoriye ait bölüme taşınmaktadır. Akıllı konteyner tasarımı bu yönüyle mevcut çözümlerden ayrılmaktadır. Akıllı konteyneri sistemi tasarımı görüntü işleme, derin öğrenme ve nesnelere interneti konseptinde otomatik bir şekilde çöpleri ayrıştırmaktadır. Derin öğrenme ve Raspberry Pi'nin birleşimi, daha hızlı, doğru ve ekonomik bir atık sınıflandırma sistemi sunmaktadır. Sürdürülebilir bir gelecek için çevresel atıkların geri dönüştürülmesinde önemli bir adım olarak değerlendirilebilir. Çalışmanın katkıları aşağıda sunulmuştur:

- Çevresel atıkların sınıflandırılmasında ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 modelleri üzerinde ince-ayar (fine-tuning) yapılmış ve bu yöntemle literatürdeki çalışmalara kıyasla daha yüksek başarı oranları elde edilmiştir.
- Çevresel atıkların yerinde ayrıştırılması için yeni bir akıllı çöp konteyneri tasarımı gerçekleştirilmiştir.
- Raspberry Pi kullanılarak çevresel atıkların görüntülerinin alınması, sınıflandırılması ve ayrıştırılmasını sağlayan sistem geliştirilmiştir.

Çalışmanın ikinci bölümünde ilgili çalışmalar, üçüncü bölümünde materyal ve metot, dördüncü bölümde deneysel sonuçlar ve tartışma ve son bölümde ise çalışmanın sonucu sunulmuştur.

2. İlgili Çalışmalar

Son yıllarda derin öğrenme, görüntü işleme ve sınıflandırma alanlarında sağlık, tarım, ilaç, havacılık, güvenlik ve otonom araçlar gibi pek çok bilim dalında oldukça başarılı sonuçlar sağlamaktadır [3]. Ahmed ve ark., çevresel atıkları sınıflandırmak için CNN (Convolutional Neural Network) mimarileri olan DenseNet169, MobileNetV2 ve ResNet50V2 modellerini kullanmış; bu modellerle sırasıyla %94,40, %97,60 ve %98,95 doğruluk oranlarına ulaşmışlardır [5].

Yıldız ve ark., atıkları sınıflandırmak için CNN mimarileri olan AlexNet, GoogLeNet, ResNet50, DenseNet201, ShuffleNet ve SqueezeNet kullanmışlardır [3]. DenseNet201 mimarisi kullanılarak özellik haritaları elde edilmiştir ve bu haritalar SVM (Support Vector Machine), KNN (K-Nearest Neighbors) ve DT (Decision Trees) algoritmalarına giriş olarak verilmiştir. DenseNet201 mimarisinin SVM, DT ve KNN sınıflandırıcılar ile hibritlenmesi sonucunda sırasıyla 89.70%, 66.90% ve 83.40% doğruluk elde edildiği görülmüştür. Elde edilen özellik haritaları, SVM sınıflandırıcısında en yüksek doğruluğu elde ettiğini göstermiştir. Ayrıca modellerin başarısını yalnızca doğrulukla değerlendirmek yeterli olmadığından, önerilen yöntemin etkinliği, farklı performans metrikleri kullanılarak da belirlenmiştir. DenseNet201+SVM modelinin performansı değerlendirilmiş ve en yüksek doğruluk oranı %97.82 olarak karton sınıfında, en düşük ise %95.69 ile kâğıt sınıfında elde edilmiştir.

Tatke ve ark., derin sinir ağları ve bilgisayarlı görme gibi teknolojilerin kullanımıyla atıkların sınıflandırma sürecini daha etkili hale gelmesi adına derin öğrenme modellerini karşılaştırarak analiz etmiştir [6]. Araştırmada CNN, ResNet50, VGG16 gibi modeller test edilmiştir. Model eğitimi için güçlü TensorFlow kütüphanesinin kullanılması, modellerin sağlam ve doğru sonuçlar vermesine ve minimal hata oranına sahip olmasına ek bir avantaj sağlamıştır. Bu modellerin sonuçlarının karşılaştırmalı analizinden ResNet50'nin en iyi performansı sunduğu ve bu konuyla ilgili uygulama odaklı bir yaklaşım için kolayca uygulanabileceği sonucuna varılmıştır. Modelin yüksek doğruluk göstermesinde, ResNet50'nin öğrenilebilir parametre sayısı ve atlamalı bağlantıların, eğitim sırasında gradyanlar üzerinde daha tutarlı bir geriye yayılma sağlaması olduğu vurgulanmıştır.

Alsubaie ve ark., akıllı şehirlerin hızlı kentleşmesi, atıkların etkili geri dönüşümü için akıllı ve otomatik atık yönetim tekniklerinin tasarlanmasına dair araştırmalar yapmıştır [7]. Önerilen DLSODC-GWM tekniği, akıllı atık yönetim sistemlerini desteklemek amacıyla küçük çöp atık nesnelerinin tespiti ve sınıflandırılmasına odaklanmaktadır. Bu teknik, nesne tespiti ve sınıflandırma olmak üzere iki ana süreçten oluşmaktadır. Nesne tespiti için IRD modelinin hiperparametrelerinin AOA (Arithmetic Optimization Algorithm) ile optimal olarak seçildiği geliştirilmiş bir RefineDet (IRD) modeli uygulanmıştır. Ardından, atık nesnelerin çeşitli sınıflara ayrılması için fonksiyonel bağlantı sinir ağı (FLNN) kullanılmıştır. Atık sınıflandırması için IRD ve AOA tabanlı hiperparametre ayarının yeniliği çalışmanın özgünlüğünü vurgulamaktadır. DLSODC-GWM tekniğinin performansı, referans veri kümeleriyle doğrulanmış ve deneysel sonuçlar, mevcut yöntemlerle karşılaştırıldığında DLSODC-GWM'nin %98,61'e varan doğruluk oranıyla üstün performans sergilediğini göstermiştir.

Varol ve ark., araştırmalarında atık görüntülerini sınıflandırmak amacıyla, açık erişimli Garbage Classification veri setini çalışmaya uygun hale getirip kullanmışlardır [2]. Deneysel süreçlerde özellik çıkarımı için CNN mimarilerinden DarkNet-19 modeli tercih edilmiştir. Performans, çeşitli metriklerle ölçülmüş ve %96'lara varan doğruluk değerleri elde edilmiştir.

Kang ve ark., görüntü sınıflandırma algoritmalarının evrimini ve derin öğrenme teknolojisinin uygulanmasını ele almıştır [8]. Son teknoloji algoritmalar olan AlexNet, VGG, Inception ve ResNet üzerinde araştırmalar yapılmıştır. ResNet-34 ve ResNet-152 modelleri, doğruluk ve kayıp açısından başarılı sonuçlar vermiştir. Ancak, hesaplama hızının azalması nedeniyle temel model olarak ResNet-34 tercih edilmiştir. ResNet-34 modeli üç farklı şekilde modifiye edilmiştir: çoklu özellik füzyonu, artık

birimlerin özelliklerinin yeniden kullanımı ve aktivasyon fonksiyonunun optimizasyonu. Her bir değişiklik, çevresel atık veri seti üzerinde test edilmiş ve orijinal ResNet-34'e kıyasla daha yüksek bir doğruluk elde edilmiştir. Modifikasyonları birleştiren tüm ResNet-34 verilerinin, en yüksek doğruluğa sahip olduğu görülmüştür. Önerilen algoritma ve donanım ile otomatik bir çöp sınıflandırma sistemi entegre edilmiştir. Bu sistem %99,96 kadar bir sınıflandırma doğruluğuna ve ortalama 0,95 saniyelik bir sınıflandırma döngüsüne sahiptir. Sürücü ve ark. önceden eğitilen modeller ile atıkları otomatik olarak sınıflandırmayı amaçlamışlardır. Modeller arasında Resnet50-V2 modeli %97,07 başarıyla öne çıkmıştır [9].

Keskin ve ark., sınıflandırma problemi için CNN mimarilerini kullanarak modellerin doğruluk oranlarını karşılaştırmış ve ResNet101, ConvNeXt ve DenseNet121 ile yapılan analizlerde, ResNet101'in doğruluk açısından diğer mimarilere kıyasla daha üstün bir performans sergilediğini tespit etmişlerdir [10]. Resnet101, %97,72 doğruluk oranıyla en başarılı model olarak öne çıkmıştır. Çalışmada ResNet101'in daha derin yapısı ve sıçrama bağlantıları sayesinde diğer modellere kıyasla daha yüksek doğruluk ve verimlilik sağladığını ortaya koymuştur.

Zhou ve ark., derin öğrenme tabanlı otomatik çöp tanıma ve sınıflandırma sistemi geliştirmiştir [11]. Çalışma, ResNet50, YOLOv5 ve zayıf denetimli CNN algoritmalarını entegre ederek çevresel atık yönetimi için yüksek doğruluk ve verimlilik sağlayan bir yaklaşım önermektedir. HGI-30 ve TrashNet gibi veri setleri üzerinde yapılan deneylerde önerilen model, geleneksel yöntemlere kıyasla doğruluk (%97,02), F1 skoru (%91,87) ve AUC (%91,22) metriklerinde üstün performans sergilemiştir. Sistem, şehirlerin sürdürülebilir gelişimine destek olmak amacıyla nesnelere interneti (IoT) teknolojileriyle de entegre edilmiştir.

Wu ve ark., ev ortamında çöp tespiti ve sınıflandırması için görsel sahne anlama temelli bir yöntem önermiştir [12]. Çalışmada, YOLOv5m modeline ESA (Efficient Spatial Attention) mekanizması entegre edilerek YOLOv5m-Attention-KG modeli geliştirilmiştir. Bu model, bilgi grafikleri ile birleştirilerek nesne özelliklerinin daha etkili bir şekilde analiz edilmesini sağlamıştır. Model, 15.000 görüntüden oluşan veri seti üzerinde eğitilmiş ve %73,2 mAP ve 28 FPS performans göstermiştir. Sistem, ev hizmet robotları gibi uç cihazlarda gerçek zamanlı algılama ve sınıflandırma sağlayarak enerji tüketimini azaltmak ve sınıflandırma sürecini otomatikleştirmek için sunulmuştur.

Chen ve ark., atık sınıflandırma yöntemlerinde derin öğrenme teknolojisinin uygulamasını incelemiş ve ShuffleNetV2 modelini temel alarak GCNet adlı bir sınıflandırma modeli geliştirmiştir [13]. ShuffleNetV2, paralel karışık dikkat mekanizması (PMAM), FReLU aktivasyon fonksiyonu ve transfer öğrenme ile iyileştirilmiştir. PMAM, modelin boyutsal ve kanal özelliklerini güçlendirirken, FReLU aktivasyon fonksiyonu piksel seviyesinde uzamsal modelleme sağlayarak doğruluk performansını artırmıştır. GCNet modeli, yazarların kendi oluşturduğu 4.256 görüntüden oluşan veri seti üzerinde test edilmiş ve %97,9 doğruluk oranına ulaşmıştır. Ayrıca, model yalnızca 1.3M parametreye sahiptir ve Raspberry Pi 4B üzerinde 105 ms tekil çıkarım süresi ile çalışmaktadır. Yapılan modifikasyonlar sonucunda, GCNet'in ShuffleNet v2'den %4,5 daha yüksek doğruluk elde ettiği görülmüştür.

Fan ve ark., ev ortamında atık sınıflandırması için Raspberry Pi tabanlı akıllı bir çöp konteyneri tasarlamış ve geliştirmiştir [14]. Çalışmada, EfficientNetB2 modeli, paralel karışık dikkat mekanizması (PMAM) ve arka plan gürültü giderme algoritması ile modifiye edilmiştir. EfficientNetB2 modeli, son havuzlama katmanından önce PMAM ile güçlendirilmiş ve görüntü işleme sırasında arka planın etkisini azaltmak için özel bir ön işleme algoritması uygulanmıştır. Model, günlük ev atıklarının dört kategoride sınıflandırılmasını sağlamıştır: geri dönüştürülebilir, mutfak, tehlikeli ve diğer atıklar. Toplamda 14.802 görüntü içeren bir veri setinde %93,38 doğruluk oranı elde edilmiştir. Sistem, düşük maliyetli bir donanım olan Raspberry Pi 4B üzerine entegre edilmiştir. Bu sistem, günlük atık yönetimi için uygun maliyetli ve etkili bir çözüm sunarak, akıllı ev uygulamaları ve geri dönüşüm süreçlerinde kullanılabilir hale getirilmiştir.

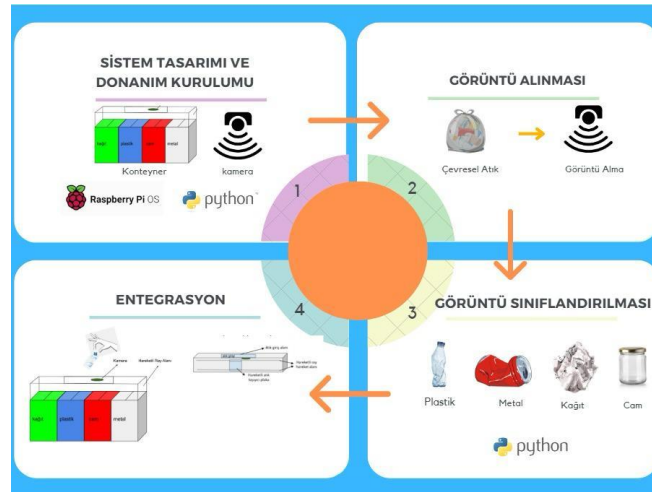
Jin ve ark., atık tespiti ve sınıflandırması için derin öğrenme tabanlı bir makine görüş sistemi geliştirmiştir [15]. Çalışmada MobileNetV2 modeli temel alınarak dikkat mekanizmaları (CBAM) ve

PCA ile modifiye edilmiştir. MobileNetV2 modeli üç farklı şekilde optimize edilmiştir: dikkat mekanizmaları ile özellik çıkarımının iyileştirilmesi, PCA ile parametre sayısının azaltılması ve aktarım öğrenmesi ile modelin genelleme kabiliyetinin artırılması. Her bir iyileştirme, Huawei Cloud veri seti üzerinde test edilmiş ve %90,7 gibi yüksek bir doğruluk oranına ulaşılmıştır. Önerilen model ve sistem, taşınabilir bir cihazda (Raspberry Pi 4B) uygulanmış ve otomatik bir çöp sınıflandırma cihazı olarak entegre edilmiştir.

Literatürdeki çalışmalar atık çöplerin sınıflandırılmasında derin öğrenme modellerin performansını artıracak parametre optimizasyonu, katman ve hiperparametre sayısı belirleme, dikkat mekanizması kullanma ve son teknoloji modellerini geliştirme konularına yoğunlaşmıştır. Bu çalışmada derin öğrenme modellerinin veri kümesine uyumunu sağlamak için son teknoloji modellerinin ince-ayarları (fine-tuning) yapılmıştır. Son yıllarda nesnenelerin interneti konseptinde çalışan çevresel atıkları sınıflandıran akıllı cihazların geliştirilmesi ve üretilmesi literatürde çalışılan güncel konular arasında yer almaktadır. Bu sistemler genellikle Raspberry Pi gibi ucuz ve düşük donanım kaynaklarına sahip küçük entegreler üzerinde geliştirilmektedir. Bu çalışmada çevresel atıkların sınıflandırılmasında Raspberry Pi üzerinde çalışacak bir akıllı çöp konteyneri sistemi tasarımı ve gerçekleştirilmesi yapılmıştır. Literatürde önerilen sistemlere göre bu çalışmada önerilen sistemin bazı farklılıkları bulunmaktadır. Bunların başında önerilen sistemin hem ev hem de dış ortam için kolaylıkla ürüne dönüştürülebilir yapıda olması gelmektedir. Ayrıca önerilen sistemde çevresel atığın taşınması ve ilgili bölüme bırakılması adım motoru gibi düşük maliyetli bir mekanizmayla gerçekleştirilmektedir.

3. Materyal ve Metod

Akıllı çöp konteyneri prototipi için geliştirilen yöntemin temel aşamalarının genel şeması Şekil 1'de verilmiştir. Bu çalışmada temel de dört aşama bulunmaktadır. Bu aşamalar çöp konteyneri tasarımı, sistem bileşenlerinin kurulumu, çevresel atıkların derin öğrenmeyle sınıflandırılması ve sistem entegrasyonu ve testlerinin yapılması şeklindedir.



Şekil 1. Önerilen yöntem; çevresel atıkları sınıflandırmanın temel aşamaları

Akıllı çöp konteyneri sistemindeki amaç insan müdahalesi olmadan çevresel atıkların derin öğrenme ve bilgisayarlı görü teknolojileri sayesinde yerinde otomatik bir şekilde sınıflandırılmasıdır. Birinci aşamada çöp konteyneri tasarımı gerçekleştirilmiştir. Konteyner üzerinde Raspberry Pi kurulumu ve tasarıma yerleştirilmesi yanında kamera, hareket algılama sensörü ve çevresel atıkları ilgili bölüme taşıyan hareketli ray sistemi bulunmaktadır. Bu aşamada, bu devrelerin konteyner üzerindeki yerleri, konteynerin büyüklüğü vb. tasarımlar gerçekleştirilmiştir.

İkinci aşamada akıllı çöp konteyneri için sistem bileşenlerinin kurulumu gerçekleştirilmiştir. Bu aşamada i- Raspberry Pi işletim sisteminin versiyon olarak en güncel hali olan Raspberry Pi OS kurulumu, ii- derin öğrenme kütüphanelerinden Tensorflow ve Keras kurulumu, iii- hareketi algılayan sensörün yerleştirilmesi ve sensörü kontrol eden uygulamaların geliştirilmesi, iv- hareketli atık çöp plakasının yerleştirilmesi, adım motoru kurulumu ve hareketi gerçekleştiren uygulamaların geliştirilmesi, v- kamera sisteminin entegrasyonu işlemleri gerçekleştirilmiştir.

Üçüncü aşamada Raspberry Pi ile çevresel atıklar derin öğrenme modelleriyle sınıflandırılmıştır. Sınıflandırma işlemi için literatürde görüntü işleme alanında yüksek performans sağlayan DenseNet201, Inception-V3, ResNet50, VGG16 ve DenseNet169 modelleri kullanılmıştır. Bu modellerin performansını arttırmak ve veri kümesine uyumunu sağlamak adına ince-ayar (fine-tuning) yapılmıştır. Bu kapsamda modellere ek eğitilebilir katmanlar eklenmiş ve performans testleri yapılmıştır. Derin öğrenme modelleri yardımıyla çöp konteynerine atılan atıkların sınıfları cam, metal, kağıt ve plastik olarak tahmin etmiştir. Bu modellerin literatürdeki çevresel atık veri kümeleri üzerindeki performansları araştırılmıştır. Bu araştırma sonucunda en iyi başarıyı gösteren model Raspberry Pi üzerinde akıllı çöp konteynerinin sınıflandırıcı metodu olmuştur. Belirlenen bu model yardımıyla atılan atıkların sınıfları belirlendikten sonra hareketli ray sistemi atığı, ilgili atık bölümüne hareket ederek götürmüştür.

Dördüncü aşamada bir bütün olarak sistemin entegrasyonu yapılmış ve örnek senaryolar doğrultusunda akıllı çöp konteynerinin performansı değerlendirilmiştir. Sistemin çalışmasını sağlayan bir bütün yazılım geliştirmesi ve modülleri entegrasyonu bu aşamada gerçekleştirilmiştir. Kamera görüntülerinin algılanması uygulaması, hareket sensörü uygulaması, hareketli ray sistemini kontrol uygulaması ve üçüncü aşamada geliştirilen derin öğrenme sınıflandırma uygulamaları bu aşamada birleştirilerek akıllı çöp konteyneri yazılımı Raspberry Pi üzerinde çalıştırılmıştır.

3.1. Akıllı Çöp Konteyneri Tasarımı

Çevresel atık çeşitleri için ayrılmış dört bölmeden oluşan çöp konteyneri tasarımı Şekil 2’de verilmiştir. Bir çevresel atık çöp konteynerine hareketli plaka üzerine bırakıldıktan sonra; i- sensör çevresel atığı fark edip kamera yardımıyla görüntüsünü almakta, ii- derin öğrenme modeliyle sınıflandırılmakta, iii- hareketli plaka adım motoru yardımıyla ray üzerinde hareket ederek çöpi ilgili bölüme taşımaktadır. Hareketli atık taşıyıcı plaka ilgili kategori üzerine geldikten sonra çöpi bu alandan aşağıya atılması planlanmıştır. Ancak hareketli atık taşıyıcı plakanın açılır kapanır şekilde tasarlanması ele alınmamıştır. Atık kutularının üst bölmesindeki kutu içerisinde tüm donanım ekipmanları bulunmaktadır (Raspberry Pi, kamera, sensörler, motorlar, kablolar, ray sistemi). Oluşturulan prototip konteyner, kartondan tasarlanmıştır.



Şekil 2. Akıllı çöp konteyneri bileşenleri

Şekil 3’te çöp konteyneri üzerinde çalışan hareketli ray sisteminin tasarımı verilmiştir. Atık konteynerine atıldıktan sonra Şekil 3’teki görüldüğü gibi hareketli atık taşıyıcı plaka üzerine düşmektedir.

Plaka ileri-geri olacak şekilde adım motor yardımıyla iki yönlü hareket etmektedir. Ray sisteminin hareketi adım motor ile sağlanmıştır. Ray tasarımı ve ray hareket yolunun tasarımında ipler ve çubuklar kullanılmıştır.



Şekil 3. Hareketli ray tasarımı

3.2. Sistem Bileşenlerinin Kurulumu ve Entegrasyonu

Çöp görüntülerinin sınıflandırılması ve çöp taşıyıcı ray sisteminin kontrol edilmesi işlemleri tasarlanan prototip üzerine yerleştirilen Raspberry Pi 4 Model B yardımıyla gerçekleştirilmiştir. Raspberry Pi, tek bir kart üzerine inşa edilmiş kompakt bir küçük bilgisayardır. Bir bilgisayarın ihtiyaç duyduğu işlemci, RAM, giriş/çıkış portları gibi tüm bileşenler, bu tek devre kartında bir araya getirilmiştir.

Raspberry Pi Kamera Modülü 3, Raspberry Pi kamera serisinin en yaygın kamera parçasıdır. Raspberry Pi'den adım motoru kontrolünü sağlamak için motor sürücü devresi olarak ULN2003A kullanılmıştır. Atık konteynere atıldığında Raspberry Pi Kamera Modülünün fotoğrafı çekebilmesi için Hc-sr501 ayarlanabilir hareket algılama sensörü aracılığıyla tespit edilmektedir. Adım motorlar adım adım döndürülebilen çok hassas konum kontrol imkanı sağlayan motorlardır. Hareketli plakanın çöp bölümleri arasında hareketi için adım motor kullanılmıştır. BreadBoard devrelerimizi birbirine lehimlemeden kurmamıza, test yapmamıza ve devreyi kontrol ederek bir hata olup olmadığını anlamamıza olanak sağlamaktadır. Hareketli ray sisteminin kontrolü için kullanılan modüller Şekil 4'te verilmiştir.



a-) Raspberry Pi 4 Model B



b-) 28 BYJ-48 Redüktörlü Adım Motoru



c-) ULN2003A Adım Motor Sürücü Kartı



d-) HC-SR501 Ayarlanabilir IR Hareket Algılama Sensörü




e-) Raspberry Pi Kamera Modülü 3

Şekil 4. Sistem bileşenleri

16 GB büyüklüğünde bir SD kartına Raspberry Pi'nin kendi işletim sisteminin kurulumu yapılmıştır. Bu kurulumdan sonra Şekil 5'te şeması gösterilen bağlantılar gerçekleştirilerek devre tamamlanmıştır. Adım motorun dönme sayısı ve dönme hızı oluşturmuş ray prototipinin şekline ve uzunluğuna göre belirlenmiştir. Adım motoru sayesinde hareketli atık taşıyıcı plaka ilgili atığın hizasına getirilmiştir. Akıllı çöp konteyneri bileşenleri tasarlanan prototip üzerine yerleştirilmiştir.

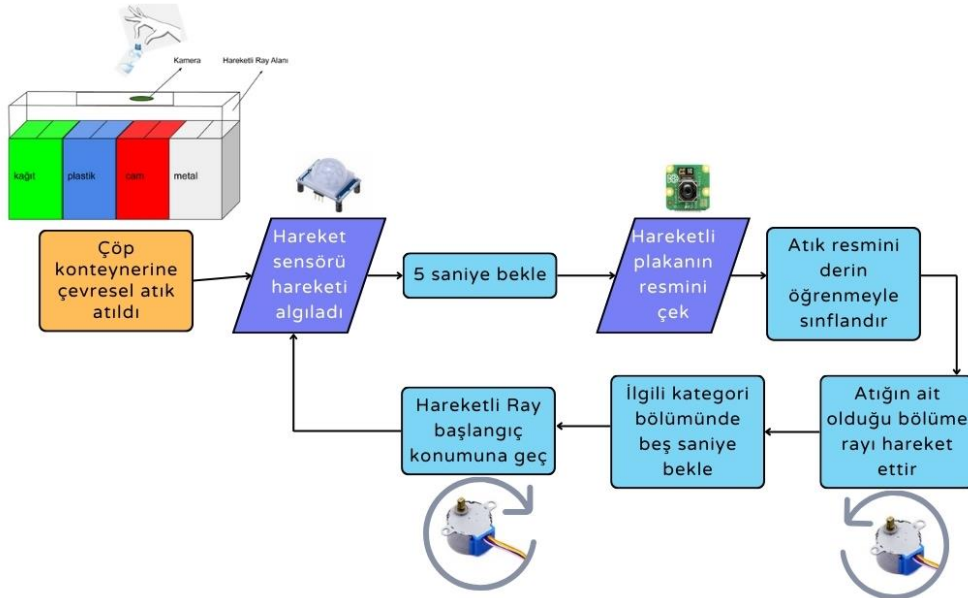
Raspberry Pi kartında derin öğrenme modellerinin çalıştırılabilmesi için TensorFlow Lite kurulumu yapılmıştır. TensorFlow, Google Beyin ekibi tarafından makine öğrenmesi algoritmalarının uygulanması amacıyla geliştirilmiş bir yazılım çatısıdır [16]. TensorFlow temelde derin öğrenme

ağlarının kullanımını desteklemek için geliştirilmiştir. TensorFlow'un yanında Keras yazılım çatısı kullanılmıştır. Keras yardımıyla aynı uygulama içerisinde hem yinelemeli hem de evrişimsel sinir ağı modeli tanımlanabilmektedir. Modüler bir yapı sağladığından her ağ katmanının özellikleri kolayca belirlenebilmektedir. Yani maliyet fonksiyonlar, aktivasyon fonksiyonları, iyileştirme yöntemleri, seyreltme (Dropout) gibi model için önem arz eden parametreler birer satırla belirlenmektedir [17].



Şekil 5. Devre bağlantı şeması

Derin öğrenme modelinin literatürdeki veri seti üzerindeki eğitimi tamamlandıktan sonra kameradan alınan görüntülerin sınıfının tahmin edilmesi için Raspberry Pi'ye yüklenmiştir. Modelin sınıflandırma sonucuna göre adım motoru yardımıyla çevresel atığın ilgili bölmeye götürülmesi sağlanmıştır. Gerçek sistem testinde fiziksel atıklar yerine fiziksel atıkların fotoğrafları çöp konteynerine bırakılmıştır. Çevresel atıkların çöp konteynerine bırakılmasıyla, hareket sensörü algılama yapmakta ve akıllı çöp konteyneri için geliştirilen sistem çalışmaya başlamaktadır. Hareketin algılanmasından beş saniye sonra sistemdeki kamera aracılığıyla fotoğraf çekilmiştir. Akıllı çöp konteynerinin örnek bir senaryosunda yapılan işlemlerin akış şeması Şekil 6'da verilmiştir.




Şekil 6. Akıllı çöp konteyneri çalışmasının akış şeması

3.3. Çevresel Atıkların Derin Öğrenmeyle Sınıflandırılması

Çevresel atıkların sınıflandırılması aşamasında derin öğrenme yöntemleri kullanılmıştır. Derin öğrenme, yapay sinir ağlarının etkili ve verimli bir versiyonudur [18]. Yapay sinir ağlarıyla yapılan öğrenme işlemini yüksek katman sayısına sahip modellerle gerçekleştirme işlemi günümüzde kaba bir tanımla derin öğrenme olarak ifade edilmektedir [19]. Derin öğrenme algoritmaları veri kümesi içerisinde öznelik çıkarımını otomatik olarak gerçekleştirmektedir. CNN modeli, derin öğrenmenin en önemli mimarilerinden biridir. Genellikle görüntü sınıflandırma amacıyla kullanılan CNN modelinin, girişi bir görüntü olurken, çıkışı ise görüntünün sınıf etiket değeridir.

Görüntü verilerini giriş olarak alan ve görüntünün sınıfını tespit etmeye çalışan bir CNN modelinin katmanlar arasındaki ilişkilerini belirten şema Şekil 7'de verilmiştir. CNN'de çeşitli filtreler yardımıyla görüntüden öznelik çıkarımı işlemi evrişim katmanında yapılmaktadır. Evrişim katmanından elde edilen özneliklerin doğrusal olmamasının sağlanması için genellikle evrişim katmanı ile havuzlama katmanı arasında ReLU (Rectified Linear Units) aktivasyon fonksiyonu uygulanmaktadır [20]. Havuzlama katmanında ise elde edilen bu özellik haritalarının boyutları düşürülmektedir. CNN'nin son katmanı ise tam bağlı katmandır.



Şekil 7. Görüntü sınıflandırma için genel CNN katmanları görünümü

Çevresel atıkların sınıflandırmasında ve sistemin testlerinin yapılması aşamasında görüntü sınıflandırmada çokça tercih edilen ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 modelleri üzerinde performans araştırmaları yapılmıştır. Bu beş model arasında en iyi başarıyı elde edilen model sistemin sınıflandırıcı modeli olarak seçilip entegrasyonu yapılmıştır.

ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 görsel tanıma ve sınıflandırma için kullanılan CNN modelleridir. DenseNet201 ve DenseNet169 "yoğun bağlantılar" olarak bilinen yapıyı kullanmaktadır. Yoğun bağlantılar, her katmanın kendinden önceki tüm katmanların çıktılarına bağlandığı anlamındadır. Bu, bilgi akışını artırır, parametre sayısını azaltır ve gradyanın daha iyi aktarılmasını sağlamaktadır. DenseNet169 ise 169 katmandan oluşan bir modelken, DenseNet201 201 katmandan oluşan bir modeldir [21]. ResNet50 "geri kalan bağlantılar" olarak bilinen bir yapıdadır. Bu daha derin ağların eğitimini kolaylaştırır ve aşırı öğrenmeyi azaltmaktadır. ResNet50, 50 katmandan oluşan bir başka CNN modelidir. ResNet modelinin diğer modellerden ayırt edici özelliği, daha derin bir yapıya sahip olmasıdır. 2015 yılındaki ILSVRC yarışmasında %3.6 hata oranıyla birinci olmuştur [22].


VGG16, 2014 yılında Simonyan ve Zisserman tarafından geliştirilmiş derin öğrenme modelidir. Modelin 16 katmanlı olduğunu belirtmek için VGG16 olarak isimlendirilmiştir. VGG16 modelinde 138 milyondan fazla parametre bulunmaktadır [23].

Inception modeli Szegedy ve ark. tarafından 2015 yılında geliştirilmiştir. Inception-V3 modeli Inception-V1 ve Inception-V2 modelinin iyileştirilmesiyle oluşturulmuştur. Inception-V3 modelinde 24 milyon parametre bulunmaktadır [23]. Inception modeli, evrişim katmanındaki filtreleme ve havuzlama işlemlerinin eş zamanlı olarak yapılmasını sağlamıştır [24]. Çevresel atıkların sınıflandırılmasında bu


modeller referans alınmış ve veri kümesi üzerinde ince-ayar (fine-tuning) ve parametre optimizasyonu yapılmıştır.

3.3.1 Veri Kümesi

Sistemin ön testlerinin yapılmasında ve derin öğrenme modellerinin performans araştırması aşamasında Garbage Classification veri seti kullanılmıştır [25]. Bu veri seti 2021 yılında yayınlanmış ve literatürde sıklıkla kullanılan bir kıyaslama veri setidir. Veri seti güvenilir bir kaynak olan Kaggle platformundan erişildiği için, verilerin doğru etiketlendiği kabul edilmiştir. Toplamda 2527 görüntüden oluşan bu veri seti, 6 farklı sınıfa ayrılmıştır. Ancak bu çalışmada 4 sınıfa ait (Cam, Metal, Kağıt ve Plastik) 1947 adet görüntü kullanılmıştır. Bunların %80 (1589) eğitim, %20 (398) ise test aşamasında kullanılmıştır. Şekil 8’de sınıf bazlı görüntü sayıları test ve eğitim olarak yer almaktadır. Ayrıca Şekil 9’da her sınıfa ait üç adet örnek görüntü verilmiştir.



Şekil 8. Veri kümesinin sınıf bazlı görüntü sayıları



Şekil 9. Veri kümesi örnek görüntüleri; a) Cam, b) Metal, c) Kağıt ve d) Plastik

3.3.2 Model Performans Değerlendirme Ölçütleri

Her bir çevresel atık görüntüsünün plastik, metal, kağıt ve cam olarak sınıflandırılması aşamasında algoritmanın başarımlarını ölçmek için literatürdeki metrikler kullanılmıştır. Bu metrikler; doğruluk (Denklem 1), hassasiyet (Denklem 2), duyarlılık (Denklem 3) ve F-ölçütü (Denklem 4) şeklindedir. Bu ölçütlerin hesaplanmasında karmaşıklık matrisi kullanılmaktadır. Şekil 10'da karmaşıklık matrisinin görseli verilmiştir.

Tahmin Edilen	Pozitif	TP	FP
	Negatif	FN	TN
		Pozitif	Negatif
		Gerçek	

Şekil 10. Karmaşıklık matrisi

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Hassasiyet (Precision)} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP + FP} \quad (3)$$

$$F - \text{ölçütü (F - measure)} = 2 * \left(\frac{\text{hassasiyet} * \text{duyarlılık}}{\text{hassasiyet} + \text{duyarlılık}} \right) \quad (4)$$

4. Deneysel Sonuçlar ve Tartışma

Raspberry Pi üzerinde derin öğrenme modellerinin eğitilmesi ve test edilmesi için derin öğrenme kütüphanelerinden Tensorflow ve Keras kullanılmıştır. Raspberry Pi üzerine ise Tensorflow Lite kurulumu gerçekleştirilmiştir. Bu kurulum ile hali hazırda eğitilmiş olan derin öğrenme modelleri çalıştırılmıştır. Eğitilmiş olan .h5 uzantılı model dosyaları öncesinde Google Colab ortamında .tflite olarak dönüştürülmüştür. Bu dönüşümün yapılmasının nedeni Keras'ın tflite içerisinde kullanılmamasından kaynaklanmaktadır. Sonrasında Raspberry Pi üzerinde .tflite uzantılı dosya kullanılarak sınıflandırılma gerçekleştirilmiştir.


Çevresel atıkların sınıflandırılmasında ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 modelleri kullanılmıştır. Modellerin ince-ayar (fine-tuning) ve parametre optimizasyonu süreçleri, doğruluk ve genel başarı metriklerini artırmak amacıyla dikkatlice tasarlanmıştır. Bu süreçte, temel olarak transfer öğrenme kullanılmış ve modeller, önceden ImageNet veri seti üzerinde eğitilmiş ağırlıklarla başlatılmıştır. İnce-ayar sürecinde, yalnızca son katmanlar yeniden eğitilmiş, böylece hesaplama maliyeti azaltılmış ve eğitim sürecinin daha hızlı olması sağlanmıştır. Her modelin sonuna eğitilebilir tam bağlı katman ve havuzlanma katmanları eklenmiştir. Tam bağlı katmandaki nöron sayısı 1024, 512, 256, 128, 64 ve 32 olacak şekilde deneyler gerçekleştirilmiştir. Model performansı doğrulama

veri seti üzerinde test edilerek, her model için en iyi hiperparametreler seçilmiştir. Tüm modellerin ince-ayar sırasında doğrulama kaybı (validation loss) göz önünde bulundurulmuş ve erken durdurma (early stopping) tekniği kullanılarak aşırı öğrenme (overfitting) önlenmiştir. Sınıflandırmada her model için ince-ayar (fine-tuning) ve parametre optimizasyonu yapılmış olup yapılan değişiklikler aşağıdaki gibidir:

- **ResNet50:** Bu model için iki boyutlu ortalama havuzlama katmanı kullanılarak, modelin çıkışındaki özellik haritalarının her bir kanalının ortalaması alınmıştır. Bu işlem, yüksek düzeyde özetlenmiş bir özellik vektörü oluşturur ve modelin daha genel özellikleri öğrenmesini sağlar. Bu özetlenmiş özellik vektöründen sonra, 256 nöronlu oluşan bir Dense katmanı eklenmiştir. Bu katman, ReLU aktivasyon fonksiyonunu kullanarak modelin daha karmaşık ilişkileri öğrenmesini sağlamıştır ve gizli katman aracılığıyla yüksek düzeyde özellikler çıkarmıştır. Aşırı uyumu önlemek amacıyla, Dropout katmanı eklenmiş ve burada nöronların %50'si rastgele devre dışı bırakılmıştır. Bu, modelin genelleme yeteneğini artırarak, eğitim verisine aşırı uyum sağlamasını önlemiştir. Dört sınıfa karşılık gelen birimlerden oluşan bir Dense çıkış katmanı eklenmiş ve softmax aktivasyon fonksiyonu kullanılmıştır. Bu katman, her bir sınıf için olasılık değerleri üretmiş ve çok sınıflı sınıflandırma problemlerinde kullanılacak nihai tahminleri sağlamıştır.
- **DenseNet201:** Bu model için iki boyutlu ortalama havuzlama katmanı kullanılarak özellik haritalarının boyutu küçültülmüştür. Ardından, 256 nöronlu ve 'relu' aktivasyon fonksiyonuna sahip tam bağlantılı bir katman olan *Dense(256, kernel_regularizer=l2(0.001))* katmanı eklenmiştir. Bu katmanı, aktivasyonları normalize eden *BatchNormalization()* ve aşırı uyumu önlemek için nöronların %50'sini devre dışı bırakan *Dropout(0.5)* katmanları izlemiştir. Daha sonra, 256 nöronlu bir tam bağlantılı katman olan *Dense(256, activation='relu', kernel_regularizer=l2(0.001))* ve yine %50 dropout katmanı aşırı uyumu önlemek için eklenmiştir. Dört sınıfa karşılık gelen birimlerden oluşan bir Dense çıkış katmanı eklenmiş ve softmax aktivasyon fonksiyonu kullanılmıştır.
- **DenseNet169:** Bu model için *GlobalAveragePooling2D()* katmanı kullanılarak özellik haritalarının boyutu küçültülmüştür. Sonrasında 32 nöronlu oluşan bir tam bağlı (Dense) katman eklenmiştir.
- **Inception-V3:** Bu model için *GlobalAveragePooling2D()* katmanı eklenmiştir. Ardından, 512 nöronlu ve 'relu' aktivasyon fonksiyonuna sahip bir tam bağlantılı Dense katmanı eklenmiştir. Bu katmanı, modelin genelleme kabiliyetini artırmak için nöronların %50'sini devre dışı bırakan *Dropout(0.5)* katmanı izlemiştir. Son olarak, dört sınıflı bir sınıflandırma için *Dense(len(classes_dict), activation='softmax')(x)* kullanılmıştır.
- **VGG16:** Bu modelde hiper parametre olarak 512 nöronlu ve 'relu' aktivasyon fonksiyonuna sahip tam bağlantılı bir katman olan *Dense(512, kernel_regularizer=l2(0.001))* iki adet katman eklenmiştir. Dense katmanının *kernel_regularizer=l2(0.001)* oranı ile ağırlıkların aşırı büyümesini sınırlayarak aşırı uyumu önlemeye yardımcı olmuştur. *BatchNormalization* katmanı ile her bir özellik vektörünü normalleştirilmiştir. Normalizasyon, eğitim sürecini hızlandırmış ve modelin performansını arttırmıştır.

ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 modelleri ile deneyler yapılmıştır. Çalışılan tüm modellerin eğitimi yüz iterasyonda tamamlanmıştır. Tüm modellerde eğitim sırasında aynı veri seti kullanılarak karşılaştırma yapılmıştır. Kullanılan veri seti %80 eğitim, %20 test olarak ayrılmıştır. ResNet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 modellerinin testinde doğruluk, hassasiyet, duyarlılık ve F-ölçütü metrik sonuçları Şekil 11'de sunulmuştur. Beş

modelin doğrulama doğruluk değerleri ResNet50 %94, DenseNet201 %91, DenseNet169 %95, InceptionNet %88 ve VGG16 ise %81 olarak elde edilmiştir. Modeller arasında DenseNet169, dört metrikte de en yüksek performansı göstererek (%95,22 doğruluk, %95,45 hassasiyet, %95,22 duyarlılık ve %95,21 F-ölçütü) genel olarak en iyi model olmuştur. Bu üstünlük, DenseNet169'un yoğun bağlantı yapısının, özelliklerin yeniden kullanımını kolaylaştırması ve gradyanların daha verimli bir şekilde akmasını sağlamasından kaynaklanmaktadır. ResNet50, %93,97 doğruluk ve diğer metriklerdeki dengeli sonuçlarıyla iyi bir performans sergilemiş; sıçrama bağlantıları sayesinde daha derin bir ağ olmasına rağmen gradyan kaybını engelleyerek yüksek doğruluk sağlamıştır. Ancak, DenseNet169'un daha küçük ancak optimize edilmiş bir model olması onu ResNet50'nin önüne geçirmiştir. DenseNet201, %91,45 doğruluk ve benzer seviyelerdeki diğer metriklerle DenseNet169'un gerisinde kalmıştır. Bunun nedeni, daha derin bir yapı olmasına rağmen ek derinliğin modelin genelleme kabiliyetine katkı sağlayamaması ve hesaplama yükünü artırması olabilir. Inception-V3, %88,44 doğruluk ile ortalama bir performans göstermiştir. Modelin çok ölçekli özellik çıkarımı yapısı avantaj sağlasa da daha modern modellerin sunduğu yoğun bağlantılar ve sıçrama mekanizmalarının eksikliği performansını sınırlamıştır. Ayrıca Inception-V3 modelinin eğitim ve test aşamalarındaki performansı arasında %8'e yakın bir fark olduğu görülmüştür. Bu modelin eğitim ve test aşamalarındaki doğruluk değerleri arasındaki başarımlar diğer modellere göre daha yüksektir. Bu nedenle bu modelin eğitim aşamasında aşırı uyum (overfitting) olduğu söylenebilir. Son olarak, VGG16, %80,90 doğruluk ile en düşük performansı göstermiştir. Bu modelin sınırlı özellik çıkarımı yapısı ve yüksek parametre sayısı, modern modellerle karşılaştırıldığında düşük bir doğrulukla sonuçlanmıştır.

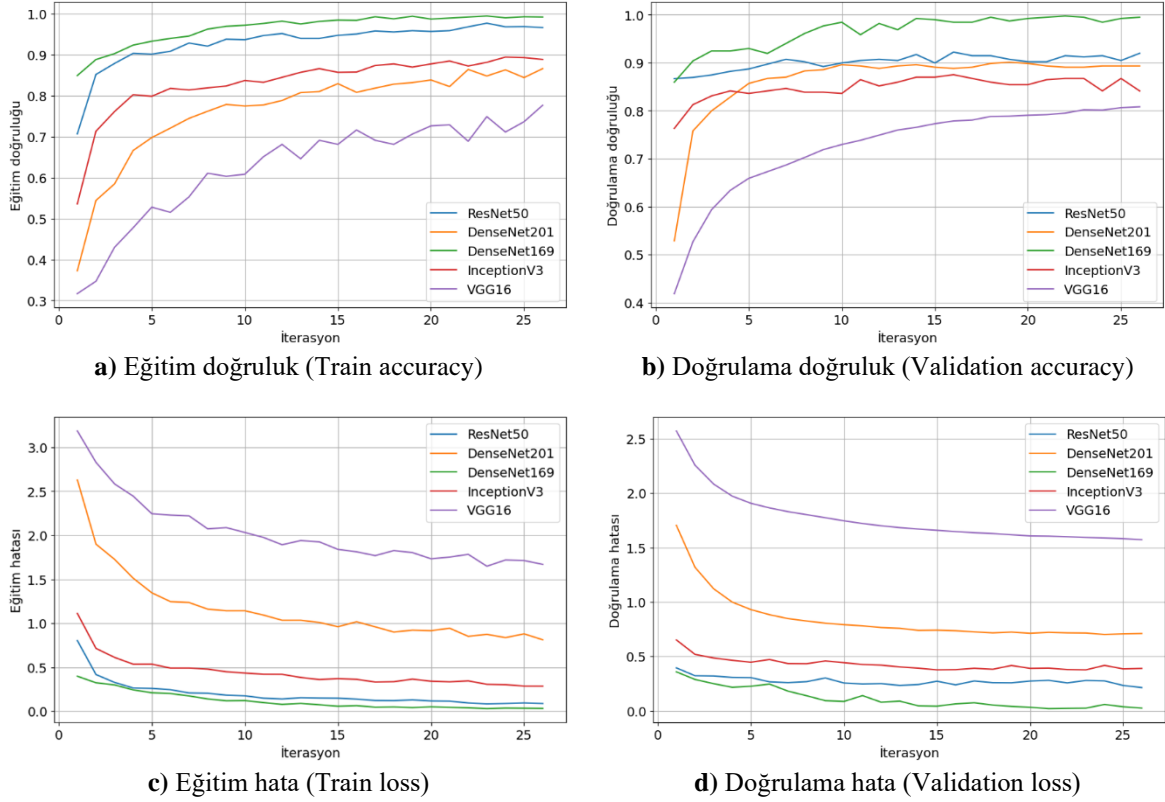


Şekil 11. Derin öğrenme modellerinin başarımlar metrikleri

DenseNet169'un diğer modellerden daha başarılı olmasının nedenleri arasında yoğun bağlantı (dense connectivity) yapısının olduğunu söylemek mümkündür. Bu mimari, her katmanın kendisinden önceki tüm katmanların çıktısını giriş olarak kullanmasını sağlayarak bilgi kaybını önlemekte ve özelliklerin yeniden kullanılmasını sağlamaktadır. Bu modelin gradyanların akışı iyileştirilir ve eğitilebilirliği artırılır. Ayrıca, DenseNet169 daha az parametreyle çalışarak aşırı öğrenme riskini azaltmış ve veri setinde genelleme yapabilme kabiliyetini güçlendirmiştir. DenseNet169'un optimize edilmiş derinliği, DenseNet201 gibi daha derin modellere kıyasla hesaplama verimliliğini korurken yüksek performans sunmasına olanak tanımıştır. Ayrıca DenseNet169 için yapılan ince-ayarda modelin sonuna 32 nöronlu tam bağlı katman eklenmiştir. Diğer modellere göre daha az sayıda nöronla yüksek başarımlar elde edilmiştir.

Şekil 12'de modellerin eğitim ve test aşamalarındaki doğruluk ve hata eğrileri verilmiştir. Şekil 12 a ve b'de eğitim ve doğrulama aşamalarındaki doğruluk değerlerinin eğrileri verilmiştir. Diğer taraftan




c ve d’de ise eğitim ve doğrulama aşamasındaki hata eğrileri verilmiştir. Modellerin eğitim ve test aşamaları için 100 iterasyon olacak şekilde erken durdurma (early stopping) mekanizmasıyla eğitimi ve testi yapılmıştır. Şekil 12’deki eğrilere bakıldığında modellerin 25 iterasyon sonrasında en düşük hata değerine eriştikleri görülmektedir. Modellerden en hızlı yakınsayan modelin DenseNet169 olduğu görülmektedir.



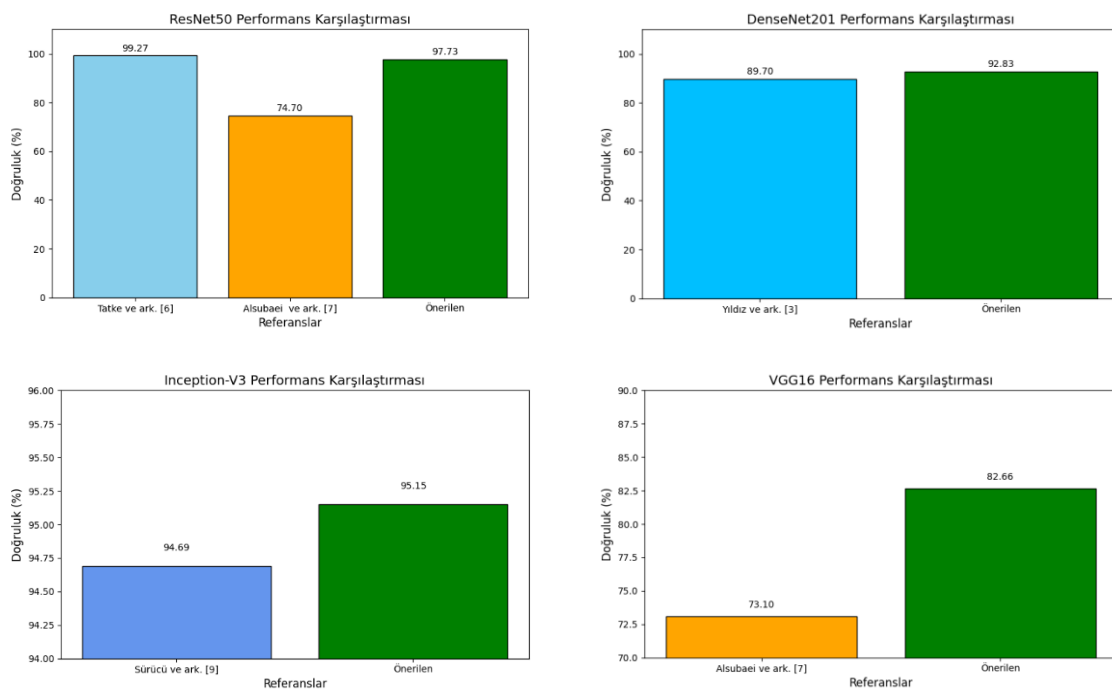
Şekil 12. Derin öğrenme modellerinin eğitim ve test aşamasındaki doğruluk ve hata eğrileri

Modellerin eğitimleri tamamlandıktan sonra yeni görüntülerle modellerin tahmin ve güven değerleri incelenmiştir. Yapılan bu testlerden bazı örneklerin sonuçları Çizelge 1’de verilmiştir. Çizelge 1’deki örneklere bakıldığında DenseNet201 ve VGG16 modellerinin bazı örnekleri yanlış sınıflandırdığı (kalın olarak vurgulanmıştır) görülmektedir.

Çizelge 1. Modellerin bazı örneklerdeki sınıflandırma sonuçları.

Giriş Görüntüsü	Kağıt		Plastik		Cam	
	Tahmin	Güven	Tahmin	Güven	Tahmin	Güven
	ResNet50	Kağıt	0,99	DenseNet201	Metal	0,86
	Inception-V3	Kağıt	0,63	DenseNet169	Plastik	1,0
	VGG16	Plastik	0,86	Inception-V3	Plastik	0,99
	ResNet50	Kağıt	0,99	DenseNet201	Cam	0,94
	DenseNet169	Kağıt	0,86	Inception-V3	Cam	0,88
	VGG16	Plastik	0,86	DenseNet169	Cam	0,93
	ResNet50	Kağıt	0,99	VGG16	Cam	0,99

Bu çalışmada kullanılan modellerin eğitim aşamasındaki doğruluk değerlerinin aynı veri kümesi üzerinde gerçekleştirilen önceki çalışmalarla kıyaslanması Şekil 13'te yapılmıştır. İnce-ayar ve parametreleri belirlenen modellerin performanslarının önceki çalışmalarla karşılaştırıldığında genel olarak daha yüksek doğruluk oranlarına ulaştığını göstermektedir. ResNet50 modeli, %97.73 doğruluk ile Alsubaei ve ark.'nın (%74.70) çalışmasından belirgin şekilde üstün performans sergilemiş, ancak Takke ve ark.'nın (%99.27) elde ettiği doğruluğun biraz gerisinde kalmıştır. DenseNet201 modeli ise Yıldız ve ark.'nın %89.70'lik sonucuna kıyasla %92.83 doğruluk oranı ile daha iyi bir başarı göstermiştir. Inception-V3 modeli için önerilen yöntem %95.15 doğruluk ile Sürücü ve ark.'nın %94.69'luk çalışmasını az bir farkla geride bırakmıştır. Son olarak, VGG16 modeli %82.66 doğruluk ile Alsubaei ve ark.'nın %73.10'luk sonucuna göre kayda değer bir gelişim sağlamıştır. Bu sonuçlar, önerilen yöntemlerin ince-ayar ve optimizasyon süreçleri sayesinde daha başarılı sınıflandırma performansı sergilediğini açıkça ortaya koymaktadır.



Şekil 13. İnce-ayarı yapılan modellerin performanslarının önceki çalışmalarla kıyaslanması

5. Sonuç

Oluşan nüfus yoğunluğuna bağlı olarak kaynak kullanımının artması sonucunda oluşan atık miktarının oldukça artması sürdürülebilir bir dünya ve yaşam için büyük bir risk oluşturmaktadır. Bu çalışma da ise geri dönüştürülebilir atıkların daha sürdürülebilir bir dünya ve yaşam için yerinde ve otomatik olarak ayrıştırılmasını gerçekleştiren akıllı çöp konteyneri prototipi oluşturulmuştur. Önerilen akıllı çöp konteyneri içerisine bırakılan çevresel atığı fark etmekte, sınıflandırmakta ve kategorisine otomatik bir şekilde taşımaktadır. Böylece çevresel atıkların yerinde ve tam zamanında ayrıştırılmasını sağlayarak çevresel atıkların ayrıştırılması için mevcut kullanılan maliyetleri düşürmektedir.

Önerilen akıllı çöp konteyneri donanımsal olarak Raspberry Pi 4 model B, 28 BYJ-48 redüktörlü adım motoru, ULN2003A adım motor sürücü kartı, HC-SR501 ayarlanabilir hareket algılama sensörü, Raspberry Pi kamerası kullanılmıştır. Raspberry Pi üzerinde atıkları sınıflandırmak için Resnet50, DenseNet201, DenseNet169, Inception-V3 ve VGG16 derin öğrenme modelleri ile eğitimler

yapılmıştır. Her model için ince-ayar gerçekleştirilmiş olup, çevresel atıkların sınıflandırmasında modellerin başarımları arttırılmıştır. Eğitim ve test aşamalarından sonra modellerden elde edilen doğruluk başarımları karşılaştırılmıştır. En yüksek doğruluğa sahip olan modelin DenseNet169 olduğu görülmüştür. Sonuç olarak DenseNet169 en iyi sınıflandırma yapan derin öğrenme modeli olduğundan akıllı çöp konteyneri sistemi için bu model kullanılmıştır. Gelecekteki araştırmanın bir parçası olan bu çalışmanın sonuçlarına bakılarak, atık artışıdaki miktarın ve taşıdığı risklerin önüne geçilebilmesi için hazırlanmış olduğumuz bu prototip çalışmasının ilerleyen çalışmalarda ürüne dönüştürülerek kullanıma sunulmasını planlanmaktadır.

Teşekkür

Bu çalışma TÜBİTAK tarafından 1919B012302200 numaralı projeyle desteklenmiştir.

Katkı Beyanı

Makaledeki akıllı çöp konteynerinin geliştirilmesi fikri, araştırma metodolojisinin oluşturulması, makalenin yazımı aşamalarında Mehmet Umut Salur, makaledeki donanımsal bileşenlerin kurulumu ve gerekli yazılımların kurulması aşamasında Nermin Elmas ve Aybuke Nur Koçak, makalenin yazılması ve derin öğrenme modellerinin eğitim ve test aşamalarında Mehmet Umut Salur, Nermin Elmas, Aybuke Nur Koçak ve Melike Kaymaz katkı sunmuştur.

Çıkar Çatışması Beyanı

Makalenin yazar/yazarları, çalışma kapsamında herhangi bir kişisel ve finansal çıkar çatışması olmadığını beyan etmektedirler.

Kaynaklar

- [1] Bobulski J, Kubanek M. Deep learning for plastic waste classification system. *Applied Computational Intelligence and Soft Computing* 2021;2021(1):6626948.
- [2] Varol Varol S, Hark C, Kızılluluk S. Geri dönüştürülebilir atıkların sınıflandırılması. In: 6th International Artificial Intelligence & Data Processing Symposium, Malatya, Türkiye; 2022.
- [3] Yıldız EN, Bingöl H, Yıldırım M. Önerilen derin öğrenme ve makine öğrenmesi tabanlı hibrit model ile çevresel atıkların sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 2023;35(1):353-361.
- [4] Sağlam A, Taş M, Baykan N. Geri dönüştürülebilir atıkların materyallerine göre sınıflandırılması için raspberry pi tabanlı donanım geliştirilmesi. *Avrupa Bilim ve Teknoloji Dergisi* 2020;30-38.
- [5] Ahmed MIB, Alotaibi RB, Al-Qahtani RA, Al-Qahtani RS, Al-Hetela SS, Al-Matar KA, Al-Saqer NK, Rahman A, Sarairoh L, Youldash M, Krishnasamy G. Deep learning approach to recyclable products classification: towards sustainable waste management. *Sustainability* 2023;15(14):11138.
- [6] Tatke A, Patil M, Khot A, Karad's PJV. Hybrid approach of garbage classification using computer vision and deep learning. *International Journal of Engineering Applied Sciences and Technology* 2021;5(10):208-213.
- [7] Alsubaei FS, Al-Wesabi FN, Hilal AM. Deep learning-based small object detection and classification model for garbage waste management in smart cities and iot environment. *Applied Sciences* 2022;12(5):2281.
- [8] Kang Z, Yang J, Li G, Zhang Z. An automatic garbage classification system based on deep learning. *IEEE Access* 2020;8:140019-140029.

- [9] Sürücü S, Ecemiş İN. Garbage classification using pre-trained models. *European Journal of Science and Technology* 2022;(36):73-77.
- [10] Keskin S, Sevli O, Okatan E. Comparative analysis of the classification of recyclable wastes. *Journal of Scientific Reports-A* 2023;(055):70-79.
- [11] Zhou Y, Wang Z, Zheng S, Zhou L, Dai L, Luo H, Zhang Z, Sui M. Optimization of automated garbage recognition model based on resnet-50 and weakly supervised cnn for sustainable urban development. *Alexandria Engineering Journal* 2024;(108):415-427.
- [12] Wu Y, Shen X, Liu Q, Xiao F, Li C. A garbage detection and classification method based on visual scene understanding in the home environment. *Complexity* 2021;2021(1):1055604.
- [13] Chen Z, Yang J, Chen L, Jiao H. Garbage classification system based on improved ShuffleNet v2. *Resources, Conservation and Recycling* 2022;(178):106090.
- [14] Fan H, Dong Q, Guo N, Xue J, Zhang R, Wang H, Shi M. Raspberry pi-based design of intelligent household classified garbage bin. *Internet of Things* 2023;(24):100987.
- [15] Jin S, Yang Z, Królczyk G, Liu X, Gardoni P, Li Z. Garbage detection and classification using a new deep learning-based machine vision system as a tool for sustainable waste recycling. *Waste Management* 2023;(162):123-130.
- [16] Tensorflow: large-Scale machine learning on heterogeneous distributed systems. <https://arxiv.org/abs/1603.04467> (Erişim tarihi: 10.09.2024).
- [17] Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research* 2014;15(1):1929-1958.
- [18] Chollet F. *Deep learning with Python*, Shelter Island: Manning Publications; 2021.
- [19] LeCun Y, Bengio Y, Hinton G. Deep learning, *Nature* 2015;521(7553):436-444.
- [20] Machine Learning vs. Deep Learning. <https://lawtomed.com/a-i-technical-machine-vs-deep-learning/> (Erişim tarihi: 20.09.2024).
- [21] Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A. Going deeper with convolutions. In: *Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition*, Boston, MA, USA; 2015.
- [22] Zhang X, Zhou X, Lin M, Sun J. ShuffleNet: An extremely efficient convolutional neural network for mobile devices. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, Utah, ABD; 2018.
- [23] Güneş E. Derin öğrenme yaklaşımı ile fındık meyvesinin sınıflandırılması. Yüksek Lisans Tezi. İstanbul: Marmara Üniversitesi; 2022.
- [24] Dandıl E, Karaca S. MR spektroskopisi sinyalleri kullanılarak LSTM derin sinir ağları ile beyinde sahte tümörlerin tespiti. *Avrupa Bilim ve Teknoloji Dergisi* 2020;2:426-433.
- [25] Garbage Classification. <https://www.kaggle.com/datasets/asdasdasdas/garbage-classification> (Erişim tarihi: 01.08.2024).