



e-ISSN: 2667-7814

$$m = \frac{f(x_2) - f(x_1)}{x_2 - x_1}$$



ALANYA
ALAADDİN
KEYKUBAT
ÜNİVERSİTESİ




0101001
1111101
0101010
0101001
1111101
0101001

ALKÜ
FEN BİLİMLERİ DERGİSİ


Cilt: 6 Sayı: 2 (Mayıs-Ağustos 2024)

ALKU
JOURNAL OF SCIENCE

Volume: 6 Issue: 2 (May-August 2024)



$$\lambda = \frac{h}{p} = \frac{h}{mv} = \frac{h}{\sqrt{2mE_k}}$$



$$E = mc^2$$

DERGİNİN KÜNYESİ / JOURNAL INFO

Derginin Adı / Journal Name: ALKÜ Fen Bilimleri Dergisi / ALKU Journal of Science

Kısa Adı/ Short Name:

e-ISSN: 2667-7814

Doi prefix: 10.46740/alku.

Yayın Dili / Publication Language : Türkçe / English

Yayın Periyodu / Publication Period: Yılda üç kez (Nisan, Ağustos ve Aralık) / Three times a year (April, August, and December)

Sahibi / Owner: Prof. Dr. Kenan Ahmet TÜRKDOĞAN, Alanya Alaaddin Keykubat Üniversitesi Rektörü

Sorumlu Yazı İşleri Müdürü / Publishing Manager: Doç. Dr. Sefa YILDIRIM

Kuruluş / Establishment: ALKÜ Fen Bilimleri Dergisi, Alanya Alaaddin Keykubat Üniversitesi Rafet Kayış Mühendislik Fakültesi tarafından tüm mühendislik bilimleri ve temel bilimler alanında yılda 3 kez yayınlanan hakemli bir dergidir. Dergimizde, Türkçe ve İngilizce dillerinde orijinal araştırma çalışmaları ve derlemeler yayımlanmaktadır. Bu dergi, hakemli ve açık erişimli bir uluslararası mühendislik bilimleri ve temel bilimler dergisidir. Değerlendirme ve yayınlanma süreçlerinde yazarlardan ücret talep edilmez.

ALKU Journal of Science is an international, peer-reviewed journal which is published by Rafet Kayış Engineering Faculty of Alanya Alaaddin Keykubat University in all areas of engineering and basic science. ALKU Journal of Science is a triannually published open access journal operating an online submission and peer review system which allows authors to submit articles online and track their progress. No charges are required from the authors in all of the publication steps.

Dizinler ve Platformlar / Indexing and Platforms: Google Scholar, Cosmos Impact Factor, ResearchBip, Bielefeld Academic Search Engine (BASE), Asos Index, International Innovative Journal Impact Factor(IIJIF), Scientific Indexing Services(SIS)

Web Adresi/ Web address : <https://dergipark.org.tr/tr/pub/alku>

Yayınlayan Kuruluş / Publisher : Alanya Alaaddin Keykubat Üniversitesi / Alanya Alaaddin Keykubat University

Makale gönderim ve takip sistemi / Article submission and tracking system: ULAKBİM Dergi Sistemleri, <https://dergipark.org.tr/tr/pub/alku>

Web barındırma ve teknik destek / Web hosting and technical support: Dergipark Akademik <http://dergipark.gov.tr/>

İletişim / Contact: Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Alanya, Antalya. E-mail: alkufbd@alanya.edu.tr Tel/Phone: 0242 5106060 (2545)

EDİTÖR / EDITOR

Doç. Dr. Sefa YILDIRIM, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Makine Mühendisliği Bölümü. Alanya, Antalya

YARDIMCI EDİTÖR / ASSOCIATE EDITOR

Dr. Öğr. Üyesi Gökhan Canbolat, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Makine Mühendisliği Bölümü. Alanya, Antalya

ALAN EDİTÖRLERİ / SUBJECT EDITORS

Prof. Dr. Derman Vatansever Bayramol, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Metalurji ve Malzeme Mühendisliği. Alanya, Antalya
Subject: Metallurgical and Materials Engineering
Alan: Metalurji ve Malzeme Mühendisliği

Doç. Dr. Tuğba Aktar Küçükarslan, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Gıda Mühendisliği Bölümü. Alanya, Antalya
Subject: Food Engineering
Alan: Gıda Mühendisliği

Doç. Dr. Bertan Beylergil, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Makine Mühendisliği Bölümü. Alanya, Antalya
Subject: Mechanical Engineering
Alan: Makine Mühendisliği

Doç. Dr. İbrahim Tekin, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Temel Bilimler Bölümü. Alanya, Antalya
Subject: Mathematics
Alan: Matematik

Doç. Dr. Burak Saltuk, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Biyosistem Mühendisliği. Alanya, Antalya
Subject: Biosystems Engineering
Alan: Biyosistem Mühendisliği

Doç. Dr. Alper Kürşat Uysal, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü. Alanya, Antalya
Subject: Computer Engineering
Alan: Bilgisayar Mühendisliği

Doç. Dr. Üyesi Aslı Giray, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Genetik ve Biyomühendislik Bölümü. Alanya, Antalya
Subject: Genetic Engineering
Alan: Genetik Mühendisliği

Doç. Dr. Üyesi Emrah Irmak, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü. Alanya, Antalya
Subject: Electrical-Electrical Engineering
Alan: Elektrik-Elektronik Mühendisliği

Doç. Dr. Murat Aksel, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü Alanya, Antalya
Subject: Civil Engineering
Alan: İnşaat Mühendisliği

Dr. Öğr. Üyesi Fatma Aydın Ünal, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü. Alanya, Antalya
Subject: Metallurgical and Materials Engineering
Alan: Metalurji ve Malzeme Mühendisliği

Dr. Öğr. Üyesi Atıl Kurt, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Endüstri Mühendisliği. Alanya, Antalya
Subject: Industrial Engineering
Alan: Endüstri Mühendisliği

Dr. Öğr. Üyesi Özgür Öztürk, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Genetik ve Biyomühendislik Bölümü. Alanya, Antalya
Subject: Genetics and Bioengineering
Alan: Genetik ve Biyomühendislik

YAYIN, DİL ve TEKNİK EDITÖRLERİ / PUBLISHING, LANGUAGE AND TECHNICAL EDITORS

Arş. Gör. Mustafa Altuğ Peker, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü. Alanya, Antalya

Arş. Gör. Hüseyin Şenli, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü. Alanya, Antalya

Arş. Gör. Dilara Zeynep Yüzen, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Endüstri Mühendisliği. Alanya, Antalya

Arş. Gör. Enis Körpe, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü. Alanya, Antalya

Arş. Gör. Gürkan Çelik, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü. Alanya, Antalya

Arş. Gör. Dr. Sevda Altun, Alanya Alaaddin Keykubat Üniversitesi, Rafet Kayış Mühendislik Fakültesi, Genetik ve Biyomühendislik Bölümü. Alanya, Antalya

YAYIN KURULU / PUBLISHING BOARD

Hüseyin AKILLI (Prof. Dr., Çukurova Üniversitesi)

Gökhan APAYDIN (Prof. Dr., Karadeniz Teknik Üniversitesi)

Naci ÇAĞLAR (Prof. Dr., Sakarya Üniversitesi)

Hakan ÇELEBİ (Doç. Dr., Aksaray Üniversitesi)

Rossana DIMITRI (Dr., University of Salento)

Tamio ENDO (Prof. Dr., Mie University)

John GELEGENIS (Prof. Dr., Technological Educational Institute of Athens)

Viktor GRIBNIAKN (Prof. Dr., Vilnius Gediminas Technical University)

Anastas IVANOV IVANOV (Prof. Dr., Todor Kableshkov Higher School of Transport)

İlker Murat KOÇ (Prof. Dr., Istanbul Teknik Üniversitesi)

Anatoli I POPOV (Prof. Dr., University of Latvia)

Bilsay SÜMER (Doç. Dr., Hacettepe Üniversitesi)

Cevat SARIOĞLU (Prof. Dr., Marmara Üniversitesi)

Francesco TORNABENE (Dr., University of Bologna)

Jamal Seyyed Monfared ZANJANI (Dr., University of Twente)

ALKÜ FEN BİLİMLERİ DERGİSİ 2024:6(2)
ALKU JOURNAL OF SCIENCE 2023:6(2)
İçindekiler / Contents

1. Pisagor Bulanık Küme Ortamında Yenilenebilir Enerji Kaynağı Seçimi / *Renewable Energy Source Selection by Pythagorean Fuzzy Sets*
Yasin Ölç, Fethullah GÖÇER96-115
2. Makine Çizelgeleme Problemlerinin Çözümünde Pekıştirmeli Öğrenme Etkisinin Analizi / *Analysis of Reinforcement Learning Effect in Solving Machine Scheduling Problems*
Orhan Engin, Bünyamin Sarıcan.....116-140
3. MIKE Programı ile Kars Çayının Taşkın Modellemesinin Yapılması / *Flood Modelling of Kars Stream with MIKE Program*
İrem Öztürkci, Mehmet Dikici.....141-154
4. Gıda ve Yem İçin Hızlı Alarm Sistemi (RASFF)'nde Bulunan 2022 Yılı Gıda ve Gıda ile Temas Eden Madde Bildirimleri / *Rapid Alert System for Food and Feed (RASFF) Notifications for Food and Food Contact Materials in 2022*
Rabia Aydoğdu, Merve Turan, Derya Deniz Şirinyıldız, Aslı Yorulmaz.....155-164
5. Adapting Object Detection Models for Multi-Target Detection Utilizing Radars / *Radarla Çoklu Hedef Tespiti için Nesne Tanıma Modellerinin Uyarlanması*
İbrahim Rıza Hallaç, Deniz Akbaba, Gökhan Gökçe, S. Gokhun Tanyer, Peter F. Driessen.....165-173

Pisagor Bulanık Küme Ortamında Yenilenebilir Enerji Kaynağı Seçimi

Yasin ÖLÇ^{1*} , Fethullah GÖÇER² 

¹Bilişim Sistemleri Bölümü, Fen Bilimleri Enstitüsü, Kahramanmaraş Sütçü İmam Üniversitesi, Kahramanmaraş, Türkiye.

²Endüstri Mühendisliği, Mühendislik-Mimarlık Fakültesi, Kahramanmaraş Sütçü İmam Üniversitesi, Kahramanmaraş, Türkiye

*yasinolc@gmail.com

Özet

Yenilenebilir Enerji Kaynağı seçiminde kriter belirleme aşaması, yenilenebilir enerji ile ilgili birçok karar kriterinden etkilenen faktörlere sahiptir. Bir seçim ortamında potansiyel kriterlerin değerlendirilmesi ve önceliklendirilmesi, çok kriterli karar verme problemi olarak ele alınabilir. Bu çalışmanın amacı, yenilenebilir enerji bağlamında kriter seçim süreçlerini teknik, ekonomik, sosyal ve çevresel yönleri ile analiz etmektir. Yazın taraması, çalışma bölgelerini, kısıtlamaları, değerlendirme ölçütlerini ve yenilenebilir enerji seçimi süreci için kullanılan yöntemleri sentezlemek ve kategorize etmek için sistematik bir inceleme yöntemi kullanılarak oluşturulmuştur. Kriter seçimi sürecinde, insan yargılarının öznelliği genellikle çatışmaya yol açar ve bir tür tereddüt yaratır. Önerilen çalışma, değerlendirme verileriyle ilişkili belirsizliği ve muğlaklığı Grup Karar Verme ortamında Pisagor Bulanık Küme kullanarak gidermeye çalışmıştır. Önerilen yöntem, Pisagor Bulanık Kümelerin geleneksel bulanık kümelerle kıyasla daha doğru bilgi sağlama yeteneğinden ve grup karar vermenin karar bilgisinde önyargı ve öznellikten kaçınma kolaylığından yararlanır. Technique for Order of Preference by Similarity to Ideal Solution (TOPSIS) tekniği, grup karar verme kullanılarak Pisagor Bulanık Küme ortamında uygulanmaktadır. Önerilen yaklaşımı doğrulamak için ampirik bir vaka çalışması uygulanmıştır. Son olarak, sentezlenmiş ve kategorize edilmiş bilgi ve araştırma boşluklarından oluşan kapsamlı bir havuz sağlayarak, bu çalışma, karar vericilerin yenilenebilir enerji seçiminde en uygun kriterleri belirlemeleri için bir yol haritası sunmaktadır.

Anahtar Kelimeler: Yenilenebilir Enerji Seçimi, Çok Kriterli Karar Verme, Pisagor Bulanık Kümeleri, Değerlendirme Kriteri, Grup Karar Verme

Renewable Energy Source Selection by Pythagorean Fuzzy Sets

Abstract

The criteria determination in Renewable Energy Source selection has factors that are strongly influenced by many decision criteria regarding renewable energy. Evaluating and prioritizing potential criteria in a selection environment can be addressed as a multi-criteria decision-making problem. This study aims to analyze criterion selection processes in the context of renewable energy with their technical, economic, social, and environmental aspects. The literature review is created using a systematic review method to synthesize and categorize study regions, constraints, evaluation criteria, and methods used for the renewable energy selection process. In the process of criterion selection, the subjectivity of human judgments often leads to conflict and creates a kind of hesitation. To avoid uncertainty and ambiguity associated with evaluation data, the proposed work attempts to eliminate it using Pythagorean Fuzzy Set in a Group Decision Making environment. The proposed method takes advantage of the ability of Pythagorean Fuzzy Sets to provide more accurate information compared to traditional fuzzy sets and ease it with group decision making which avoids bias and subjectivity in decision information. The technique for Order of Preference by Similarity to Ideal Solution (TOPSIS) technique is implemented in the Pythagorean

Fuzzy Set environment using group decision-making. An empirical case study was applied to validate the proposed approach. Finally, by providing a comprehensive repository of synthesized and categorized knowledge and research gaps, this study offers a roadmap for decision-makers to determine the most appropriate criteria for choosing renewable energy.

Keywords: Renewable Energy Selection, Multi-Criteria Decision Making, Pythagorean Fuzzy Sets, Criteria Evaluation, Group Decision Making.

1. GİRİŞ

Dünya nüfusunda meydana gelen hızlı artış ve bu artışla beraber ortaya çıkan enerji ihtiyacı gün geçtikçe artmaktadır. Giderek artan teknoloji kullanımı, araç sayılarındaki artış, sanayi ürünlerinden küçük ev aletlerinin kullanımına kadar her alanda enerji ihtiyacı artmakta ve büyük bir ihtimalle enerji ihtiyacı daha da artacaktır. Teknolojinin yaygın kullanımıyla paralel olarak artan enerji ihtiyacının da toplumdaki refah artışı ile de doğru orantılı olarak arttığı söylenebilir [1]. Başlangıçta enerji ihtiyacının karşılanmasında üretim-tüketim odaklı bir anlayışa sahip olan ülkeler, yenilemez enerji kaynaklarının bir gün tükeneceği gerçeğinden hareketle enerjinin sadece üretim tüketim kapsamında değil, ekonomik, sosyal ve çevresel unsurlar kapsamında değerlendirilmesini zorunlu kılmıştır. Hükümetlerin politikaları, çağdaş uygarlık ilkeleri, sanayileşme ve yaşam tarzı da enerjiden yararlanmanın kullanımını etkileyen önemli faktörlerdir. Yenilemez enerji kaynaklarının tarihsel süreç içerisinde hızla tükenmesi, artan tüketim ve siyasal krizlerden etkilenerek petrol ve doğalgaz gibi fosil yakıtların fiyatlarının gün geçtikçe artması da yenilenebilir enerji kaynaklarına yönelimi arttırmıştır. Fosil yakıtların kullanımının hem sürdürülebilir olmaması hem de çeşitli çevresel sorunlara (küresel ısınma, hava kirliliği, su kirliliği, vb.) sebep olması da hükümetlerin yenilenebilir enerji kaynaklarına yönelmesini sağlamıştır [2].

Birçok ülkenin temel politikası haline gelen yenilenebilir enerji kaynakları güneş, hidroelektrik enerjisi, rüzgâr, biokütle enerjisi, jeotermal, dalga ve hidrojen enerji kaynakları, vb. olarak sıralanabilir. Birçok yenilenebilir enerji kaynağı bulunmasına rağmen ülkeler bu enerjilerin seçiminde ekonomik kriterlerin yanı sıra coğrafik, sosyo-politik, çevresel ve teknolojik birçok kriteri göz önüne almak zorundadırlar. Herhangi bir yenilenebilir enerji kaynağının kurulması ve kullanılması, büyük ekonomik yatırımları ve vasıflı bir işgücünü içeren önemli bir durumdur. Bu sebepten dolayı yenilenebilir enerji yatırımlarının kazançlı ve büyük oranda verim alınabilecek bir zemine oturtulması elzemdir [3]. Bunun için yenilenebilir enerji seçimi için kriter belirleme işlemi çok önemlidir. Dünya üzerinde kullanımı yaygınlaşmakta olan bazı yenilenebilir enerji kaynaklarını şöyle sıralayabiliriz:

1. Güneş Enerjisi: Hâlihazırda kullanılacak en geniş enerji kaynağıdır. Bu enerji kaynağı güneşten doğrudan ya da dolaylı olarak elde edilir. Güneş enerjisinden elektrik üretimi, güneş panellerinden ve ısı dönüşüm aşamaları şeklinde dünya genelinde yaygın bir kullanıma sahiptir [4]. Güneş panelleri vasıtasıyla elde edilen enerji, elektrik ve sıcak su üretimi ile ısınma ihtiyaçlarını karşılamak için kullanılmaktadır [4].
2. Rüzgâr Enerjisi: Rüzgârın hareketi nedeniyle ihtiva ettiği kinetik enerjinin ilk olarak mekanik enerjiye, daha sonra da elektrik enerjisine dönüştürüldüğü sisteme rüzgâr türbini denir [5]. Son yıllarda rüzgârdan elektrik üretimi ciddi oranlarda artış göstermiştir ve bunun sonucu olarak dünya genelinde rüzgâr en önemli ikinci yenilenebilir enerji kaynağıdır denilebilir [6].
3. Biokütle Enerjisi: Biyolojik atıkların çeşitli şekillerde kullanılmasıyla elde edilen enerji çeşididir. Biokütle enerji kaynakları sınırsızdır ve istenilen her bölgede üretilebilir [4]. Biyokimyasal dönüşüm ve termo-kimyasal dönüşüm süreci olarak iki bölümde incelenir [7].
4. Jeotermal Enerji: Yerin altında bulunan radyoaktif elementler biçimindeki enerjidir [3]. Jeotermal enerji kaynakları her yerde bulunmayan özel kaynaklardır. Kesintisiz bir kaynak olup hava koşullarından etkilenmemektedir [8].
5. Hidroelektrik Enerji: Suyun yüksek bir mevkiden aşağı doğru düşerken sahip olduğu kinetik enerjinin elektrik enerjisine dönüştürülmesi hidroelektrik enerji üretiminin temel prensibidir [3].

Elektrik enerjisinin üretimi için temin edilebilecek en temel yenilenebilir enerji kaynağı olarak bilinir [9].

6. Okyanus Enerjisi: Okyanusların derin ve derin olmayan suları arasındaki sıcaklık farkından veya gelgit, dalga, ana okyanus enerji sistemleri ve okyanusun akış enerji sistemlerinden elde edilmektedir. Bunlar gibi deniz ve okyanuslardan enerji elde etmek için birçok yöntem kullanılmaktadır [5]. Okyanuslardaki gelgit enerjisi genellikle enerji üretimi için geliştirilmesi mümkün olan bir kaynak olarak kabul edilir [3].
7. Hidrojen Enerjisi: Evrende en fazla bulunan element olan hidrojen, hafif olduğu için yükselir ve atmosfere gider [5]. Çeşitli formlara dönüştürülebilen hidrojenin moleküllerine ayrışmasıyla açığa çıkan kimyasal enerjiye hidrojen enerjisi denir. Farklı yöntemlerle elektrik ve ısı enerjisine dönüştürülebilir.

Çok Kriterli Karar Verme (ÇKKV), seçim sürecinde birden fazla kriteri dikkate alarak en iyi alternatifi belirlemeyi amaçlayan temel karar verme problemlerinden biridir. ÇKKV, finanstan mühendislik tasarımına kadar farklı alanlarda uygulanabilecek çok çeşitli araç ve yöntemlere sahiptir [10]. Analitik Hiyerarşi Süreci (AHP), Analitik Ağ Süreci (ANP), Oran analizine ve tam çarpımsal forma dayalı çok amaçlı optimizasyon (MILTIMOORA), Çok Kriterli Optimizasyon ve Uzlaşma Çözümü (VIKOR) ve İdeal Çözüme Benzerliğe Göre Tercih Sıralaması Tekniği (TOPSIS) gibi birçok ÇKKV tekniği bulunmaktadır. Bu tekniklerden TOPSIS metodu, karar verme durumlarında pozitif ve negatif ideal çözümlerin sonucuna göre alternatif seçilmesine karar vermeye dayanır [11]. TOPSIS yöntemi, çok sayıda karar vericinin birden fazla ölçüte göre belirsizlik durumlarında alternatifleri değerlendirerek bu alternatifleri sıralamasına dolayısıyla da seçim yapmaya yönelik kararını isabetli vermesine yardımcı olmaktadır [12]. Birden fazla değerlendirme planının mevcut olduğu durumlarda karar verme, bilim insanları ve karar analistlerinin önemli bir endişesi haline gelmiştir. Ancak bu alanda literatürde önerilen çok sayıda model ve yöntemde, kriterlerin yanı sıra çözüm yolunun da net bir şekilde tanımlanabileceği varsayılmaktadır. Kriterlerden birinin veya çözüm uzayının veya her ikisinin de bulanık olması durumunda bu problemlerin net (Crisp) sayılarla nasıl çözülebileceği açık değildir. Net küme iki değerli (0, 1) mantığı kullanır. Buna karşılık bulanık küme sonsuz değerli mantığı kullanır. Net kümeler ikili üyeliklere sahip elemanlara sahipken, bulanık kümeler üyelik derecesine sahip bileşenlere sahiptir. Bulanık küme, kümede değişen üyelik derecelerine sahip bileşenlerin bir koleksiyonudur. "Bulanık" terimi belirsizlikle ilgilidir; yani farklı üyelik dereceleri arasındaki geçiş, bulanık kümelerin sınırlarının belirsiz olduğu anlamına gelir. Sonuç olarak, evrenin öğelerinin kümedeki üyeliği, belirsizlik ve muğlaklığı tespit etmeye yönelik bir fonksiyonla karşılaştırılır. Geçmişte, formal akıl yürütmeye ve bilgisayarlarda çözümleri "doğru" veya "yanlış" ve "evet" veya "hayır" gibi iki biçimde temsil etmek için ikili mantık tabanlı kesin kümeler kullanılıyordu. Bu konuda ortaya çıkan problemleri gidermek için, bulanık küme teorisi ilk olarak 1965 yılında bilgisayar bilimcisi Lotfi A. Zadeh tarafından önerildi [13]. Bundan sonra bu konuda çeşitli teorik gelişmeler meydana geldi. Zadeh, her bir elemanın kümeye üyelik derecesi [0,1] olarak tanımlanan bazı elemanları ve üyelik derecesinin 1'e tamamlayıcısı ile temsil edilen elemanların üye olmayışını içeren tekil sıradan bulanık kümeleri temsil etti.

Sıradan bulanık kümelerin bu tamamlayıcı özelliği, çeşitli araştırmacılar tarafından, bir elemanın üyelik derecesinin de bulanık olması gerekliliği ve sıradan bulanık kümelerin tamamlayıcı özelliği için fazlalık olması gerektiği temelinde eleştirilmiştir. Bu iki eleştiriye dayanarak, sıradan bulanık kümeler birçok araştırmacı tarafından üyelik fonksiyonlarını daha ayrıntılı olarak tanımlamak için başarıyla genişletildi. Yager, tarafından önerilen Pisagor bulanık küme, sezgisel bulanık küme üzerinden geliştirilmiş ve uygulanmış bulanık kümenin genişletilmiş nesnel ortamlarından biridir [14]. Pisagor bulanık kümeler, sezgisel bulanık kümelerin belirsizliği tam anlamıyla gideremeyeceği hallerde kullanılabilmesi sebebi ile belirsizlik ihtiva eden problemleri çözmek için diğer bulanık küme ortamlarından daha esnek, daha güçlü ve daha kullanışlıdır [15]. Pisagor bulanık kümeler, sezgisel bulanık kümeler gibi üyelik derecesi ve üye olmama derecesi ile niteliği ortaya konulur ve üyelik derecesi ile üye olmama derecesinin karelerinin toplamının bir veya birden küçük olma şartına dayanır [16].

Grup karar verme (GKV), daha fazla sayıda bireyin deneyimlerinden ve bakış açılarından faydalanma avantajına sahiptir. Bir grup tarafından tek başına çalışan bir kişiden daha fazla fikir üretilebilir. Dolayısıyla bir grup daha yaratıcı olma ve daha etkili kararlar alma potansiyeline sahip olabilir. Aslında gruplar bazen bireysel olarak yapabileceklerinin ötesinde sonuçlar elde edebilirler. Bu yüzden ÇKKV yöntemleri kullanılarak çözümlenecek olan bu çalışmada Grup Karar Verme ortamında Pisagor Bulanık Kümeleri uygulanarak yenilenebilir enerji seçiminde en uygun kriterleri belirlemek amaçlanmıştır.

Yenilenebilir enerji kaynağı seçiminde birden fazla alternatifi, birden fazla ölçütü değerlendirme çalışması yapılacaktır. Bu alternatiflerinin değerlendirilmesinde sadece maliyet ya da sadece çevreye olan etki kriterleri göz önüne alınırsa sürdürülebilir enerji temini zorlaşabilir. Bu nedenle yenilenebilir enerji seçimi için olası bütün kriterler değerlendirilmelidir. Literatürde yenilenebilir enerji konusunda ÇKKV yöntemleriyle değerlendirilmiş birçok çalışma bulunmaktadır. Bu çalışmalardan faydalanılarak ve uzman görüşleri kullanılarak, karar vericilere yenilenebilir enerji seçiminde en uygun kriterleri belirlemeleri için bir yol haritası sunulacaktır.

Makalenin geri kalanı şu şekilde organize edilmiştir: Yenilenebilir Enerji seçimine yönelik kriterlerin araştırılması ve yazın taraması Bölüm 2'de sunulmaktadır. Bölüm 3'te ise uygulanacak yöntem için kullanılan çerçeve, bu çerçevede oluşturulmuş yöntem konsolide edilmiştir. Bölüm 4'te sayısal sonuçlar sunulmakta ve tartışılmaktadır. Bölüm 5, yönetsel çıkarımların sunulduğu ve tartışıldığı bir alan sağlamıştır. Son olarak, makale 6. bölümde sonlandırılmakta ve geleceğe yönelik çalışma alanları hakkında bilgiler sunulmaktadır.

2. LİTERATÜR TARAMASI

Literatürde yenilenebilir enerji konusunda ÇKKV yöntemiyle değerlendirilmiş birçok çalışma bulunmaktadır. Tablo 1 literatürde bulunan çalışmaların, grup karar verme ortamında yenilenebilir enerji kriterleri açısından değerlendirildiği ve kullanılan ÇKKV yöntemlerinin gösterildiği bir çerçeve sunmaktadır. Yaygın olarak belirsizlik altındaki ÇKKV problemlerini çözmek için kullanılan Pisagor Bulanık TOPSIS yöntemi, klasik TOPSIS yaklaşımının Pisagor Bulanık kümelerine genişletilmiş bir versiyonudur [17]. Pisagor Bulanık küme teoremi, bir elemanın üyeliğini belirlemede eleman ile kümenin merkezi arasındaki mesafeyi kullanır [18, 19]. Pisagor Bulanık TOPSIS, Pisagor bulanık kümelerin bu özelliğini dikkate alarak pozitif ideal çözüme en kısa mesafeye ve negatif ideal çözüme en uzak mesafeye sahip çözümün seçilmesine dayanan bir ÇKKV tekniğidir [20]. Bu alanda yapılan çalışmalar arasında, Pisagor Bulanık TOPSIS yaklaşımının algoritmik yapısını inceleyen Yücesan ve Gül [21] 5 adımdan oluşan bir Pisagor Bulanık TOPSIS algoritmasını sunmuştur. Birçok araştırmacı TOPSIS yöntemini karar verme amacıyla kullanmış ve Pisagor Bulanık ortamda genişletmiş birçok farklı versiyonu bulunmaktadır [22-24]. Önerilen yöntem literatürde bulunan diğer Pisagor Bulanık TOPSIS yöntemlerinden farklıdır. Öncelikle, bu çalışmada GKV ortamında Pisagor Bulanık Kümeleri uygulanarak yenilenebilir enerji kaynağı seçimi gerçekleştirilmiştir. Mevcut yazında “Grup Karar Verme ile Pisagor Bulanık TOPSIS [20]” veya “Yenilenebilir Enerji ile Pisagor Bulanık [9]” çalışmaları olsa da “Grup Karar Verme, Pisagor Bulanık Küme, TOPSIS ve Yenilenebilir Enerji Seçimini” bütünüyle entegre eden çalışma yoktur. Bu yönüyle, bu çalışma yazına katkı sağlamaktadır. Ayrıca, bu çalışma GKV için kullanılan Pisagor bulanık ağırlıklı ortalama (PFWA) toplama yöntemini önerilen metodolojiye özgün bir şekilde adapte etmektedir. Bu nedenle çalışmamız PFWA operatörünün gerçek bir probleme güvenilir bir uygulamasını sunmaktadır. Literatürde pek çok uygulaması bulunması nedeniyle geliştirilen ÇKKV çerçevesini daha güvenilir ve tutarlı hale getirmek için TOPSIS yöntemi Pisagor aritmetik operatörleri kullanılarak sunulmuştur.

Tablo 1. Yenilenebilir enerji kriterleri ve kullanılan yöntemler

Yazar	Yılı	Kriterler	Yöntemler
[25]	2011	Teknoloji kullanımı, çevre uyumu, sosyo-politik durum, ekonomik potansiyel.	Graf Teorisi, Matris Yaklaşımı
[26]	2011	Politik, güvenlik, insani yardım, fayda, maliyet, risk	AHP, BOCR
[27]	2012	Ulusal enerji politikası hedefleriyle uyumluluk, projenin siyasi kabulü, sosyal kabul, istihdam olanağı, yatırım maliyeti, işletme ve bakım maliyeti, birincil enerji maliyeti, kirletici emisyon, arazi gereksinimi, ekosistem üzerindeki etkisi, hazırlık ve uygulama aşaması süresi, süreklilik ve performansın öngörülebilirliği, teknik fizibilite.	Bulanık AHP, Bulanık TOPSIS
[28]	2013	Yerel ekonomiye katkı, istihdamın artması, potansiyel ticaret yapabilme, pazarın genişliği, yatırım maliyetlerinin makul seviyede olması, İthalat riskleri, karbon emisyon oranının azaltılması, azot ve kükürt salınımının azaltılması, alan gereksiniminin azlığı, ekolojik planlamalara uygunluk, enerji fiyat istikrarı, enerji arz güvenliği, enerji üretiminde istikrar, dışa bağımlılığın azaltılması, enerji verimliliğini sağlama, etkin politika uygulama, yenilikçi ve destekleyici olma	AHP
[29]	2013	Fizibilite etüdü, risk analizi, güvenilirlik analizi, hazırlık süresi, uygulama süresi, sürekli ve performanslı olmanın öngörülebilirliği, yerli teknolojiyi destekleme, kirletici salınımları azaltma, arazi gereksinimi, atık bertaraf ihtiyacı, milli enerji politikalarıyla ile uyumlu olma, siyasi olarak kabul edilme, sosyal çevrenin kabulü, işgücünün yatırıma etkisi, uygulama maliyeti, fon kaynakları ve devlet teşviki, ekonomik değer	MACBETH ve Bulanık AHP
[30]	2013	Güç, işletme ve bakım maliyeti, yatırım oranı, uygulama süresi, işlem süresi, kullanım ömrü, CO2 emisyon oranı	AHP, COPRAS
[31]	2014	Enerji kaynağının kaliteli olması (sürdürülebilir olması sağlam ve dayanıklı, kullanıcıya yakın olması), devlet politikası, işgücünün tesiri, sosyal çevrenin kabulü, uygulama maliyeti, ekonomik olarak kıymeti, ekonomik olması, performansın sürekli ve tahmin edilebilir olması, risk, yerel teknik bilgi, kirletici salınım, arazi ihtiyacı, atık bertaraf için gereklilik	Bulanık AHP
[32]	2014	Verim, fizibilite, güvenlik, risk, yatırım maliyeti, işletme ve bakım maliyeti, yatırım getirisi, dışa bağımlılık, siyasi ve yasal durumla uygunluk, ulusal enerji politikası ile uyumluluk, sosyal fayda, sosyal kabul, iş olanakları, sera emisyonu, arazi kullanım gereksinimi, ekosisteme etkisi	AHP ve Bulanık TOPSIS
[33]	2014	Ortalama elektrik maliyeti, talebe cevap verebilme yeteneği, verim, kapasite faktörü, arazi kullanımı, dış masraflar (çevre), iş yaratımı, sosyal kabul edilebilirlik, harici tedarik riski	SWING
[34]	2014	Üretilen güç miktarı, teknolojinin yetkinliği, enerji arzının güvenilirliği, sera gazı emisyonu, kolaylık etkisi, alan gereksinimi, ortalama elektrik maliyeti, ekonomiye katkı, sosyal kabul	Monte Carlo Simülasyonu, PROMETHEE
[35]	2015	Verimlilik, enerji verimliliği, birincil enerji oranı, güvenlik, güvenilirlik, olgunluk, yatırım maliyeti, işletme ve bakım maliyeti, yakıt maliyeti, elektrik maliyeti, net şimdiki değer, ödeme süresi, hizmet ömrü, eşdeğer yıllık maliyet, Azot emisyonu, karbondioksit emisyonu, karbon emisyonu, kükürt emisyonu, parçacık emisyonları, metan olmayan uçucu organik bileşikler, arazi kullanımı, sosyal kabul, iş olanakları, sosyal fayda	Bulanık TOPSIS
[36]	2016	Sürdürülebilirlik ve erişilebilirlik, verimlilik, kullanım alanlarının çeşitliliği, saklanabilirlik, iletim verimliliği, ilk yatırım maliyeti, tesisin sadeliği, teknolojinin gereksinimi, bakım gereksinimi, kaza riski ve etkileri, doğaya ve insanlara olan zarar düzeyi.	Bulanık ANP, Bulanık DEMATEL, Bulanık VIKOR

[37]	2016	Maliyet, çevresel etki, risk ve iklim değişimi üzerine etki, güvenilirlik, rezerv miktarı, üretim kapasitesi, sürdürülebilirliğe olan katkı, hükümet politikalarınca desteklenme, ülke ekonomisi açısından sahip olunan önem, basitlik ve kamu kabulü	Bulanık TOPSIS
[38]	2016	Verim, enerji verimliliği, yatırım maliyetleri, işletme ve bakım maliyetleri, Azot emisyonu, karbondioksit emisyonu, arazi kullanımı, sosyal kabul, istihdam olanağı,	Bulanık AHP
[39]	2016	Verim, sermaye maliyeti, işletme ve bakım maliyeti, iş oluşturma, arazi gereksinimi, emniyet, enerji maliyeti, kaynak kullanılabilirliği, olgunluk, emisyon üzerindeki etkisi, yerinden uzman girişleri, önem pozisyonu, ulusal ekonomik gelişme, sosyal ve politik kabul	AHP
[40]	2017	Ekonomik, teknolojik, sosyal, politika, çevresel	Bulanık ANP, Bulanık DEMATEL, Bulanık TOPSIS
[41]	2017	Verimlilik, santral inşa süresi, maliyet, devlet teşviki, ekonomik ömür, dışa bağımlılık, istihdam olanakları, sosyal kabul, alan gereksinimi, çevresel etki, topografik gereksinimler, sera gazı salınımı.	ANP, TOPSIS
[42]	2020	Maliyet, Elde edilebilirlik miktarı, gürültü, arazi ihtiyacı, iş imkânı güvenilirlik, sera emisyonları, teknolojik olgunluk, ekolojik etki, hizmet ömrü, verimlilik, su tüketimi, teslim süresi, devlet teşvikleri	SWARA-TOPSIS
[43]	2021	Yatırım maliyeti, işletme maliyeti, istihdam işletme ömrü, enerji verimliliği ekonomik potansiyel, alan gereksinimi, elektrik üretim maliyeti, çevresel etkiler ve sera gazı salınımı	Best Worst Method (BWM)
[44]	2021	İnsan kaynakları, çekici araştırma sistemleri, inovasyon dostu ortam, finansman, destek ve firma yatırımları, araştırma sistemleri, istihdam etkileri	MULTIMOORA
[45]	2021	Öğrenme ve büyüme, müşteri, iç süreçler, finans durumları	DEMATEL
[46]	2022	Yatırım maliyeti, işçilik maliyeti, ARGE maliyeti, üretim maliyeti, gürültü etkisi, sera gazı etkisi, atık bertarafı, şehir merkezine mesafe, ekonomik riskler	DEMATEL
[47]	2022	Potansiyel toplam güç üretimi, CO ₂ ve CH ₄ emisyonu, alan gereksinimi, seviyelendirilmiş enerji maliyeti, potansiyel istihdam oluşturma	AHP, Fuzzy Shannon Entropy, ve Weighted Sum Model
[48]	2022	Verimlilik, güç çıkışı, kapasite, kullanılabilirlik, ürün maliyeti, bakım ve işletme maliyeti, CO ₂ emisyonu, toprak ve su kullanımı	WSM, AHP, WPM, ELECTRE
[49]	2023	Rüzgâr enerjisinin etkileri, rüzgâr enerjisinin öngörülebilirliği, kurulum ve elektrik ağ maliyeti, risk değerlendirmesi, coğrafi konum	DEMATEL
[50]	2023	Çok haneli konutlar, beş kat, 1945-1995 yılları arasında inşa edilenler, bağımsızlık, teknolojik gereksinim	TOPSIS
[51]	2023	Enerji geçişi, karbon salınımı, hızlı arz, ekonomik canlanma, istihdam oluşturma, ulusal ve uluslararası stratejiler	FF-CRITIC-VIKOR
[10]	2023	İstihdam oluşturma, yasal teşvikler, sosyal kabul, yerel kalkınma, kazsa durumları, yatırım maliyeti, üretim maliyeti, yatırım getiri oranı, bakım maliyeti, Pazar payı, verimlilik, güvenilirlik, sürdürülebilirlik, güvenli olma, yenilikçilik	IVFF-ARAS
[52]	2024	Çevresel kısıtlamalar, dalga gücü yoğunluğu, su derinliği, kıyıdan uzaklık	GKV-AHP, TOPSIS ve PSO-ANN

3. MALZEME VE YÖNTEM

3.1 Ön Hazırlıklar

Pisagor bulanık setlerinin ana kavramları kısaca tanıtılmış ve bunların aritmetik işlemleri sunulmuştur. Yager [14] sonlu sabit bir x kümesi sunar ve Denklemden Pisagor bulanık kümesi \tilde{P} 'yi Denklem (1)'de tanımlamıştır.

$$\tilde{P} = \{x, \tilde{P}(\mu_{\tilde{P}}(x), v_{\tilde{P}}(x)) \mid x \in X\} \quad (1)$$

Burada $\mu_{\tilde{P}}(x)$ ve $v_{\tilde{P}}(x)$ sırasıyla üyelik ve üyeliksizlik dereceleridir ($\mu_{\tilde{P}}(x), v_{\tilde{P}}(x) \in [0,1]$) ve $0 \leq (\mu_{\tilde{P}}(x))^2 + (v_{\tilde{P}}(x))^2 \leq 1, \forall x \in X$ için Tereddüt derecesi Denklem (2) de şu şekilde tanımlanır:

$$\pi_{\tilde{P}}(x) = \sqrt{1 - (\mu_{\tilde{P}}(x))^2 - (v_{\tilde{P}}(x))^2}, \quad (2)$$

$p_1 = (\mu_{P_1}(x), v_{P_1}(x))$ ve $p_2 = (\mu_{P_2}(x), v_{P_2}(x))$ iki PFS numarası olsun ve $\lambda > 0$.

Temel PFS işlemleri Denklem (3) ile Denklem (11) arasında sunulmaktadır [45, 46]:

$$p_1 \oplus p_2 = \left(\sqrt{(\mu_{P_1}(x))^2 + (\mu_{P_2}(x))^2 - (\mu_{P_1}(x))^2 \cdot (\mu_{P_2}(x))^2}, v_{P_1}(x) \cdot v_{P_2}(x) \right), \quad (3)$$

$$p_1 \otimes p_2 = \left(\mu_{P_1}(x) \cdot \mu_{P_2}(x), \sqrt{(v_{P_1}(x))^2 + (v_{P_2}(x))^2 - (v_{P_1}(x))^2 \cdot (v_{P_2}(x))^2} \right), \quad (4)$$

$$p_1 \ominus p_2 = \left(\sqrt{\frac{(\mu_{P_1}(x))^2 - (\mu_{P_2}(x))^2}{1 - (\mu_{P_2}(x))^2}}, \frac{v_{P_1}(x)}{v_{P_2}(x)} \right), \quad (5)$$

$$\text{if} \left(\mu_{P_1}(x) \geq \mu_{P_2}(x), v_{P_1}(x) \leq \min \left\{ v_{P_2}(x), \frac{v_{P_2}(x) \cdot \pi_{P_1}(x)}{\pi_{P_2}(x)} \right\} \right), \quad (6)$$

$$\frac{p_1}{p_2} = \left(\frac{\mu_{P_1}(x)}{\mu_{P_2}(x)}, \sqrt{\frac{(v_{P_1}(x))^2 - (v_{P_2}(x))^2}{1 - (v_{P_2}(x))^2}} \right), \quad (7)$$

$$\text{if} \left(\mu_{P_1}(x) \leq \min \left\{ \mu_{P_2}(x), \frac{\mu_{P_2}(x) \cdot \pi_{P_1}(x)}{\pi_{P_2}(x)} \right\}, v_{P_1}(x) \geq v_{P_2}(x) \right), \quad (8)$$

$$\lambda p_1 = \left(\sqrt{1 - (1 - (\mu_{P_1}(x))^2)^\lambda}, (v_{P_1}(x))^\lambda \right), \quad (9)$$

$$p_1^\lambda = \left((\mu_{P_1}(x))^\lambda, \sqrt{1 - (1 - (v_{P_1}(x))^2)^\lambda} \right), \quad (10)$$

$$p_1^c = (v_{P_1}(x), \mu_{P_1}(x)), \quad (11)$$

3.2 Önerilen Yöntem

TOPSIS tekniği, 1981 yılında Hwang ve Yoon [11] tarafından sunulan bir ÇKKV yöntemidir. Bu yöntem, en iyi tercih edilen alternatifin, negatif ideal çözümden mümkün olduğunca uzak ve pozitif ideal çözüme mümkün olduğunca yakın olan alternatif olduğu hipotezinden yararlanır. Pozitif ideal çözüm, maliyet kriterlerinin minimumunu ve fayda kriterlerinin maksimumunu dikkate alırken, negatif ideal çözüm, maliyet kriterlerinin maksimumunu ve fayda kriterlerinin minimumunu dikkate alır. Kısaca, pozitif ideal çözüm, çözüm kriterlerinin en iyi değerini dikkate alırken, negatif ideal çözüm, çözüm kriterlerinin en kötü değerini dikkate alır. Bu yöntem, alternatifleri pozitif idealden negatif ideal noktalara olan mesafeleri dikkate alarak sıralar. Önerilen metodoloji adımları aşağıdaki gibi sunulmaktadır:

Adım 1: Karar kriterlerini ve alternatifleri belirleme:

$i = 1, 2, \dots, m$ olan A_i kümesinin alternatiflerinin her biri $j = 1, 2, \dots, n$ olan C_j kümesinin karar kriterleri için değerlendirildi. Kümeleme karar kriterleri için her biri ile küme alternatifleri değerlendirilmiştir.

Tablo 2. Pisagor bulanık kümelerinin dilsel değişkenleri [46]

Dilsel Terimler		μ	ν
Çok Zayıf	ÇZ	[0,15	0,85]
Zayıf	Z	[0,25	0,75]
Orta zayıf	OZ	[0,35	0,65]
Orta	O	[0,50	0,45]
Orta İyi	Oİ	[0,65	0,35]
İyi	İ	[0,75	0,25]
Çok iyi	Çİ	[0,85	0,15]

Adım 2: KV'lerin ağırlıklarını belirleme

$k = 1, 2, \dots, K$, bir KV seti olarak, bireysel ağırlıkları ile λ_k ve $\sum_{k=1}^K \lambda_k = 1$. KV'lerin ağırlıklarını hesaplamak için Denklem (12) kullanılır.

$$\lambda_k = \frac{\left[\mu_{P_k}(x) + \pi_{P_k}(x) \left[\frac{1 - \pi_{P_k}(x)}{\mu_{P_k}(x)} \right] \right]}{\sum_{k=1}^K \left[\mu_{P_k}(x) + \pi_{P_k}(x) \left[\frac{1 - \pi_{P_k}(x)}{\mu_{P_k}(x)} \right] \right]}, \quad (12)$$

Adım 3: Bireysel karar matrisini belirleme

KV'nin dilbilimsel açıdan bireysel seçenekleri, Tablo 2'deki dilsel değişkenler tarafından dönüştürülür ve bireysel karar matrisi $(A_{(k)}_{ij})_{m \times n}$ Denklem (13)'teki gibi oluşturulur.

$$A_{(k)}_{ij} = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{m1} & \dots & a_{mn} \end{bmatrix} \quad (13)$$

Adım 4: Toplu karar matrisini belirleme

Bireysel alternatif değerlendirmeler, PFWA toplama operatörü [14, 16] tarafından GKV matrisinde Denklem (14)'te gösterildiği gibi birleştirilir.

$$PFWA = \left\langle \sqrt{1 - \prod_{k=1}^K \left(1 - \left(\mu_{ij}^{(k)} \right)^2 \right)^{\lambda_k}}, \prod_{k=1}^K \left(\nu_{ij}^{(k)} \right)^{\lambda_k} \right\rangle \quad (14)$$

$$A_{ij} = \begin{bmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{m1} & \cdots & a_{mn} \end{bmatrix} \quad (15)$$

Adım 5: Kriter ağırlıklarını belirleme

\tilde{w}_j kriter ağırlıklarını PFS değeri şeklinde tanımlayalım,

Denklem (16) kriter ağırlıklarını hesaplamak için kullanılır.

$$PFWA_\lambda = (\tilde{w}_j^{(1)}, \tilde{w}_j^{(2)}, \dots, \tilde{w}_j^{(K)})$$

$$PFWA_\lambda = \lambda_1 * \tilde{w}_j^{(1)} \oplus \lambda_2 * \tilde{w}_j^{(2)} \oplus \dots \oplus \lambda_K * \tilde{w}_j^{(K)}$$

$$PFWA_\lambda = \langle \sqrt{1 - \prod_{k=1}^K (1 - (\mu_j^{(k)})^2)^{\lambda_k}}, \prod_{k=1}^K (v_j^{(k)})^{\lambda_k} \rangle$$

$$\tilde{w}_j = \langle (\sqrt{\mu_j^{(k)}} - (v_j^{(k)})^2) / 2 \rangle \quad (16)$$

Adım 6: Ağırlıklandırılmış normalleştirilmiş karar matrisi oluşturma

Matris, maliyet türü kriterleri olması durumunda Denklem (11) kullanılarak normalleştirilir.

Ağırlıklı matrisi bulmak için Denklem (17) kullanılır. Ağırlıklar Adım 5'te verilmiştir.

$$\tilde{R}_{ij} = \tilde{w}_j \otimes \tilde{x}_{ij}, j = 1, 2, 3, \dots, n, i = 1, 2, 3, \dots, m \quad (17)$$

$\tilde{r}_{ij} = (\mu_{\tilde{A}}(x), v_{\tilde{A}}(x))$ olduğu yerde

Adım 7: Pozitif ve negatif ideal çözümü hesaplama

Sırasıyla pozitif (A^+) ve negatif (A^-) ideal çözümleri bulmak için Denklem (18) ve Denklem (19) kullanılır.

$$A^+ = (\tilde{r}_1^+, \tilde{r}_2^+, \dots, \tilde{r}_n^+), \tilde{r}_j^+ = (\mu_j^+, v_j^+, \pi_j^+), \quad (18)$$

$$A^- = (\tilde{r}_1^-, \tilde{r}_2^-, \dots, \tilde{r}_n^-), \tilde{r}_j^- = (\mu_j^-, v_j^-, \pi_j^-), \quad (19)$$

$j = 1, 2, \dots, n$, olduğu yerde

$$\mu_j^+ = \{(\max_i \{\mu_{ij}\} | j \in J_1)\}, \{(\min_i \{\mu_{ij}\} | j \in J_2)\}$$

$$v_j^+ = \{(\min_i \{v_{ij}\} | j \in J_1)\}, \{(\max_i \{v_{ij}\} | j \in J_2)\}$$

$$\mu_j^- = \{(\min_i \{\mu_{ij}\} | j \in J_1)\}, \{(\max_i \{\mu_{ij}\} | j \in J_2)\}$$

$$v_j^- = \{(\max_i \{v_{ij}\} | j \in J_1)\}, \{(\min_i \{v_{ij}\} | j \in J_2)\}$$

J_1 fayda kriteri, J_2 maliyet kriteri olarak kabul edilsin.

Adım 8: Ayırma ölçülerini hesaplama

Negatif ve pozitif ideal çözümlerin ayırma ölçülerini hesaplamak için Denklem (20) ve Denklem (21) kullanılır.

$$S_i^+ = \sqrt{\frac{1}{2n} \sum_{j=1}^n [|\mu_{ij}^2 - \mu_j^{*2}| + |v_{ij}^2 - v_j^{*2}| + |\pi_{ij}^2 - \pi_j^{*2}|]} \quad (20)$$

$$S_i^- = \sqrt{\frac{1}{2n} \sum_{j=1}^n [|\mu_{ij}^2 - \mu_j^{-2}| + |v_{ij}^2 - v_j^{-2}| + |\pi_{ij}^2 - \pi_j^{-2}|]} \quad (21)$$

Adım 9: Yakınlık katsayısını hesaplama

Denklem (22) 'yi kullanarak her alternatif için yakınlık katsayısı hesaplanır.

$$C_i^+ = \frac{S_i^-}{S_i^+ + S_i^-}, i = 1, 2, \dots, m \quad 0 \leq C_i^+ \leq 1 \quad (22)$$

Adım 10. Alternatifleri sıralama.

Yakınlık katsayısının (C_i^+) azalan sırasına göre alternatifler sıralanır.

4. UYGULAMA

Yenilenebilir enerji kaynaklarını belirlemek için literatürde bulunan farklı çalışmalardan elde edilen sonuçlara göre bazı ana kriterler ve alt kriterler belirlenmiştir. Yapılan bu çalışmalara göre; teknik, ekonomik, sosyal ve çevresel kriterler olmak üzere dört ana kriter ve bu kriterlerin alt kriterleri olarak sekiz tane alt kriter belirlenmiş ve Tablo 3'te belirtilmiştir.

Tablo 3. Belirlenen kriterler

Ana kriter ID	Ana Kriter	Alt Kriter ID	Alt Kriter	Açıklamalar
C ₁	Teknik Kriterler	C ₁₁	Kurulum Süresi	Teknolojinin kullanılabilir hale gelme süresidir [1,3,4, 8, 41, 55].
		C ₁₂	Kapasite Faktörü	Toplam üretimin yıllık miktarının, kurulmuş gücün kapasitesine oranıdır [1, 2, 4, 8, 29, 34, 38].
C ₂	Ekonomik Kriterler	C ₂₁	Yatırım Maliyeti	Teçhizat, şebeke bağlantısı, yolların yapımı, teknolojinin kurulması ve tesisat gibi hizmetlerin maliyeti [5, 6, 9, 32, 55].
		C ₂₂	Ekonomik Ömür	Santral kurulum ve işletme maliyetlerinin yüksek olması nedeniyle, yatırımın ekonomik ömrü kârlılığını belirleyen faktör [3, 4, 5, 41, 42, 43, 48].
C ₃	Sosyal Kriterler	C ₃₁	İstihdam Oluşturma	Santrallerin oluşturabileceği istihdamı belirtir [2, 3, 7, 11, 26, 31, 39, 41].
		C ₃₂	Yerel Ekonomiye Katkı	Herhangi bir teknoloji yatırımının özelde bölgeye yapacağı katkı [2, 4, 5, 7, 8, 9, 37, 41].
C ₄	Çevresel Kriterler	C ₄₁	Ekolojik Etki	Tabii hayat bölgelerinin değişimi veya kaybı ile su kaynakları, orman alanları, tarım ve balıkçılık gibi ekosistem hizmetlerinin azalması ya da bitmesi [1, 2, 3, 39, 40, 42, 55].
		C ₄₂	Alan Gereksinimi	Yenilenebilir enerji teknolojileri için ihtiyaç duyulan arazi miktarıdır [7, 8, 9, 11, 27, 28, 29, 30].

Adım 1: Tablo 3’te bahsedilen 4 ana kriter altındaki 8 kriter Kahramanmaraş genelinde kullanılabilir 4 adet yenilenebilir enerji kaynağı alternatifini değerlendirmek için kullanılacaktır. Bu alternatifler rüzgâr, hidroelektrik, güneş enerjisi ve biyoenerji olarak belirlenmiştir. Karar verici olarak alanında uzman iki elektrik mühendisi ve üniversiteden bir akademisyene başvurulmuştur. Üç karar verici (KV)’ye göre 4 alternatif için her bir kritere ait dilsel değişkenler Tablo 4’te gösterilmiştir.

Tablo 4. Her bir kritere göre her alternatife ilişkin karar matrislerinin dilsel değerlendirilmesi

	A_1 (Rüzgâr)			A_2 (Güneş)			A_3 (Hidroelektrik)			A_4 (Biyoenerji)		
	KV_1	KV_2	KV_3	KV_1	KV_2	KV_3	KV_1	KV_2	KV_3	KV_1	KV_2	KV_3
C_{11}	oi	o	oi	çi	i	i	i	i	oi	o	oz	oz
C_{12}	çi	i	oi	çi	çi	i	çi	i	i	i	i	oi
C_{21}	i	oi	oi	çi	çi	çi	i	oi	i	oz	z	Z
C_{22}	oi	i	i	i	çi	i	i	oi	i	oi	oi	o
C_{31}	o	oz	o	oi	oi	o	çi	çi	i	o	oi	o
C_{32}	o	o	oi	i	i	oi	çi	i	çi	o	oi	oz
C_{41}	i	i	çi	çi	i	çi	çi	çi	i	oi	i	oi
C_{42}	çi	i	çi	çi	i	i	oi	o	o	o	oz	z

Adım 2: Karar matrislerinin ağırlıkları Denklem (12) kullanılarak hesaplanmıştır.

İlk KV için değerlendirme alanında Çİ olduğu, üçüncü KV’nin Oİ olduğu ve ikinci KV’nin de İ olduğu değerlendirilmiştir. Bu sözel değerlendirmeler ikinci adımda Tablo 2’yi kullanarak Pisagor bulanık küme değerlerine dönüştürülmüş ve Denklem (12) ile KV’lerin ağırlıklarını hesaplamak için kullanılmıştır. Örneğin, ilk karar vericinin ağırlığını bulmak için, dilsel değişkenlerin sayısal aralıkları kullanılarak yapılan hesaplamayla;

$$\lambda_1 = \frac{0,85 + 0,5 \left[\frac{1-0,50}{0,85} \right]}{\left[0,85 + 0,5 \left[\frac{1-0,5}{0,85} \right] \right] + \left[0,75 + 0,61 \left[\frac{1-0,61}{0,75} \right] \right] + \left[0,65 + 0,67 \left[\frac{1-0,67}{0,65} \right] \right]} = 0,3577 \text{ değeri bulunur.}$$

Tablo 5’te bütün karar matrislerinin ağırlıkları görülmektedir.

Tablo 5. Her bir karar matrisinin ağırlıkları

KV	KV_1	KV_2	KV_3
Dilsel Terim	çi	i	oi
λ_k	0,3577	0,3335	0,3088

Adım 3: KV’lerin her bir alternatifi her kriter için değerlendirdikleri dilsel değerler Tablo 4 te verilmiştir. Bu dilsel değerlendirmelerin Pisagor bulanık değerler, alan kısıtlaması nedeniyle tümüyle gösterilememiştir. Ancak, veriler çalışmanın özünü yansıtacak şekilde ölçeklendirilmiştir. Tablo 6 ilk alternatif için üç KV’nin her bir kriter açısından değerlendirmesini Pisagor bulanık küme değerleri olarak göstermektedir.

Tablo 6. İlk alternatif için bireysel karar matrisi

A_1	KV_1			KV_2			KV_3		
C_{11}	0,650	0,350	0,675	0,500	0,450	0,740	0,650	0,350	0,675
C_{12}	0,850	0,150	0,505	0,750	0,250	0,612	0,650	0,350	0,675
C_{21}	0,750	0,250	0,612	0,650	0,350	0,675	0,650	0,350	0,675
C_{22}	0,650	0,350	0,675	0,750	0,250	0,612	0,750	0,250	0,612
C_{31}	0,500	0,450	0,740	0,350	0,650	0,675	0,650	0,350	0,675
C_{32}	0,500	0,450	0,740	0,500	0,450	0,740	0,650	0,350	0,675
C_{41}	0,750	0,250	0,612	0,750	0,250	0,612	0,850	0,150	0,505
C_{42}	0,850	0,150	0,505	0,750	0,250	0,612	0,850	0,150	0,505

Adım 4: Bireysel alternatif değerlendirmeler, PFWA toplama operatörü tarafından GKV matrisine Denklem (14) kullanılarak dönüştürülür.

Elde edilen sonuçlar Tablo 7’de gösterilmiştir. Örnek olarak kurulum süresi kriterine (C_{11}) ait toplu karar matrislerini elde etmek için;

$$\mu_1 = \sqrt{1 - ((1 - 0,65^2)^{0,3577} * (1 - 0,50^2)^{0,3335} * (1 - 0,65^2)^{0,3088})} = 0,608$$

$$v_1 = 0,35^{0,3577} * 0,45^{0,3335} * 0,35^{0,3088} = 0,381$$

Tablo 7. Toplu karar matrisi

A_i	A_1		A_2		A_3		A_4	
	μ	v	μ	v	μ	v	μ	v
C_{11}	0,608	0,381	0,793	0,208	0,723	0,277	0,413	0,570
C_{12}	0,771	0,231	0,825	0,176	0,793	0,208	0,723	0,277
C_{21}	0,691	0,310	0,850	0,150	0,721	0,280	0,291	0,713
C_{22}	0,719	0,282	0,790	0,211	0,721	0,280	0,612	0,378
C_{31}	0,521	0,471	0,612	0,378	0,825	0,176	0,559	0,414
C_{32}	0,555	0,416	0,723	0,277	0,823	0,178	0,528	0,464
C_{41}	0,787	0,214	0,823	0,178	0,825	0,176	0,688	0,313
C_{42}	0,823	0,178	0,793	0,208	0,612	0,378	0,392	0,596

Adım 5: Kriter ağırlıkları KV’lerin dilsel her bir kriter için dilsel değerlendirmeleri alındıktan sonra Denklem (16) kullanılarak hesaplanır. Tablo 8 bu dilsel değerlendirmeleri, net kriter ağırlıklarını ve kriter sıralamasını sunmaktadır. Tablo 9 kriter Pisagor Bulanık değerleri ve ağırlıklarını sunmaktadır. Örnek olarak C_{11} kriterine ait ağırlığı elde etmek için;

$$\mu_1 = \sqrt{1 - ((1 - 0,650^2)^{0,3577} * (1 - 0,500^2)^{0,3335} * (1 - 0,750^2)^{0,3088})} = 0,649,$$

$$v_1 = 0,350^{0,3577} * 0,450^{0,3335} * 0,250^{0,3088} = 0,343,$$

$$\tilde{w}_1 = \langle (\sqrt{0,649} - (0,343)^2) / 2 \rangle = 0,344$$

Tablo 8. Kriter değerlendirme, net ağırlık ve sıralamaları

C_j	C_{11}	C_{12}	C_{21}	C_{22}	C_{31}	C_{32}	C_{41}	C_{42}
KV_1	oi	çi	çi	o	oi	o	i	oz
KV_2	o	i	çi	oz	o	i	i	z
KV_3	i	oi	çi	o	oi	o	çi	o
w_j	0,344	0,412	0,450	0,209	0,318	0,322	0,421	0,124
Sıra	4	3	1	7	6	5	2	8

Tablo 9. Kriter Pisagor Bulanık değerleri ve ağırlıkları

C_j	KV_1		KV_2		KV_3		PFWA $_{\lambda}$	
C_{11}	0,650	0,350	0,500	0,450	0,750	0,250	0,649	0,343
C_{12}	0,850	0,150	0,750	0,250	0,650	0,350	0,771	0,231
C_{21}	0,850	0,150	0,850	0,150	0,850	0,150	0,850	0,150
C_{22}	0,500	0,450	0,350	0,650	0,500	0,450	0,458	0,509
C_{31}	0,650	0,350	0,500	0,450	0,650	0,350	0,608	0,381
C_{32}	0,500	0,450	0,750	0,250	0,500	0,450	0,611	0,370
C_{41}	0,750	0,250	0,750	0,250	0,850	0,150	0,787	0,214
C_{42}	0,350	0,650	0,250	0,750	0,500	0,450	0,381	0,609

Adım 6: Toplu karar matrisleri belirlendikten sonra kriter ağırlıkları hesaba katılarak ağırlıklandırılmış normalleştirilmiş karar matrisleri oluşturulur. Kriterler C_{11} , C_{21} , C_{41} ve C_{42} maliyet kriterleri, diğerleri fayda kriterleridir. Denklem (17) kullanılarak Tablo 9’da her alternatife ait kriterlerin ağırlıklandırılmış değerleri görülmektedir. Maliyet türü kriterler olması durumunda minimum değer ideal olarak kabul edilmektedir. Örnek olarak C_{11} kriterine ait ağırlıklandırılmış karar değerini bulmak için; $\mu_{11} = \sqrt{1 - ((1 - 0,608^2)^{0,649}} = 0,509, v_{11} = 0,381^{0,343} = 0,718,$

Tablo 10. Ağırlıklandırılmış karar matrisleri

A_i	A_1		A_2		A_3		A_4	
	μ	v	μ	v	μ	v	μ	v
C_{11}	0,509	0,718	0,689	0,584	0,618	0,644	0,338	0,825
C_{12}	0,666	0,605	0,723	0,551	0,689	0,584	0,618	0,644
C_{21}	0,252	0,881	0,121	0,946	0,227	0,894	0,607	0,654
C_{22}	0,614	0,648	0,686	0,586	0,616	0,646	0,616	0,646
C_{31}	0,431	0,772	0,512	0,716	0,723	0,551	0,465	0,739
C_{32}	0,461	0,740	0,618	0,644	0,721	0,553	0,437	0,768
C_{41}	0,683	0,589	0,721	0,553	0,723	0,551	0,584	0,671
C_{42}	0,721	0,553	0,689	0,584	0,512	0,716	0,320	0,837

Tablo 11. Pozitif (A^+) ve negatif (A^-) ideal çözümler

C_j	A^+		A^-	
	μ_j^+	v_j^+	μ_j^-	v_j^-
C_{11}	0,689	0,584	0,338	0,825
C_{12}	0,723	0,551	0,618	0,644
C_{21}	0,121	0,946	0,607	0,654
C_{22}	0,686	0,586	0,614	0,648
C_{31}	0,723	0,551	0,431	0,772
C_{32}	0,721	0,553	0,437	0,768
C_{41}	0,723	0,551	0,584	0,671
C_{42}	0,721	0,553	0,320	0,837

Adım 7: Pozitif (A^+) ve negatif (A^-) ideal çözümleri bulmak için Denklem (18) ve Denklem (19) kullanılmıştır. Belirlenen değerler Tablo 11’de gösterilmiştir. C_{11} , C_{21} , C_{41} ve C_{42} maliyet kriterleri, diğerleri fayda kriterleri olarak hesaplanmıştır.

Adım 8: Ayırma ölçüleri (S_j^+ , S_j^-) hesaplamak için Denklem (20) ve Denklem (21) kullanılır.

Adım 9: Denklem (22) kullanılarak her alternatif için yakınlık katsayısı (C_i^+) hesaplanır.

Adım 10: yakınlık katsayısının azalan sırasına göre alternatifler sıralanır. Tablo 12’de bu sıralama görülmektedir. A_2 yani güneş enerjisi en iyi alternatif, A_4 ise en son alternatif olarak ortaya çıkmıştır.

Tablo 12. Alternatiflerin sıralanması

	S_i^+	S_i^-	C_i^+	Rank
A_1	0,492	0,481	0,495	3
A_2	0,300	0,614	0,672	1
A_3	0,342	0,595	0,635	2
A_4	0,678	0,103	0,132	4


5. YÖNETİMSEL ÇIKARIMLAR VE TARTIŞMA

Yenilenebilir enerji kaynaklarının kullanımının önemi kadar, hangi kaynağın seçileceği de büyük önem arz etmektedir. Bu çalışma Kahramanmaraş genelini kapsayan bir çalışmadır. Hâlihazırda Kahramanmaraş ili sınırları içerisinde elektrik üretimi için kullanılan barajlar mevcuttur. Aynı zamanda yenilenebilir enerji kaynaklarından olmayan Afşin- Elbistan yöresinde bulunan iki adet termik santral mevcuttur. Nurhak ilçesine de yapılmayı planlanan bir hidroelektrik santral de Çevresel Etki Değerlendirme (ÇED) sürecindedir. Ancak bahsedilen hidroelektrik santrallerinin kapasitesinin sınırlı olması ve termik santrallerin hem çevreye verdiği büyük zararlar hem de tükenebilir bir kaynak olması nedeniyle yeni santrallere ihtiyaç olduğu söylenebilir [26].

Bu santrallerin yenilenebilir enerji kaynaklarıyla oluşturulması da daha önce belirtilen sebeplerden dolayı elzemdir. Kahramanmaraş genelinde kullanılabilecek dört tip yenilenebilir enerji kaynağı mevcuttur. Bunlar rüzgâr, güneş, hidro ve biyoenerjidir. Bu enerji kaynaklarının kullanımı için uzman görüşü alınarak sekiz kriter belirlenmiştir. Kurulum süresi teknolojinin hazır hale gelme süresidir ve kısa olması bir avantajdır. Kapasite faktörü karar vericiler tarafında önem verilen bir ölçüt olup santralin üretim miktarını belirtmektedir. Yatırım maliyeti ve ekonomik ömür karar vericiler tarafından dikkate alınan ekonomik kriterlerdir. İstihdam oluşturma ve yerel ekonomiye katkı Kahramanmaraş bölgesi için oldukça önemli ölçütlerdir. Karar vericilerin önemle üzerinde durduğu önemli çevresel kriterlerden olan ekolojik etki yenilenebilir enerji kaynaklarının seçimini etkileyen en önemli nedenlerden biridir. Alan gereksinimi, Kahramanmaraş genelinde müsait bölgelerin olduğunu gösteren bir ölçüttür. Örneğin, Elbistan ilçesi sınırlarında yer alan Doğan mevkiinde güneş enerji panelleri bulunmaktadır.

Bu çalışmada kullanılan, Pisagor Bulanık TOPSIS yöntemi, Pisagor bulanık kümelerini içeren geleneksel TOPSIS yönteminin bir uzantısıdır. Pisagor bulanık kümeleri, belirsizliği ve muğlaklığı temsil etmede daha fazla esnekliğe izin veren bulanık kümelerin bir genellemesidir. Pisagor Bulanık TOPSIS yönteminin bazı güçlü ve zayıf yönleri şunlardır: Pisagor bulanık kümelerinin temel güçlü yönlerinden biri, belirsizliği geleneksel bulanık kümelerden daha etkili bir şekilde ele alma yetenekleridir. Bu özellikle belirsizliğin hâkim olduğu karar verme süreçlerinde önemlidir. Pisagor bulanık kümeler, üyelik derecesi ve üyeliksizlik derecesinin toplamının 1'den büyük bir değere toplanmasına izin vererek belirsizliğin daha esnek bir temsilini sağlar. Bu esneklik, gerçek dünyadaki karar problemlerindeki belirsizliği ve belirsizliği daha iyi yakalayabilir. Pisagor Bulanık TOPSIS yöntemi, karar vericilerin alternatiflerin performansı hakkında kesin bilgiye sahip olamayacakları durumlar için uygundur. Pisagor bulanık kümesi, karar matrislerindeki belirsizliğin daha gerçekçi bir temsiline izin verir. Yöntem, özellikle çok kriterli ve kesin olmayan bilgiler içeren çok çeşitli karar verme problemlerine uygulanabilir. Finans, mühendislik, çevre yönetimi gibi çeşitli alanlarda kullanılabilir. Pisagor bulanık kümelerinin dâhil edilmesi, geleneksel TOPSIS yöntemleriyle karşılaştırıldığında ek hesaplama karmaşıklığı getirebilir. Bu, özellikle büyük ölçekli karar problemlerinde hesaplama yükünün artması nedeniyle bir sınırlama olabilir. Birçok bulanık tabanlı yöntem gibi Pisagor Bulanık TOPSIS yöntemi de üyelik ve üyeliksizlik dereceleri gibi parametrelerin ayarlanmasını gerektirir. Bu parametrelerin seçimi subjektif olabilir ve sonuçları etkileyebilir. Pisagor Bulanık TOPSIS yöntemi pratikte yaygın kabul ve uygulama kazanmamış olabilir. Karar vericiler ve uygulayıcılar geleneksel TOPSIS veya diğer karar verme yöntemlerine daha aşina olabilirler. Pisagor Bulanık TOPSIS yönteminin etkinliği, karar alternatifleri için doğru ve kapsamlı verilere dayanır. Bu tür verileri elde etmek, özellikle gerçek dünya senaryolarında zorlayıcı olabilir ve sonuçların güvenilirliğini etkileyebilir. Özetle, Pisagor Bulanık TOPSIS yönteminin belirsizlik ve esneklikle başa çıkma konusunda kayda değer güçlü yönleri olmasına rağmen, aynı zamanda hesaplama karmaşıklığı, parametre belirlemede öznellik, sınırlı kabul ve veri toplamadaki potansiyel zorluklarla ilgili sınırlamaları da vardır. Uygunluğu, eldeki karar probleminin spesifik özelliklerine ve karar vericilerin tercihlerine bağlıdır. Bu çalışmada, Pisagor Bulanık TOPSIS yönteminin GKV ortamında ve Yenilenebilir Enerji Kaynağı seçimine uygulanması etkinliğini artırmış ve güçlü yönlerini ortaya çıkarmıştır.

Günümüz gelişen ve ilerleyen dünyasının önemli bir bölümünü karar verme süreci oluşturmaktadır. Kişiler, kurumlar veya işletmeler hızla değişen ve giderek zorlaşan çalışma koşulları altında sürekli kararlar almaktadır. Durum böyle olunca karar verme sorunları da karmaşık hale geldi. Alternatif ve kriterlerin sayısının artması ve kriterlerin birbiriyle çelişmesi, karar vericilerin aralarında seçim yapmasını oldukça zorlaştırmaktadır. Bu nedenle, birden fazla alternatif arasından bir karara varmak amacıyla birden fazla kriterin değerlendirilmesi amacıyla ÇKKV yöntemleri kullanılmaktadır. ÇKKV yöntemleri yalnızca araç, teknik veya algoritma olarak yürütülmez, aynı zamanda insana özgü yargılama durumlarını da içerir. Farklı ölçü birimlerine sahip kriterlerin bulunması durumunda bu farklılıkların ortadan kaldırılması esastır. Örneğin niteliksel ve niceliksel kriterlerin ölçüm birimi farklı olmasına rağmen TOPSIS yöntemindeki bu farklılığı uzaklığa dayalı ölçeklendirme ile ortadan kaldırılmaktadır. ÇKKV yöntemleri ile ilgili literatür taraması yapıldığında karar problemlerinin çözümü için kullanılan birçok farklı yöntemin olduğu görülmektedir. Farklı ÇKKV yöntemlerine göre değişikliklerin sonuçlar üzerindeki etkisini incelemek için bir karşılaştırma analizi de yapılmıştır. Göreceli yöntemlerdeki olası değişikliklerin nihai sıralamayı nasıl etkileyeceğini gözlemlemek için araştırılmalıdır. Bu amaçla TOPSIS, VIKOR, TODIM ve COPRAS ÇKKV yöntemleri Pisagor Bulanık Ortam altında incelenmiştir. Analizde alternatif sıralamaların varyasyonlarını görebilmek için bilgi sağlamaya yardımcı olmak amacıyla karşılaştırma yapılır. Sonuçlar incelendiğinde yöntemlerde bahsedilen değişikliklerin bazı alternatiflerin sıralamasını az da olsa değiştirdiği görülmektedir. Ancak, COPRAS tekniği dışında ilk ve son alternatifin sonuçları aynı kalmıştır. Farklı ÇKKV durumları için bu aday performans değerlerinin (sıralamaları) bir özeti Şekil 1'de gösterilmektedir. Sonuçlar, önerilen yöntemin avantajlarının ve sonuçların tutarlılığının etkin bir şekilde doğrulanmasını sağlar.



Şekil 1. Farklı ÇKKV yöntemlerinin karşılaştırmaları

ÇKKV yöntemlerinden olan TOPSIS yöntemi kullanılarak yapılan değerlendirmede ilk sırada güneş enerjisinin çıkması normal karşılanabilir. Halen il genelinde sınırlı sayıda da olsa güneş panelleri bulunmaktadır. Bu sayının çok daha fazla artması gerektiği düşünülmektedir. Daha sonra hidroelektrik enerjisi gelmektedir. Büyük akarsu kaynaklarına ve engebeli arazilere sahip olan Kahramanmaraş ilinde hidro enerjiden daha fazla faydalanma çalışmaları devam etmektedir. Örneğin Nurhak ilçesine bir baraj yapılması projesi ÇED sürecindedir [57]. Hidroelektrik enerjiden daha çevreci olan rüzgâr enerjisinde kapasite faktörü sorunu bulunmaktadır. Dört mevsim rüzgârlı yer sayısı il genelinde fazla bulunmamaktadır. Dördüncü alternatif olan biyoenerji için bölgede ciddi bir yatırımın olmadığı görülmektedir. Bu nedenden dolayı diğer alternatiflere göre karar vericiler tarafından geri planda değerlendirilmiştir. Tarım ve hayvancılığın yoğun olarak yapıldığı bölgede bu enerji kaynağı da destekleyici bir alternatif olarak düşünülebilir. Pisagor bulanık küme ortamında TOPSIS yöntemi kullanılarak yapılan bu çalışmanın isabetli bir sonuç verdiğini söyleyebiliriz.

6. SONUÇ

Enerjiye olan ihtiyacın günden güne arttığı günümüz dünyasında yenilenemez enerji kaynağı olan doğalgaz, petrol, kömür, vb. kaynakların da hızla tükenmesi, küresel olarak tüm dünyada yenilenebilir enerji kaynaklarının daha etkin nasıl kullanılacağı konusunda araştırma, yatırım ve üretim yapma mecburiyeti ortaya çıkmıştır. Bu yapılacak olan yatırımların maliyet, verim, kapasite, istihdam oluşturma gibi ölçütler düşünülerek en ideal şekilde yapılması gerekmektedir. Bu çalışmada da Pisagor bulanık küme ortamında TOPSIS çok kriterli karar verme tekniği kullanılarak pozitif ideal çözüme en kısa mesafedeki ve negatif ideal çözüme en uzak mesafedeki karar seçeneğinin belirlenmesi işlemi yapılmak suretiyle bir vaka çalışması yapılmıştır. Çok kriterli karar verme yöntemlerinin avantajları kullanılarak uzman görüşlü alınarak belirlenen kriterlerden dört alternatif içerisinde en iyi alternatif bulunmaya çalışılmıştır. Bu çalışma sonucunda, A_2 yani Güneş enerjisi Kahramanmaraş bölgesi için en tercih edilebilir yenilenebilir enerji kaynağı olarak ortaya konmuştur. A_4 yani Bioenerji ise en son tercih olarak bulunmuştur. Yatırım maliyeti (C_{21}) ve Ekolojik etki (C_{41}) kriterleri bu seçime en çok etki yapan kriterler olarak görülmüş, seçimde en az etkiyi ise Alan gereksinimi (C_{42}) kriteri olmuştur. Bu tercihler yapılan literatür taraması ve uzman görüşleri ile örtüşmektedir. Bu konu ile alakalı gelecek çalışmalara ışık tutacak bazı önemli hususlarda burada belirtilebilir. Farklı ÇKKV yöntemleri bu önerilen modele entegre edilebilir. İlerde AHP benzeri başka yöntemler kriter ağırlıklarını belirlemek için kullanılabilir. Yenilenebilir enerji kaynağının seçimi değerlendirilirken kullanılan metod ile elde edilen sonuçlar duyarlılık analizi ile kontrol edilebilir. Bu sayede farklı yöntemler aynı anda uygulanarak sonuçların güvenilirliği duyarlılık analizi ile doğrulanmış olacaktır. Genel ölçütler her bölgede kullanılabilir olacakken, bölgesel farklılıkları açığa çıkaracak bölgesel ölçütler kullanılabilir olacaktır. Ayrıca daha geniş bir çerçevede yapılacak çalışmalarda seçilecek olan yöntemlerin seçim nedenleri daha objektif bir şekilde açıklanırsa, daha etkili sonuçlar ve çıkarımlara ulaşılabilir.

REFERANSLAR

- [1] Koç E and Kaya K, “Enerji Kaynakları–Yenilenebilir Enerji Durumu,” *Mühendis ve Makina*, vol. 56, no. 667, pp. 36–47, 2015.
- [2] A. Kayahan Karakul, “Bulanık AHP Yöntemi ile Yenilenebilir Enerji Kaynağı Seçimi,” *Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, no. 19, pp. 127–150, Apr. 2020, doi: 10.29029/busbed.640162.
- [3] D. Ghose, S. Pradhan, and Shabbiruddin, “Development of model for assessment of renewable energy sources: a case study on Gujarat, India,” *International Journal of Ambient Energy*, vol. 43, no. 1, pp. 1157–1166, Dec. 2022, doi: 10.1080/01430750.2019.1691650.
- [4] H. Dinçer and S. Yüksel, “Multidimensional evaluation of global investments on the renewable energy with the integrated fuzzy decision-making model under the hesitancy,” *Int J Energy Res*, vol. 43, no. 5, pp. 1775–1784, Apr. 2019, doi: 10.1002/er.4400.
- [5] G. N. Yücenur, Ş. Çaylak, G. Gönül, and M. Postalcioglu, “An integrated solution with SWARA&COPRAS methods in renewable energy production: City selection for biogas facility,” *Renew Energy*, vol. 145, pp. 2587–2597, Jan. 2020, doi: 10.1016/j.renene.2019.08.011.
- [6] Y. A. Solangi, Q. Tan, N. H. Mirjat, G. Das Valasai, M. W. A. Khan, and M. Ikram, “An Integrated Delphi-AHP and Fuzzy TOPSIS Approach toward Ranking and Selection of Renewable Energy Resources in Pakistan,” *Processes*, vol. 7, no. 2, p. 118, Feb. 2019, doi: 10.3390/pr7020118.
- [7] E. Billig and D. Thraen, “Renewable methane – A technology evaluation by multi-criteria decision making from a European perspective,” *Energy*, vol. 139, pp. 468–484, Nov. 2017, doi: 10.1016/j.energy.2017.07.164.

- [8] H.-C. Lee and C.-T. Chang, “Comparative analysis of MCDM methods for ranking renewable energy sources in Taiwan,” *Renewable and Sustainable Energy Reviews*, vol. 92, pp. 883–896, Sep. 2018, doi: 10.1016/j.rser.2018.05.007.
- [9] P. Rani, A. R. Mishra, K. R. Pardasani, A. Mardani, H. Liao, and D. Streimikiene, “A novel VIKOR approach based on entropy and divergence measures of Pythagorean fuzzy sets to evaluate renewable energy technologies in India,” *J Clean Prod*, vol. 238, p. 117936, Nov. 2019, doi: 10.1016/j.jclepro.2019.117936.
- [10] F. Göçer, “A Novel Extension of Fermatean Fuzzy Sets into Group Decision Making: A Study for Prioritization of Renewable Energy Technologies,” *Arab J Sci Eng*, Oct. 2023, doi: 10.1007/s13369-023-08307-5.
- [11] C.-L. Hwang and K. Yoon, *Multiple Attribute Decision Making*, vol. 186. Berlin, Heidelberg: Springer Berlin Heidelberg, 1981. doi: 10.1007/978-3-642-48318-9.
- [12] S. Dündar, F. Ecer, and Ş. Özdemir, “Fuzzy Topsis Yöntemi İle Sanal Mağazaların Web Sitelerinin Değerlendirilmesi,” *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, Cilt. 21, Sayı. 1, ss.1- 19.
- [13] L. A. Zadeh, “Fuzzy sets,” *Information and Control*, vol. 8, no. 3, pp. 338–353, Jun. 1965, doi: 10.1016/S0019-9958(65)90241-X.
- [14] R. R. Yager, “Pythagorean Membership Grades in Multicriteria Decision Making,” *IEEE Transactions on Fuzzy Systems*, vol. 22, no. 4, pp. 958–965, Aug. 2014, doi: 10.1109/TFUZZ.2013.2278989.
- [15] E. Ilbahar, A. Karaşan, S. Cebi, and C. Kahraman, “A novel approach to risk assessment for occupational health and safety using Pythagorean fuzzy AHP & fuzzy inference system,” *Saf Sci*, vol. 103, pp. 124–136, Mar. 2018, doi: 10.1016/j.ssci.2017.10.025.
- [16] R. R. Yager, “Pythagorean fuzzy subsets,” in *2013 Joint IFSA World Congress and NAFIPS Annual Meeting (IFSA/NAFIPS)*, IEEE, Jun. 2013, pp. 57–61. doi: 10.1109/IFSA-NAFIPS.2013.6608375.
- [17] P. Rani, A. R. Mishra, G. Rezaei, H. Liao, and A. Mardani, “Extended Pythagorean Fuzzy TOPSIS Method Based on Similarity Measure for Sustainable Recycling Partner Selection,” *International Journal of Fuzzy Systems*, vol. 22, no. 2, pp. 735–747, Mar. 2020, doi: 10.1007/s40815-019-00689-9.
- [18] F. Göçer and G. Büyükoçkan, “A novel extension of Pythagorean fuzzy MULTIMOORA approach for new product development,” *Heliyon*, vol. 9, no. 6, p. e16726, Jun. 2023, doi: 10.1016/j.heliyon.2023.e16726.
- [19] F. Göçer, “Improving sustainable supplier evaluation by an integrated MCDM method under pythagorean fuzzy environment,” *Cumhuriyet Science Journal*, vol. 42, no. 1, pp. 218–235, Mar. 2021, doi: 10.17776/cs.j.735674.
- [20] M. Akram, W. A. Dudek, and F. Ilyas, “Group decision-making based on pythagorean fuzzy TOPSIS method,” *International Journal of Intelligent Systems*, vol. 34, no. 7, pp. 1455–1475, Jul. 2019, doi: 10.1002/int.22103.
- [21] M. Yucesan and M. Gul, “Hospital service quality evaluation: an integrated model based on Pythagorean fuzzy AHP and fuzzy TOPSIS,” *Soft comput*, vol. 24, no. 5, pp. 3237–3255, Mar. 2020, doi: 10.1007/s00500-019-04084-2.
- [22] Y. Dorfeshan and S. M. Mousavi, “A group TOPSIS-COPRAS methodology with Pythagorean fuzzy sets considering weights of experts for project critical path problem,” *Journal of Intelligent & Fuzzy Systems*, vol. 36, no. 2, pp. 1375–1387, Mar. 2019, doi: 10.3233/JIFS-172252.

- [23] A. Biswas and B. Sarkar, “Pythagorean fuzzy TOPSIS for multicriteria group decision-making with unknown weight information through entropy measure,” *International Journal of Intelligent Systems*, vol. 34, no. 6, pp. 1108–1128, Jun. 2019, doi: 10.1002/int.22088.
- [24] M. Hajiaghaei-Keshteli, Z. Cenk, B. Erdebilli, Y. Selim Özdemir, and F. Gholian-Jouybari, “Pythagorean Fuzzy TOPSIS Method for Green Supplier Selection in the Food Industry,” *Expert Syst Appl*, vol. 224, p. 120036, Aug. 2023, doi: 10.1016/j.eswa.2023.120036.
- [25] Uysal F, “Türkiye’de Yenilenebilir Enerji Alternatiflerinin Seçimi İçin Graf Teori ve Matris Yaklaşım,” *Ekonometri ve İstatistik Sayı: 13 (12. Uluslararası Ekonometri, Yöneylem Araştırması, İstatistik Sempozyumu Özel Sayısı)*, pp. 23–40, 2011.
- [26] S.-K. Yi, H.-Y. Sin, and E. Heo, “Selecting sustainable renewable energy source for energy assistance to North Korea,” *Renewable and Sustainable Energy Reviews*, vol. 15, no. 1, pp. 554–563, Jan. 2011, doi: 10.1016/j.rser.2010.08.021.
- [27] A. Sadeghi, T. Larimian, and A. Molabashi, “Evaluation of Renewable Energy Sources for Generating Electricity in Province of Yazd: A Fuzzy Mcdm Approach,” *Procedia Soc Behav Sci*, vol. 62, pp. 1095–1099, Oct. 2012, doi: 10.1016/j.sbspro.2012.09.187.
- [28] Yakıcı Ayan Tuba and Pabuçcu Hakan, “Yenilenebilir Enerji Kaynakları Yatırım Projelerinin Analitik Hiyerarşi Süreci Yöntemi ile Değerlendirilmesi,” *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, vol. 18, pp. 89–110, 2013.
- [29] T. Ertay, C. Kahraman, and İ. Kaya, “Evaluation Of Renewable Energy Alternatives Using Macbeth And Fuzzy AHP Multicriteria Methods: The Case Of Turkey,” *Technological and Economic Development of Economy*, vol. 19, no. 1, pp. 38–62, Apr. 2013, doi: 10.3846/20294913.2012.762950.
- [30] A. Yazdani-Chamzini, M. M. Fouladgar, E. K. Zavadskas, and S. H. H. Moini, “Selecting The Optimal Renewable Energy Using Multi Criteria Decision Making,” *Journal of Business Economics and Management*, vol. 14, no. 5, pp. 957–978, Sep. 2013, doi: 10.3846/16111699.2013.766257.
- [31] A. Tasri and A. Susilawati, “Selection among renewable energy alternatives based on a fuzzy analytic hierarchy process in Indonesia,” *Sustainable Energy Technologies and Assessments*, vol. 7, pp. 34–44, Sep. 2014, doi: 10.1016/j.seta.2014.02.008.
- [32] G. Büyüközkan and S. Güleriyüz, “A new GDM based AHP framework with linguistic interval fuzzy preference relations for renewable energy planning,” *Journal of Intelligent & Fuzzy Systems*, vol. 27, no. 6, pp. 3181–3195, 2014, doi: 10.3233/IFS-141275.
- [33] A. Maxim, “Sustainability assessment of electricity generation technologies using weighted multi-criteria decision analysis,” *Energy Policy*, vol. 65, pp. 284–297, Feb. 2014, doi: 10.1016/j.enpol.2013.09.059.
- [34] M. Troldborg, S. Heslop, and R. L. Hough, “Assessing the sustainability of renewable energy technologies using multi-criteria analysis: Suitability of approach for national-scale assessments and associated uncertainties,” *Renewable and Sustainable Energy Reviews*, vol. 39, pp. 1173–1184, Nov. 2014, doi: 10.1016/j.rser.2014.07.160.

- [35] Ü. Şengül, M. Eren, S. Eslamian Shiraz, V. Gezder, and A. B. Şengül, “Fuzzy TOPSIS method for ranking renewable energy supply systems in Turkey,” *Renew Energy*, vol. 75, pp. 617–625, Mar. 2015, doi: 10.1016/j.renene.2014.10.045.
- [36] Y. Çelikkilek and F. Tüysüz, “An integrated grey based multi-criteria decision making approach for the evaluation of renewable energy sources,” *Energy*, vol. 115, pp. 1246–1258, Nov. 2016, doi: 10.1016/j.energy.2016.09.091.
- [37] Sağır H and Doğanalp B, “Bulanık Çok Kriterli Karar Verme Perspektifinden Türkiye İçin Enerji Kaynakları Değerlendirmesi,” *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi Ocak 2016, Sayı:11*, 2016.
- [38] L. Abdullah and L. Najib, “Sustainable energy planning decision using the intuitionistic fuzzy analytic hierarchy process: choosing energy technology in Malaysia,” *International Journal of Sustainable Energy*, vol. 35, no. 4, pp. 360–377, Apr. 2016, doi: 10.1080/14786451.2014.907292.
- [39] H. Al Garni, A. Kassem, A. Awasthi, D. Komljenovic, and K. Al-Haddad, “A multicriteria decision making approach for evaluating renewable power generation sources in Saudi Arabia,” *Sustainable Energy Technologies and Assessments*, vol. 16, pp. 137–150, Aug. 2016, doi: 10.1016/j.seta.2016.05.006.
- [40] G. Büyükoçkan and S. Gülerüz, “Evaluation of Renewable Energy Resources in Turkey using an integrated MCDM approach with linguistic interval fuzzy preference relations,” *Energy*, vol. 123, pp. 149–163, Mar. 2017, doi: 10.1016/j.energy.2017.01.137.
- [41] S. Ünlüsoy, T. Eren, and E. Özcan, “ANP VE TOPSIS Yöntemleriyle Türkiye’de Yenilenebilir Enerji Yatırım Alternatiflerinin Değerlendirilmesi,” *Selcuk University Journal of Engineering ,Science and Technology*, vol. 5, no. 2, pp. 204–219, Jun. 2017, doi: 10.15317/Scitech.2017.82.
- [42] O. Derse and E. Yontar, “SWARA-TOPSIS Yöntemi ile En Uygun Yenilenebilir Enerji Kaynağının Belirlenmesi,” *Endüstri Mühendisliği*, vol. 31, no. 3, pp. 389–419, Dec. 2020, doi: 10.46465/endustrimuhendisligi.798063.
- [43] S. Bilgiç, B. Torğul, and T. Paksoy, “Sürdürülebilir Enerji Yönetimi için BWM Yöntemi ile Yenilenebilir Enerji Kaynaklarının Değerlendirilmesi,” *Verimlilik Dergisi*, no. 2, pp. 95–110, Apr. 2021, doi: 10.51551/verimlilik.663721.
- [44] M. Sipa and I. Gorzeń-Mitka, “Assessment of the Progress towards the Management of Renewable Energy Consumption in the Innovativeness Context—A Country Approach,” *Energies (Basel)*, vol. 14, no. 16, p. 5064, Aug. 2021, doi: 10.3390/en14165064.
- [45] Y. Xie, Y. Zhou, Y. Peng, H. Dincer, S. Yuksel, and P. an Xiang, “An Extended Pythagorean Fuzzy Approach to Group Decision-Making With Incomplete Preferences for Analyzing Balanced Scorecard-Based Renewable Energy Investments,” *IEEE Access*, vol. 9, pp. 43020–43035, 2021, doi: 10.1109/ACCESS.2021.3065294.
- [46] E. Yontar, “Determining the Importance Order of The Criteria Affecting the Problems of Regional Selection in Renewable Energy Studies,” *Uluslararası Mühendislik Arastirma ve Gelistirme Dergisi*, vol. 14, no. 2, pp. 475–491, Jul. 2022, doi: 10.29137/umagd.1034298.

- [47] F. Sitorus and P. R. Brito-Parada, “The selection of renewable energy technologies using a hybrid subjective and objective multiple criteria decision making method,” *Expert Syst Appl*, vol. 206, p. 117839, Nov. 2022, doi: 10.1016/j.eswa.2022.117839.
- [48] H. Rezk *et al.*, “Multi-criteria decision making for different concentrated solar thermal power technologies,” *Sustainable Energy Technologies and Assessments*, vol. 52, p. 102118, Aug. 2022, doi: 10.1016/j.seta.2022.102118.
- [49] K. Govindan, “Pathways to low carbon energy transition through multi criteria assessment of offshore wind energy barriers,” *Technol Forecast Soc Change*, vol. 187, p. 122131, Feb. 2023, doi: 10.1016/j.techfore.2022.122131.
- [50] K. Barnaś *et al.*, “Algorithm for the comprehensive thermal retrofit of housing stock aided by renewable energy supply: A sustainable case for Krakow,” *Energy*, vol. 263, p. 125774, Jan. 2023, doi: 10.1016/j.energy.2022.125774.
- [51] M. Kamali Saraji, E. Aliasgari, and D. Streimikiene, “Assessment of the challenges to renewable energy technologies adoption in rural areas: A Fermatean CRITIC-VIKOR approach,” *Technol Forecast Soc Change*, vol. 189, p. 122399, Apr. 2023, doi: 10.1016/j.techfore.2023.122399.
- [52] M. Shao, Z. Han, J. Sun, H. Gao, S. Zhang, and Y. Zhao, “A novel framework for wave power plant site selection and wave forecasting based on GIS, MCDM, and ANN methods: A case study in Hainan Island, Southern China,” *Energy Convers Manag*, vol. 299, p. 117816, Jan. 2024, doi: 10.1016/j.enconman.2023.117816.
- [53] X. Peng and Y. Yang, “Fundamental Properties of Interval-Valued Pythagorean Fuzzy Aggregation Operators,” *International Journal of Intelligent Systems*, vol. 31, no. 5, pp. 444–487, May 2016, doi: 10.1002/int.21790.
- [54] X. Zhang and Z. Xu, “Extension of TOPSIS to Multiple Criteria Decision Making with Pythagorean Fuzzy Sets,” *International Journal of Intelligent Systems*, vol. 29, no. 12, pp. 1061–1078, Dec. 2014, doi: 10.1002/int.21676.
- [55] J.-J. Wang, Y.-Y. Jing, C.-F. Zhang, and J.-H. Zhao, “Review on multi-criteria decision analysis aid in sustainable energy decision-making,” *Renewable and Sustainable Energy Reviews*, vol. 13, no. 9, pp. 2263–2278, Dec. 2009, doi: 10.1016/j.rser.2009.06.021.
- [56] G. Büyüközkan, Y. Karabulut, and E. Mukul, “A novel renewable energy selection model for United Nations’ sustainable development goals,” *Energy*, vol. 165, pp. 290–302, Dec. 2018, doi: 10.1016/j.energy.2018.08.215.
- [57] <https://kahramanmaras.csb.gov.tr/kahramanmaras-ili-caglayancerit-nurhak-ilcesindeki-duyuru-340537>.

Makine Çizelgeleme Problemlerinin Çözümünde Pekiştirmeli Öğrenme Etkisinin Analizi

Orhan Engin^{1*}, Bünyamin Sarıcan²

¹Endüstri Mühendisliği Bölümü, Mühendislik Fakültesi, Konya Teknik Üniversitesi, Konya, Türkiye.

²Endüstri Mühendisliği Bölümü, Lisansüstü Eğitim Enstitüsü, Konya Teknik Üniversitesi, Konya, Türkiye.

*oengin@ktun.edu.tr

Özet

Pekiştirmeli öğrenme, günümüz dünyasında birçok gerçek hayat problemine çözüm bulmak için aktif bir şekilde kullanılmakta ve endüstri içerisinde umut verici yöntemler arasında gösterilmektedir. Bu çalışmada, makine öğrenmesinin bir alt dalı olan pekiştirmeli öğrenmenin iş çizelgeleme problemlerinin çözümündeki etkisi araştırılmıştır. Bu kapsamda, öncelikle pekiştirmeli öğrenmede durum tanımı, eylem seçimi ve öğrenme algoritmaları açıklanmıştır. Ardından, iş çizelgeleme probleminin sınıflandırmasına yer verilmiştir. Literatürde yer alan iş çizelgelemede, pekiştirmeli öğrenme yönteminin kullanıldığı, son yirmi yılda yayımlanan, 50 makale çalışmasına yer verilmiştir. Literatürde yer alan çalışmaların çizelgeleme problemlerinin çözümü üzerinde gösterdiği etki değerlendirilmiştir. Son bölümde, pekiştirmeli öğrenmenin diğer çözüm yöntemlerine kıyasla güçlü ve zayıf yönlerine yer verilmiştir. Pekiştirmeli öğrenme algoritmaları, dinamik çevreden, önceden gelen, bilgileri kullanarak öğrenme gerçekleştirdikleri için üretim sürecinde meydana gelecek ani değişikliklere (makine arızası, işlerin rassal gelişi, sipariş iptali vd.) kolayca tepki vererek dinamik bir çizelgeleme yaklaşımı sunar. Bu çalışmanın sonunda, gelecekte yapılacak araştırmalar ile ilgili öneriler sunulmuştur.

Anahtar Kelimeler: Makine çizelgeleme optimizasyonu, Makine öğrenmesi, İş çizelgeleme, Pekiştirmeli öğrenme

Analysis of Reinforcement Learning Effect in Solving Machine Scheduling Problems

Abstract

Reinforcement learning is actively used to find solutions to many real-life problems in today's world and is shown among the promising methods in the industry. This study investigated the effect of reinforcement learning, which is a sub-branch of machine learning, in solving job scheduling problems. In this context, first, situation definition, action selection, and learning algorithms in reinforcement learning are explained. Then, the classification of the job scheduling problem is given. In the literature, 50 articles published in the last twenty years, in which the reinforcement learning method is used in job scheduling, are included. The effects of the studies in the literature on the solution of scheduling problems were evaluated. In the last section, the strengths and weaknesses of reinforcement learning compared to other solution methods are included. Reinforcement learning algorithms offer a dynamic scheduling approach by easily reacting to sudden changes that may occur in the production process (machine failure, random arrival of jobs, order cancellation, etc.) because they learn by using previous information from the dynamic environment. At the end of this study, suggestions for future research are presented.

Keywords: Machine scheduling optimization, Machine learning, Job scheduling, Reinforcement learning.

1. GİRİŞ

Üretim çizelgeleme, sınırlı üretim kaynaklarını zaman içinde paralel ve sıralı üretim faaliyetleri arasında tahsis eden bir optimizasyon süreci olarak tanımlanır. Bu tahsis, faaliyetler arasındaki zamansal ilişkileri ve bir dizi paylaşılan kaynağın kapasite sınırlamalarını yansıtan kısıtlara uymalıdır. Deterministik çizelgeleme probleminde, iş sayısı, makine sayısı, iş başına işlem sayısı, makinelerdeki işlem süreleri, öncelik kısıtlamaları ve problem kısıtlamaları gibi çizelgeleme probleminin türüne bağlı olarak değişebilen tüm parametrelerin önceden bilindiği varsayılır. Çözüm bulunmak istenen çizelgeleme problemi stokastik ise, mevcut bilgiler kesin değildir çünkü farklı işlere ait operasyonların işlem süreleri rassal değişkenler olarak modellenir. Bu, bütün işlerin işlem süresinin, çizelgeleme süresince tam olarak bilinmediği anlamına gelir. İşlem süreleri, teslim tarihleri ve diğer çizelgeleme ile ilgili parametrelerin tam olarak bilinmediği durumlarda, son yıllarda yoğun olarak kullanılan bir diğer yöntemde bulanık çizelgeleme modelleridir. Bulanık Çizelgeleme problemlerinde, işlem süreleri, işlerin teslim tarihleri ve diğer çizelgeleme problemi ile ilgili parametreler bulanık sayılar ile ifade edilir [1, 2].

Çizelgeleme problemlerinin çözümü, üretim sistemlerinde ve endüstriyel süreçlerde önemli olduğu için verimli çizelgeleme teknolojilerinin geliştirilmesi son elli yılda üzerinde en çok çalışılan konulardan biri olmuştur [3]. Çizelgeleme problemlerinin çözümünde farklı yöneylem araştırması teknikleri (doğrusal programlama, karışık tamsayı programlama vb.) kullanılır. Bu yaklaşımlar genellikle bir amaç fonksiyonu, bir dizi değişken ve bir dizi kısıtlama içeren bir modelin tanımını içerir. Yöneylem araştırması tabanlı teknikler, iyi tanımlanmış problemler için en uygun çözümleri elde etme yeteneğini göstermiştir, ancak yöneylem araştırması çözümleri statik modellerle sınırlıdır. Öte yandan yapay zekâ yaklaşımları, gerçek dünya problemlerinin daha esnek temsillerini sağlayarak insan uzmanlığının döngüde yer almasına izin verir. Çizelgeleme konusundaki araştırmaların büyük çoğunluğu, tam bilgi ve deterministik bir ortam varsayarak bir temel çizelge oluşturmak için kesin ve yeterli olmayan prosedürlerin geliştirilmesine odaklanmıştır. Ancak, gerçek dünya o kadar istikrarlı değildir, projeler yürütülürken beklenmedik olaylara maruz kalınabilir ve bu durum çok sayıda program kesintisine yol açabilir. Örneğin, kaynaklar kullanılamaz hale gelebilir (arızalar veya planlanmış bakımlar), yeni siparişler gelebilir, operasyonlar zarar görebilir, işler beklenenden daha uzun sürebilir vb. Bu tür durumlarla başa çıkmak için kullanılan bir yaklaşımda, sağlamlığın bir algoritmanın belirsizlikler altındaki performansını ifade ettiği, sağlam çizelgeler oluşturmaktır.


Pekiştirmeli Öğrenme (PÖ), sayısal bir ödül sinyali maksimize etmek için ne yapılacağını (durumları eylemlerle nasıl eşleştireceğini) öğrenmektir. Bir ajanın, ortamıyla deneme yanılma etkileşimleri yoluyla en uygun davranışı öğrenmesini sağlar. Ajan, farklı durumlarda eylemleri tekrar tekrar deneyerek eylemlerinin sonuçlarını keşfedebilir ve her durum için en iyi eylemi belirleyebilir. Örneğin, beklenmedik olaylarla uğraşırken, önceki sonuçlardan 'öğrenebilecekleri' ve sonraki yinelemeler için belirli parametreleri değiştirebilecekleri için öğrenme yöntemleri önemli bir rol oynayabilir. Endüstrinin ihtiyaç duyduğu sistem, üretim tesisindeki koşullara tam olarak uyum sağlayan ve çok kısa sürede iyi çözümler üreten, optimize edilmiş çizelgelerdir. Endüstri 4.0 ile akıllı fabrikalarda optimize edilmiş çizelgeleme problemleri son yıllarda geliştirilmeye başlanmıştır [4]. Bu tip çizelgelerde kullanılan yöntemlerden biri de öğrenme tabanlı algoritmalarıdır. Bu algoritmalar, dinamik çizelge oluşturmaya imkân verir. Pekiştirmeli öğrenme yöntemlerinin son yıllarda iş çizelgeleme problemlerine aktif olarak uygulandığı görülmektedir. Bu çalışmada, literatürde pekiştirmeli öğrenme yöntemlerinin çizelgeleme problemlerinin çözümü üzerindeki etkisi araştırılmıştır. Bu amaçla “scholar.google.com” arama motoru yardımıyla “Reinforcement Learning and scheduling” anahtar kelimeleri kullanılarak, 2003 ile 2023 yılları aralığında tarama yapılmış, elde edilen çalışmalar değerlendirilmiştir. Bu çalışmalardan; tek makine, paralel makine, akış tipi, atölye tipi ve diğer makine çizelgeleme ile doğrudan ilgili 50 adet makale tespit edilmiş ve çalışmalar detaylı olarak incelenmiştir. Bu araştırma, pekiştirmeli öğrenme yöntemlerinin tek makine, paralel makine, akış tipi, atölye tipi ve diğer makine çizelgeleme problemlerinin çözümünde kullanımı ile ilgili literatürde yapılan detaylı bir çalışmadır.

Bu çalışma dört bölümden oluşmaktadır. İkinci, "Pekiştirmeli öğrenme" bölümü, pekiştirmeli öğrenme yöntemi, öğrenme algoritmaları, durum tanımı ve eylem seçimini açıklar. Üçüncü, "İş çizelgeleme" bölümü, iş çizelgelemenin temel yönlerini açıklar. Literatür araştırması olan dördüncü bölümünde, literatürde yer alan çalışmalara dört başlık altında sınıflandırılarak yer verilmiştir. Beşinci bölüm olan sonuç kısmında ise analiz ve değerlendirmelerde bulunulmuştur.

2. PEKİŞTİRMELİ ÖĞRENME

Pekiştirmeli öğrenme, makinenin amaç doğrultusunda ne yapması gerektiğini öğrenen bir makine öğrenme tekniğidir. "Pekiştirmeli öğrenme yaklaşımı, denetimli ve denetimsiz öğrenme yöntemlerinden farklılık gösterir. Denetimli öğrenme, etiketli verilerden eğitim ve test kümeleri oluşturarak bir modelin oluşturulması ve performansının test kümeleriyle değerlendirilmesi üzerine kuruludur. Bu sayede model, etiketsiz verileri tahmin etmek için kullanılabilir hale gelir. Öte yandan, denetimsiz öğrenme, genellikle etiketlenmemiş veri kümelerinde, veri gruplandırma üzerinde yoğunlaşır. Pekiştirmeli öğrenmede ise, bir öğrenen makine olan ajanlar karşılaştığı durumlara tepki verir ve buna karşılık sayısal bir ödül alır. Pekiştirmeli öğrenmenin en belirgin özelliği olan deneme yanılma yöntemiyle ajan, aldığı ödülü maksimize etmeyi hedefler [5].

Pekiştirmeli öğrenme sürecindeki temel zorluklardan biri, keşif ve sömürü dengesini sağlamaktır. Ajan, daha önce pozitif ödül aldığı eylemleri seçerek daha fazla ödül kazanmayı hedefler. Ancak, yeni durumlarda daha yüksek ödül kazanabilecek eylemleri de keşfetmelidir. Ajan, böylece farklı eylemler deneyerek optimum sonuçları elde etmeyi kademeli olarak öğrenir. Pekiştirmeli öğrenme ajanları, belirlenen hedeflere ulaşabilir, çevrelerini algılayabilir ve etkileyebilecek eylemleri seçebilir. Ajandan kastedilen, robot gibi bir varlık veya bir organizma değildir. Ajan denilince eylemleri gerçekleştiren ve öğrenen faktör akla gelmelidir. Aşağıda yer alan Şekil 1'de pekiştirmeli öğrenmeye yönelik şematik gösterim yer almaktadır. Pekiştirmeli öğrenme sistemlerinde, ajan ve çevrenin yanı sıra dört unsurdan oluşan bir yapı bulunur: politika, ödül, değer fonksiyonu ve çevre modeli.



Şekil 1. Pekiştirmeli öğrenmeye ilişkin şematik görünüm [6].

Politika, ajanın mevcut durumda alabileceği aksiyonu belirleyen bir yönerge kümesidir. Bu, etki-tepki ilişkisini ifade eder. Durum, bir etki olarak düşünüldüğünde, ajan buna tepki olarak bir aksiyon verir. Politika, basit bir aksiyon veya tüm durumları kapsayan bir arama tablosu olarak tanımlanabilir. Aynı zamanda politika, ajanın durumu değerlendirerek alabileceği aksiyonları dinamik olarak aramasından kaynaklanan bir niteliğe sahiptir [7]. Ödül, ajanın gerçekleştirdiği bir aksiyon sonucunda ortamdaki aldığı sayısal bir puandır. Pekiştirmeli öğrenme ajanı, uzun vadede aldığı ödülleri maksimize etmeyi amaçlamaktadır. Ajanın politikası, edinilen ödülleri çerçevesinde süreç içinde değişir. Mesela, düşük bir puan elde edilen bir aksiyon sonrasında ajan aynı durumla karşılaştığında başka bir eylem seçebilir.

Durum değeri, ajanın mevcut durumdan başlayarak gelecekteki beklenen ödüllerin toplamını temsil eder. Durum değeri, uzun vadede, neyin iyi veya kötü olduğunu gösterirken ödülleri anlık olarak aksiyonların iyi veya kötü olduğunu ifade eder. İsteğe bağlı olarak sisteme entegre edilen bir unsur modeldir. Ortamın bir

simülasyonunu oluşturur ve ajanın aksiyon almadan elde edeceği ödülü ve oluşacak durumu tahmin etmesine olanak sağlar. Bu sayede planlama yapılır ve ajanın davranışında değişiklikler olabilir [7].

2.1 Öğrenme Algoritmaları

Ödül temsili, durum temsili, değer güncelleme prosedürü, politika uyarlama gibi konulara göre kullanılan algoritmalar, birbirinden farklılık gösterir. Aşağıda, pekiştirmeli öğrenme için literatürde sıklıkla kullanılan algoritmalar açıklanmıştır.

2.1.1 Q-Öğrenme

Q-Öğrenme, modelden bağımsız bir pekiştirmeli öğrenme algoritmasıdır. Belirli bir durumdaki bir eylemin değerini öğrenmek için kullanılır. Çevre modeline ihtiyaç duymaz ve stokastik geçişler ve ödüllerle ilgili problemleri çözebilir ("modelsiz" olarak adlandırılır). Q-öğrenme, herhangi bir Sonlu Markov Karar Süreci (SMKS) için en uygun politikayı bulmak amacıyla, mevcut durumdan başlayarak, birbirini izleyen adımlarda, toplam ödülün beklenen değerini maksimize etmeye çalışır. Sınırsız keşif süresi ve kısmen rasgele bir politika kullanıldığında, herhangi bir SMKS için en uygun, eylem seçim politikasını belirleyebilir. "Q" ise algoritmanın belirli bir durumda gerçekleştirilen bir eylem için beklenen ödülleri hesapladığı fonksiyonu temsil eder. Geleceğe Δt adım attıktan sonra ajan bir sonraki adımı seçer. Bu adımın ağırlığı $\gamma^{\Delta t}$ şeklinde hesaplanır. Burada γ (Gamma) indirim faktörü olarak adlandırılır ve $[0,1]$ arasında bir değer alır. γ , daha önce alınan ödüllere daha sonra alınanlardan daha yüksek bir ağırlık verme etkisine sahiptir, böylece "iyi bir başlangıcın" değerini yansıtır. γ , her Δt adımda başarılı olma olasılığı olarak da yorumlanabilir. Bu nedenle algoritma, bir durum-eylem kombinasyonunun kalitesini hesaplayan bir fonksiyona sahiptir. $Q: S \times A \rightarrow \mathbb{R}$

Öğrenme başlamadan önce Q , muhtemel keyfi bir sabit değerle (programcı tarafından seçilen) başlatılır. Ardından, ajan her t zamanda seçtiği a_t eyleminde, bir r_t ödülü gözlemler ve yeni bir s_{t+1} durumuna girer (bu hem önceki s_t durumuna hem de seçilen eyleme bağlı olabilir) ve Q güncellenir. Algoritmanın temeli, basit bir değer yineleme güncellemesi olan Bellman denklemi kullanarak geçerli değerlerin ağırlıklı ortalamasını ve yeni bilgileri kullanmaktır [8].

2.1.2 SARSA

Durum-eylem-ödül-durum-eylem (SARSA), makine öğreniminin, pekiştirmeli öğrenme alanında kullanılan Markov karar süreci politikasını öğrenmek için kullandığı bir algoritmadır. Rummery ve Niranjan, "Değiştirilmiş Bağlantıcı Q-Öğrenme" (DBQ-Ö) adlı bir teknik önerdiler [9]. Bu ad, Q -değerini güncellemeye yönelik ana işlevin, " S_1 " ajanın mevcut durumuna, " A_1 " ajanın seçtiği eyleme, " R " ajanın bu eylemi seçtiği için aldığı ödüle, " S_2 " ajanın bu eylemi yaptıktan sonra girdiği duruma ve son olarak " A_2 " ajanın yeni durumunda seçtiği bir sonraki eyleme bağlı olduğu gerçeğini yansıtır. $(s_t, a_t, r_t, s_{t+1}, a_{t+1})$ beşlinin kısaltması SARSA'dır. Bir SARSA ajanı, çevre ile etkileşime girer ve gerçekleştirilen eylemlere dayalı olarak politikayı günceller, dolayısıyla bu, politikaya dayalı öğrenme algoritması olarak bilinir. Bu güncelleme işlemi denklem (1)'e göre yapılır.

$$Q^{yeni}(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha[r_t + \gamma Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)] \quad (1)$$

Bir durum eylemi için Q değeri, alfa öğrenme oranı tarafından ayarlanan bir hatayla güncellenir. Q değerleri, s durumunda a eylemi gerçekleştirmek için bir sonraki zaman adımında alınan olası ödülü, artı bir sonraki durum eylemi gözlemlerinden alınan indirimli gelecekteki ödülü temsil eder. Watkin'in Q -öğrenmesi, mevcut eylemlerin maksimum ödülüne dayalı olarak optimal durum-eylem değeri fonksiyonu Q^* tahminini günceller. SARSA kendi izlediği politikayı almakla ilişkili Q değerlerini öğrenirken, Watkin'in Q -öğrenmesi bir keşif/sömürü sürecini izlerken en uygun politikayı almakla ilişkili Q değerlerini öğrenir. Watkin'in Q -öğrenmesinin bazı optimizasyonları, SARSA'ya uygulanabilir [10].

2.1.3 R-Öğrenme

R-öğrenme, Schwartz tarafından, 1993 yılında önerilen ve ortalama ödülü dikkate alan bir PÖ algoritmasıdır. R-öğrenme, Q-öğrenme ile aynı Q-değerlerini güncellemek için mümkün olan en iyi eylemi göz önünde bulundurur, ancak ortalama ödül, aşağıdaki formül (2)'de gösterildiği gibi anlık ödülle değiştirilir. Denklem (3)'te, ρ , π politikası kapsamında karar süresi adımı başına beklenen ödülün yaklaşık değeridir ve u , karar süresi adım sayısıdır [11].

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha[r_{t+1} - \rho + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t)] \quad (2)$$

$$\rho = \sum_{t=1}^u \frac{r_t}{u} \quad (3)$$

2.1.4 SMART

Yarı Markov karar süreci problemlerinde, zincirdeki geçiş süreleri, sabit birim yerine genel dağılımlı rassal değişkenlerdir. Bu nedenle, bu tür problemlerde geçiş süreleri, tekleştirme süreciyle sabit birime dönüştürülerek, Q-öğrenme ve benzeri ödüllü öğrenme algoritmaları yardımıyla Markov karar süreci problemlerinin çözümü için kullanılabilir. Ancak, yarı Markov Karar Süreci (MKS) problemlerinin tam olarak MKS'ye dönüştürülmesi her zaman mümkün değildir. Ayrıca, tekleştirme süreci için geçiş olasılıklarının bilinmesi gerekmektedir. Literatürde yer alan SMART algoritması, yaklaşık optimal olarak yarı Markov karar sürecini, Markov karar süreci problemlerine dönüştürmeden çözebilen bir ödüllü öğrenme algoritmasıdır. Algoritmanın motivasyonu, (4)'te verilen Bellman'ın optimalite denkleminde kaynaklanmaktadır:

$$v(x) = \min_{a \in A(x)} [g(x, a) - \rho^* y(x, a) + \sum_{x' \in x} P(x'|x, a)v(x')] \quad (4)$$

2.1.5 Derin Q ağı

Derin Q ağı (DQA)'da Q-değerlerinin parametreleştirilmesiyle Q-fonksiyonuna yaklaşmak için bir sinir ağı uydurulur: $Q(s, a, \theta_i)$. Her k iterasyonun hedefi (5)'te tanımlanmıştır [12].

$$Y_{hedef} = r + \gamma \max_a Q(s', a'; \theta_i) \quad (5)$$

Ağı eğitmek için parametreler, kayıp işlevi ve bir yeniden oynatma arabelleği kullanılarak ayarlanır. Ağ, her bölümde $\langle s, a, s', r \rangle$ deneyimlerini bir yeniden oynatma arabelleği \mathcal{M} 'de depolar. Ağ eğitirken, bir mini-toplu deneyim tekrar oynatma arabelleği $(U(\mathcal{M}))'$ den eşit şekilde çekilir. Bir MKS yörüngesinin deneyimleri birbirine büyük ölçüde bağlı olduğundan, bu deneyimler üzerine eğitim, değişkenlik ve istikrarsızlık getirir. Tekrar oynatma arabelleğinde saklanan tüm önceki deneyimler üzerinde tekdüze örnekleme yoluyla, mini deneyim grubu, öğrenme sürecinin istikrarını artıran bağımsız ve aynı şekilde dağıtılmış bir küme haline gelir. Parametreler, kayıp fonksiyonunun stokastik gradyan inişiyle güncellenir. Kayıp işlevi, ağın beklenen değerini, gerçek değerle karşılaştırır ve karesi alınmış kaybın minimizasyonu, denklem (6) gibi tanımlanır [12].

$$L_i(\theta_i) = \mathbb{E}_{\langle s, a, s', r \rangle \sim U(\mathcal{M})} \left(\underbrace{r + \gamma \max_a Q(s', a'; \theta_i^-)}_{hedef} - Q(s, a; \theta_i) \right)^2 \quad (6)$$

DQA, "çalışan hedef" sorununu çözmek için hedef değerleri oluşturmak üzere ayrı bir hedef ağ tutar. Hedef değerlerini tahmin etmek ve ağırlıklarını güncellemek için tek bir ağ kullanılırsa, politikadaki salınımlar,

öğrenme sürecini istikrarsızlaştırır [13]. Her bölümde, politika ağının parametreleri, bellekteki deneyimler kullanılarak güncellenir. Her C yinelemede, hedef ağ, öğrenen ağdan güncellenen ağırlıkları alır [12].

2.1.6 İlişkisel pekiştirmeli öğrenme


İstatistiksel ilişkisel öğrenme ve muhakeme, belirsiz ilişkileri inceler ve varlıkların ve onların ilişkilerinin yapılandırılmış temsillerini, bunların nasıl oluşturulacağına ilişkin kurullarla manipüle eder. Tümevarımsal Mantık Programlama (TMP), belirsiz mantık kurallarını olumlu ve olumsuz örneklerden öğrenir. Olasılıksal, istatistiksel ilişkisel öğrenme ile yakından ilişkilidir. Olasılığa dayalı TMP, kural tabanlı öğrenmeyi, istatistiksel öğrenmeyle bütünleştirir ve TMP'nin yüksek karmaşıklığının üstesinden gelir. Grafik modeller, istatistiksel ilişkisel öğrenme için önemli yaklaşımlardır. Yapay sinir ağlarının bağlantıcılık, paralel dağıtılmış işleme ve sinirsel hesaplama gibi alternatif isimleri vardır. Sembolizm, matematik ve mantık tarafından tanımlanan, sembolleri ve kuralları olan resmi bir dille ilgilidir. Sinir ağları ile ilişkisel öğrenme ve akıl yürütme, bağlantıcılık ve sembolizmi bütünleştiren bir yaklaşımdır. İlişkisel pekiştirmeli öğrenme, bilgi temsili ve muhakeme için PÖ'yü istatistiksel ilişkisel öğrenme ile bütünleştirir ve PÖ'yü klasik yapay zekâ ile birleştirir [14].

2.1.7 Zamansal fark öğrenmesi

Zamansal Fark (ZF) öğrenmesi, pekiştirmeli öğrenmenin temel yöntemlerinden biridir ve dinamik programlama ile Monte Carlo yöntemlerinin bir kombinasyonunu temsil eder. Bu yöntem, ortamın modelini öğrenme gerektirmediği gibi, sonucu beklemeksizin diğer tahminlerden yardım alarak tahminleri güncelleyebilme özelliğine sahiptir. Bu yöntemin ilk aşaması, tahmin aşamasıdır, yani bir politika için değer fonksiyonunu tahmin etmektir. Ardından, kontrol aşamasına geçerek en iyi politikayı bulmaya çalışır. ZF öğrenmenin, ortamın modeline ihtiyaç duymadan çalışabilen bir yöntem olduğu görülmektedir. Bu yönü, dinamik programlamaya kıyasla en büyük artısıdır. Monte Carlo yöntemine kıyasla en önemli artısı, bölüm sonunu beklemek zorunda kalmadan tahmini güncellemesidir [7]. Zamansal fark öğrenme yöntemlerinin, yeterince küçük adım boyutu kullanılarak herhangi bir sabit politikadan, optimum politikaya yakınsadığı kanıtlanmıştır. Ayrıca, matematiksel yönden kanıtlanmasa da uygulamada, zamansal fark öğrenme yöntemlerinin çoğunlukla Monte Carlo yöntemlerinden daha hızlı bir şekilde yakınsadığı gözlenmiştir [7].

2.1.8 Aktör-Kritik

Aktör-kritik yöntemleri, yalnızca aktör ve yalnızca eleştirmen yöntemlerinin avantajlarını birleştirmeyi amaçlar. Yalnızca aktöre yönelik yöntemler gibi, aktör-kritik yöntemler de sürekli eylemler üretme yeteneğine sahipken, yalnızca aktöre yönelik yöntemlerin politika gradyanlarındaki büyük varyansa bir kritik eklenerek karşı konulur. Kritik 'in rolü, aktörün öngördüğü mevcut politikayı değerlendirmektir. Prensip olarak, bu değerlendirme, ZF, artık gradyanlar gibi yaygın olarak kullanılan herhangi bir politika değerlendirme yöntemiyle yapılabilir. Kritik, örnekleri kullanarak değer işlevine yaklaşır ve günceller. Değer işlevi, daha sonra aktörün, politika parametrelerini, performans iyileştirme yönünde güncellemek için kullanılır. Bunlar, yalnızca kritik yöntemlerin aksine, genellikle politika gradyan yöntemlerinin istenen yakınsama özelliklerini korur. Aktör-kritik yöntemlerde, politika, değer işlevinden doğrudan çıkarsanmaz. Bunun yerine, politika yalnızca küçük bir α_a adım boyutu kullanılarak politika gradyanı yönünde güncellenir; bu, değer fonksiyonundaki bir değişikliğin, politikada yalnızca küçük bir değişikliğe yol açacağı ve politikada daha az veya hiç salınım davranışına yol açmayacağı anlamına gelir. Şekil 2, bir aktör-kritik algoritmasının şematik yapısını göstermektedir [15].



Şekil 2. Aktör-kritik algoritmasına şematik genel bakış.
Kesikli çizgi, kritiğin aktörü ve kendisini güncellemekten sorumlu olduğunu gösterir.

Şekil 2’de görüldüğü gibi öğrenen ajan iki ayrı varlığa bölünmüştür: aktör (politika) ve eleştirmen (değer fonksiyonu). Aktör, yalnızca geçerli x durumu verildiğinde bir kontrol girişi u oluşturmaktan sorumludur. Eleştirmen, aldığı ödülleri işlemekten, yani değer fonksiyonu tahminini uyarlayarak mevcut politikanın kalitesini değerlendirmekten sorumludur. Eleştirmen tarafından bir dizi politika değerlendirme adımından sonra, aktör, eleştirmenden gelen bilgiler kullanılarak güncellenir. Burada açıklanan aktör-kritik algoritmaları için birleşik bir gösterim, aralarında daha kolay bir karşılaştırma yapılmasına izin verir. Ek olarak, çoğu algoritma, standart güncelleme kurallarının genel bir şablonuna uyarlanabilir. Aktör-kritik algoritmalarında veya bu konudaki diğer herhangi bir PÖ algoritmasında amaç, bazı durağan MKS verildiğinde mümkün olan en iyi politikayı bulmaktır. Bunun ön şartı, eleştirmenin belirli bir politikayı, doğru bir şekilde değerlendirebilmesidir. Başka bir deyişle, eleştirmenin amacı, o politika için Bellman denkleminde yaklaşık bir çözüm bulmaktır [15].

2.2 Eylem Seçimi

Pekiştirmeli öğrenmede ortaya çıkan zorluklardan biri, keşif ve sömürü arasındaki ödünleşimdir. Yüksek bir ödül elde etmek için, bir pekiştirmeli öğrenme ajanı, geçmişte denediği ve ödül üretmede etkili bulunduğu eylemleri tercih etmelidir. Ancak bu tür eylemleri keşfetmek için daha önce seçmediği eylemleri denemesi gerekir. Ajan, ödül elde etmek için zaten bildiklerini kullanmak zorundadır, ancak gelecekte daha iyi eylem seçimleri yapmak için de keşfetmek zorundadır. Buradaki ikilem ne keşif ne de sömürünün, görevde başarısız olmadan münhasıran takip edilemeyeceğidir [9]. Ajan, farklı eylemleri denemeli ve daha iyi olanları aşamalı olarak seçmelidir. Etkili bir öğrenme yöntemi oluşturmak için keşif ve sömürü arasındaki değiş tokuşun uygun şekilde kontrol edilmesi önemlidir. Yaygın olarak kullanılan üç eylem seçim yöntemi, greedy, ϵ -greedy ve softmax kısaca aşağıda açıklanmıştır. Ajan, olası eylemler arasından en iyisini seçmeye karar verirse, açgözlü bir eylem seçim stratejisi izlediğini söyleyebiliriz. Bununla birlikte, her zaman en iyi eylemi seçmek, eylem ödüllerinin varyansına bağlı olarak yetersiz performansa yol açabilir [16].

Bu açgözlü davranışa bir alternatif, ϵ -açgözlü seçim stratejisini izlemektir. Bu eylem seçim yöntemi, ajana çoğu zaman en iyi eylemini seçmesini, ancak bazen rastgele bir eylemi seçmesini söyler (mevcut s durumundaki her olası eylem a için eşit olasılıkla). Rastgele bir eylem seçme olasılığını, ϵ değeri belirler. ϵ -greedy, pekiştirmeli öğrenmede, keşif ve sömürüyü dengelemek için etkili ve popüler bir strateji olmasına rağmen, bir dezavantajı, keşifte tüm eylemler arasından eşit olarak seçim yapmasıdır [9]. Bu, görünen en kötü eylem ile aynı olasılıkla en iyiye yakın eylem arasında seçim yapabileceği anlamına gelir. Alternatiflerden biri, eylem olasılıklarını tahmini değerlerinin dereceli bir fonksiyonu olarak değiştirmektir; softmax eylem seçim stratejisinin yaptığı da budur. Açgözlü eylem yine de en yüksek olasılığa sahip olacaktır, ancak diğerleri değer tahminlerine göre sıralanır. Bu, m olası eylemden a eylemini seçme olasılığının, bu eylem seçim mekanizmasını kullanırken en sık kullanılan dağılım olan Boltzmann dağılımı tarafından verildiği anlamına gelir. Olasılık, denklem (7) ile hesaplanır.

$$\Pr(a) = \frac{e^{Q_t(a)/\tau}}{\sum_{b=1}^m e^{Q_t(b)/\tau}} \quad (7)$$

Denklem (7)'de τ , ajanın ne kadar açgözlü davranacağını kontrol eden, sıcaklık adı verilen pozitif bir parametredir, m , mevcut eylemlerin sayısını temsil eder ve $Q_t(a)$, t zaman adımıdaki a eyleminin tahminini temsil eder. Yüksek sıcaklıklar, eylemlerin tamamen (neredeyse) eşit olasılığa sahip olmasına neden olur. Düşük sıcaklıklar, değer tahminlerinde farklılık gösteren eylemler için seçim olasılığında daha büyük bir farka neden olur, başka bir deyişle, düşük sıcaklık değerleri, ajanın daha açgözlü davranmasına neden olur. Softmax eylem seçimi ile ε -greedy eylem seçimi arasındaki benzerlikleri fark etmek mümkündür, her iki yöntemin de ayarlanması gereken yalnızca bir parametresi vardır, ancak çözülmekte olan göreve bağlı olabileceğinden hangisinin daha iyi olabileceği açık değildir. Her iki yöntemin de zaman içinde parametrelerinin değerini (ε ve τ) düşürmesi mümkündür, bu, ajanların, öğrenme aşamasının başında daha fazlasını keşfedecekleri ve sonunda daha açgözlü hareket edecekleri anlamına gelir. Hangi eylem seçim stratejisinin daha iyi olduğunu belirlemek için çeşitli deneyler geliştirilmiştir. Deneyler, keşif stratejileri için farklı parametrelerin çok farklı sonuçlara yol açtığını göstermiştir. Çok az araştırma, öğrenme sürecinin sonunda yetersiz sonuçlara yol açarken, çok fazla araştırma, öğrenme sürecinde kötü performansa ve uzun öğrenme sürelerine yol açar. O halde en iyi ε seçimi, probleme bağlıdır [16].

2.3 Durum Tanımı

Durum tanımı, önemli bir konudur. Birçok problemde, durum uzayının büyük ve sürekli olması gibi zorluklar vardır. Bu zorluklarla başa çıkabilmek ve değer fonksiyonlarına yaklaşmak için farklı durum tanımlama stratejileri kullanılır. İlgili literatürde ele alınan stratejiler aşağıda verilmiştir.

1. *Tüm Durumlar*: Bu yöntemde, ortamın her bir durumu Q -tablosunda yer alır. Ancak bu yöntem yalnızca küçük ölçekli problemlere uygundur ve durumlar genellikle tek bir özellikle tanımlanır.
2. *Durum Toplama*: Durumlar, durum uzayını azaltmak için bir araya toplanır. Genellikle bir veya iki özellikle tanımlanan durumlar, önceden belirlenen aralıklara dayalı olarak kategorize edilir.
3. *Kümeleme*: Durumlar, bir dizi özellik tarafından tanımlanır ve benzerlik veya farklılık dikkate alınarak kümeler oluşturulur.
4. *Yapay Sinir Ağları*: İnsan beyninin nöral yapısından esinlenerek geliştirilen yapay sinir ağları, girdi verilerini, çıktı verileriyle eşleştiren ve genelleme yeteneği kazanan öğrenme teknikleridir.
5. *Vaka Tabanlı Akıl Yürütme*: Benzer problemlerin, benzer çözümleri olduğu fikrine dayanır. Ziyaret edilen durum-eylem çiftleri, bir vaka tabanında saklanır ve yeni bir durumla en benzer durumun eylemleri tahmin edilir.
6. *Regresyon*: İstatistiksel bir öğrenme tekniği olan regresyon, girdi değerlerine dayalı olarak çıktı değerlerini bulmayı amaçlayan bir fonksiyon bulma yöntemidir.
7. *Regresyon Ağacı*: Belirli bir karar ağacı türü olan regresyon ağacı, gerçek değerli değişkenleri işleyerek hedef değerleri tahmin etmeyi amaçlar.
8. *Gradyan İniş Yöntemi*: Durumlar, öznitelik vektörleriyle temsil edilir ve değer fonksiyonları, bu vektörlerin doğrusal bir kombinasyonu ile oluşturulur.

Bu stratejiler, durum uzayının boyutunu azaltma, benzer durumları gruplama ve tahmin etme gibi yöntemlerle, değer fonksiyonlarına yaklaşmayı kolaylaştırır. Ancak her bir stratejinin kendi avantajları ve zorlukları bulunmaktadır. Gelecekteki araştırmalar, bu stratejilerin etkinliğini ve farklı durum tanımlama yöntemlerinin karşılaştırılmasını daha da inceleyebilir ve çizelgeleme problemleri için daha iyi çözümler sunabilir.

3. İŞ ÇİZELGELEME PROBLEMİ

İşlerin, belirli hazırlık süreleri, işlem süreleri ve teslim zamanları olduğu ve bu işlerin belirli sayıda makinelerde işlendiği durumlarda, işlerin, optimize edilmiş bir sıralamasına ihtiyaç duyulmaktadır. Bu tür problemlere, iş sıralama veya iş çizelgeleme denir. Çizelgeleme problemlerinin çözümü için çeşitli teknikler ve yöntemler geliştirilmiştir. Simülasyon çalışmaları ve sezgisel yaklaşımlar, çizelgeleme problemlerinin geliştirilmesi ve uygulanmasında büyük fayda sağlamaktadır. Kullanılacak teknikler, problemin karmaşıklığına, model yapısına ve amaçlarına bağlı olarak değişiklik gösterir. Çizelgeleme

problemleri, işlerin geliş biçimine, makine sayısına, üretim şekline ve performans kriterine göre dört farklı şekilde sınıflandırılabilir. Çizelgeleme problemleri literatürde, $\alpha / \beta / \gamma$ üçlü notasyon ile tanımlanmaktadır. Bu notasyonlarda, α , makine çevresini ifade etmektedir. Diğer bir değişle çizelgeleme probleminin, akış tipi, atölye tipi, paralel makine vd. olduğunu ifade etmektedir. β notasyonu, işlem özelliklerini ifade etmektedir. Örneğin, beklemesiz olması, hazırlık süresinin olması, sıra bağımlı vd. olduğunu belirtmektedir. γ notasyonu da performans kriterini ifade etmektedir. Örneğin, maksimum tamamlanma zamanının minimize edilmesi, maksimum gecikmenin minimize edilmesi vd. gibi tanımlar [17].

İşlerin geliş biçimine göre sınıflandırıldığında, çizelgeleme problemleri statik ve dinamik olarak ikiye ayrılır. Statik durumda, tüm işler işlem alanında hazır durumdadır ve çizelgeleme süreci boyunca yeni işler eklenmez. Ayrıca işlerin ne zaman geldiği bilinmektedir. Dinamik durumda ise işlerin süresi ve geliş zamanı belirsizdir. İşler, sürekli olarak bir prosese göre gelir ve kuyuklar oluşabilir, bu nedenle sıralamada güncellemeler yapılması gerekmektedir. Dinamik durumlarda genel amaç, makine boş kalma süresini ve kuyukta bekleyen iş sayısını en aza indirmektir [18]. Çizelgeleme problemlerini, üretim tipine göre, akış tipi ve atölye tipi olarak iki kategori altında ele alabiliriz. Akış tipi çizelgeleme problemleri, birbirinden farklı m adet makine ve n adet iş'ten oluşmakta ve her bir iş, aynı sıra ile m farklı makinede işlem görmektedir [19]. Akış tipi çizelgeleme problemlerinde, esnek akış tipi, çok prosesli esnek akış tipi, beklemesiz akış tipi, bloklama kısıtlı akış tipi ve dağıtılmış akış tipi olmak üzere birçok versiyona sahiptir.

Esnek akış tipi çizelgeleme problemlerinde, n adet iş k aşamada aynı sıra ile işlem görmekte ve her bir aşamada özdeş m_k adet paralel makine bulunmaktadır. Çok prosesli, esnek akış tipi çizelgeleme problemi de esnek akış tipi çizelgeleme probleminin özel bir hali olup her aşamada makinelerde birden fazla proses gerçekleştirilir [20]. Beklemesiz akış tipi çizelgeleme problemlerinde, m adet makinede aynı sıra ile işlem gören n adet işin, makinelerde işlem görürken, ardışık iki makine arasında beklemesine müsaade edilmez. Makineler bekleyebilir fakat işlerin beklemesine müsaade edilmez [21]. Bloklama kısıtlı, akış tipi çizelgeleme problemlerinde, işler, aynı sıra ile makinede işlem görürken, bir makinede işlem gördükten sonra bir sonraki makine boş değil ise son işlem gördüğü makinede beklemek zorunda kalır. Bir sonraki makine boşaldığında, iş, işlem görmek üzere bir sonraki makineye geçer. İşin, bir sonraki makinede işlem görmek için beklemesinden dolayı geçen zaman, bloklama süresi olarak isimlendirilir [22]. Dağıtılmış, akış tipi çizelgeleme problemlerinde, n adet iş, F adet özdeş fabrikaya dağıtılarak m adet makine de aynı sıra ile işlem görmektedir [23].

Atölye tipi çizelgeleme problemi de birbirinden farklı n adet iş m adet makineden oluşmaktadır. İşlerin makinelerde işlem görme sırası, her bir işin rotasına bağlı olarak değişmektedir. Atölye tipi çizelgeleme problemi de esnek atölye tipi, açık atölye tipi çizelgeleme olmak üzere birçok versiyona sahiptir. Esnek atölye tipi çizelgeleme problemlerinde, n adet iş, c adet iş merkezinde, iş rotalarına göre işlem görmekte ve her bir iş merkezinde özdeş m_c adet paralel makine bulunmaktadır [24]. Açık atölye tipi çizelgeleme problemi, birbirinden farklı n adet iş, m adet makineden oluşmaktadır. İşlerin makinelerde işlem görmesi ile ilgili herhangi bir iş sırası ya da rota bulunmamaktadır [25]. Çizelgeleme problemlerini değerlendirirken performans kriterleri kullanılır. Bu kriterler, tamamlanma süreleri, teslim zamanları ve tesisin verimli kullanımı ile ilgilidir. Tek bir performans kriteri kullanılabilmesi gibi birden fazla kriter de kullanılabilir. Çizelgeleme problemlerinin çözümünde kullanılan tekniklerin değerlendirilmesinde performans kriterlerinin dikkate alınması önemlidir. Bu kriterler kısaca aşağıda açıklanmıştır.

1. Tamamlanma süresiyle ilgili performans kriterleri [26]:

- Maksimum tamamlanma zamanı,
- Ortalama tamamlanma zamanı,
- Ortalama akış süresi,
- Ortalama bekleme süresi.

2. Teslim zamanıyla ilgili performans kriterleri işletmeler için daha önemli ve zor çözümler gerektirebilir. Bu kriterler:

- Maksimum gecikme süresi,
- Geciken iş sayısı,
- Ortalama gecikme.

3. Tesisin verimli kullanılmasıyla ilgili performans kriterleri:

- Bekleyen iş sayısı,
- Tamamlanmamış iş sayısı,
- Makinelerin boş bekleme süresidir.

Çizelgeleme problemlerinin çözümünde, literatürde tek ve çok performans kriterleri kullanılmaktadır. Çok performans kriterli çizelgeleme problemlerinin çözümü, tek performans kriterli problemlerinin çözümünden daha zor dur, çünkü aynı anda tüm performans kriterlerinin optimize edilmesi mümkün olmayabilir. Bir performans kriterinin değerini optimize ederken diğer performans kriterinin değeri azalabilir [27].

4. LİTERATÜR ARAŞTIRMASI

Kayhan ve Yıldız [11], makine çizelgeleme problemlerinde, pekiştirmeli öğrenme uygulamaları ile ilgili 1995- 2020 yılları aralığını kapsayan bir literatür çalışması yapmışlardır. Bu çalışmada, literatürde ilk defa, pekiştirmeli öğrenme yöntemlerinin çizelgeleme problemlerinin çözümü üzerindeki etkisi, 2003-2023 yılları aralığında incelenmiştir. Araştırmada, “scholar.google.com” arama motoru yardımıyla, “Reinforcement Learning and scheduling” anahtar kelimeleri kullanılmıştır. Tarama sonucunda on dokuz bin yüz adet sonuç elde edilmiştir. Elde edilen sonuçlar, tekrar analiz edilerek, doğrudan makine çizelgeleme ile ilgili olan (tek makine, paralel makine, akış tipi, atölye tipi ve diğer makine çizelgeleme) 50 adet araştırma tespit edilmiş ve detaylı olarak incelenerek aşağıda sunulmuştur.

4.1 Tek Makine Çizelgeleme Problemleri

Wang ve Usher [28], tek makinedeki sevk kuralı seçim problemine, Q -öğrenme uygulayarak, makine ajanının önceden tanımlanmış sevk kurallarını en iyi şekilde öğrenmesini sağlamışlardır. Wang, Yang ve Zhang [29], kötüleşen etkilere sahip, çok durumlu tek makine sisteminde, üretim çizelgeleme ve esnek önleyici bakıma entegre bir optimizasyon problemini incelemişlerdir. Zaman temelli, esnek önleyici bakım ve koşul temelli, esnek önleyici bakım kullanarak, proaktif bir şekilde, makine arızalarıyla başa çıkmışlar ve üretim çizelgesi üzerinde iyileştirmeler yapmışlardır. Yang, Li ve Wang [30], bozulma süreçleri yaşayan, çok durumlu, tek makineli, üretim sistemleri için üretim çizelgelemenin entegre optimizasyon problemini ele almışlardır. İşleme ve bakım maliyetleri ile tamamlama ödülleri birlikte dikkate alarak, optimum üretim politikalarını belirlemek için çalışmışlardır. Deliktaş [31], aynı anda tamamlama süresi ve toplam gecikmenin minimize edilmesini gerektiren iki hedefi göz önünde bulundurarak, öğrenme etkisi ve serbest bırakma sürelerine sahip, tek makine çizelgeleme problemi önermiştir. Memetik algoritmalara dayalı çeşitli optimizasyon teknikleri kullanmış ve iki amaçlı problemin çözümü için farklı skalarizasyon yöntemlerini birleştirmiştir.

4.2 Paralel Makine Çizelgeleme Problemleri

Lopes Silva, Souza, Freitas Souza, Bazzan [32], optimizasyon için çok ajanlı bir çerçeve olan Metasezgisel için Çok Ajanlı Mimari (MÇAM) sunmuşlardır. Deneyler, ajanın öğrenme yeteneğinin, bireysel ve ekip çalışması açısından çözümlerin kalitesini doğrudan etkilediğini göstermiştir. Liangxun Guo [33], dinamik, özdeş olmayan paralel makine çizelgeleme problemini, makine hızı farklılıkları, belirsiz görev varış zamanı ve çoklu optimizasyon metrikleri ile karakterize ederek incelemiştir. Pekiştirmeli öğrenme yaklaşımı ile farklı hedefler ve tekrar tekrar eğitilen çok aşamalı bir öğrenme süreci kullanarak problemi çözmeyi önermiştir. Chien ve Lan [34], sıra bağımlı kurulum süresi ile bağımsız paralel makine çizelgeleme problemi için yeni bir ajan tabanlı yaklaşım geliştirmişlerdir. Çalışmalarında, derin pekiştirmeli öğrenme

ve hibrit genetik algoritmayı birleştirilerek bir planlama ajanını eğitmek için derin Q ağı (DQA) kullanmışlardır.

4.3 Akış Tipi Çizelgeleme Problemleri

Arviv, Stern ve Edan [35], özdeş iş ve makinelere sahip, iki robotlu bir akış tipi çizelgeleme problemini, dört farklı robot iş birliği seviyesi için tanımlamış ve değerlendirmişlerdir. Amaçları, farklı işlem sürelerine sahip makineler için maksimum tamamlanma zamanını minimize eden bir robot programı elde etmektir. Wang ve Tang [36], ayrık permütasyon akış tipi çizelgeleme problemini çözmek için, makine öğrenimi tabanlı çok amaçlı memetik algoritma önermişlerdir. Yöntemleri, her aşama için domine edilmemiş çözümleri depolayarak ayrı bir arşiv kullanıp yeni bir popülasyon güncelleme sunar. Ayrıca, önerdikleri yöntem adaptif çok amaçlı yerel arama geliştirmek için geçmiş verilerin analizini kullanır. Shao, Pi, Shao [37], aylak süresi olmayan, akış tipi çizelgeleme problemini, toplam gecikme kriteri ile çözmek için karma ayrık öğretim-öğrenme tabanlı meta-sezgisel algoritma önermişlerdir. Önerdikleri öğretim-öğrenme olgusunu, gerçek dünyada taklit etmek için olasılıksal modele dayalı, ayrık öğretim aşaması, hiyerarşik yapıya dayalı ayrık öğrenme aşaması ve pekiştirmeli öğrenme olmak üzere üç aşama sunmuşlardır. Han, Guo ve Su [38], hibrit akış tipi çizelgeleme problemini çözmek için pekiştirmeli öğrenme yöntemini incelemişlerdir. Pekiştirmeli öğrenmeyi, bir otomobil motoru fabrikasının metal işleme atölyesinde çizelgeleme için kullanmışlardır. Zhao vd. [39], maksimum montaj tamamlanma süresini en aza indirme hedefiyle, dağıtılmış montaj aylak süresi olmayan, akış tipi çizelgeleme problemini incelemişler, çözmek için su dalgası optimizasyon algoritmasını önermişlerdir. Chen vd. [40], çoklu makine iş birliği ile akış tipi çizelgeleme problemini ele almışlar ve maksimum tamamlama süresini ve toplam makine yükünü en aza indirme hedefleriyle pekiştirmeli öğrenmeye dayalı uyarlanabilir çok popülasyonlu gri kurt optimize edici geliştirmişlerdir. Pan vd. [41], maksimum tamamlanma süresini en aza indirme hedefiyle, permütasyon akış tipi çizelgeleme problemini çözmek için derin pekiştirmeli öğrenmeye dayalı bir optimizasyon algoritması önermişlerdir. Cai vd. [42], üretim, nakliye ve montajı içeren dağıtılmış, montaj hibrit akış tipi çizelgeleme problemine, Q -öğrenme ile yeni bir karışık kurbağa öğrenme algoritması önermişlerdir. Zhao, Hu, vd. [43], çok amaçlı, enerji açısından verimli, dağıtılmış montaj ve beklemesiz akış tipi çizelgeleme problemini çözmek için pekiştirmeli öğrenme güdümlü bir beyin fırtınası optimizasyon algoritması önermişlerdir. Problemin amaçları, maksimum montaj tamamlanma süresini (C_{max}) ve toplam enerji tüketimini en aza indirme ile dengeli kaynak tahsisini sağlamayı içermektedir. Zhao, Wang, vd. [44], sıra bağımlı kurulum sürelerine sahip, dağıtılmış, heterojen, beklemesiz akış tipi çizelgeleme problemini ele almışlardır. Fabrika konfigürasyonundaki ve nakliye süresindeki farklılıkları modelde dikkate alarak Q -öğrenmeli, yapay bir arı kolonisi algoritması önermişlerdir. Zhao, Jiang, vd. [45], sıra bağımlı kurulum süresi ile enerji verimli, dağıtılmış, beklemesiz bir akış tipi çizelgeleme problemini, maksimum tamamlanma zamanı ve toplam enerji tüketimini en aza indirmek için Q -öğrenmeye dayalı işbirlikçi bir meta-sezgisel algoritma kullanarak çözmüşlerdir. Yan vd. [46], dağıtılmış, permütasyon akış tipi çizelgeleme probleminin, esnek periyodik önleyici bakım ile entegre bir optimizasyonunu incelemişlerdir. Bu problemin çözümü için açgözlülük oranı azalan, derin Q ağ tabanlı bir çözüm çerçevesi tasarlamışlardır. Nahhas vd. [47], gerçek dünyadaki dört aşamalı bir hibrit akış tipi çizelgeleme problemini çözmek için ayrık olay simülasyon modeli ve derin pekiştirmeli öğrenme tekniklerine dayanan bir yaklaşım sunmuşlardır. He vd. [48], akış tipi çizelgeleme problemini optimize etmek için geliştirilmiş bir Q -öğrenme algoritması önermişlerdir. Maksimum tamamlanma zamanı, geri bildirim sinyali olarak kullanmışlar ve çevresel durum değişikliği süreci, iş seçme süreci olarak tanımlamışlardır. Algoritmanın verimliliğini, NEH sezgisel yöntemi ile birleştirilerek iş ekleme modu değiştirilerek artırmışlardır. Dong vd. [49], Permütasyon Akış Tipi Çizelgeleme Problemini (PATÇP) çözmek için kombinatorial optimizasyon ve derin öğrenme alanının yenilikçi bir kombinasyonunu önermişlerdir. Yöntemleri, politika ağı, aday işlerin dağılımını tahmin etmek için PATÇP'nin grafik temsilini ve işlerin sıra bilgilerini birleştirir. Yang ve Xu [50], gerçek zamanlı ve akıllı karar verme için derin pekiştirmeli öğrenmeyi kullanan, dinamik iş gelişleriyle, dağıtılmış permütasyon akış tipi çizelgeleme problemini ele almışlardır. Amaçları, tüm işlerin toplam gecikme maliyetini en aza indirmektir. Farklı üretim durumları için verimli eylemler sağlamak üzere farklı problemlere özel dağıtım

kuralları geliştirmişlerdir. Ying ve Lin [51], dağıtılmış, montaj, permütasyon akış tipi çizelgeleme problemini, ilişkisiz, montaj makinelerini ve sıra bağımlı kurulum sürelerini dikkate alacak şekilde incelemişlerdir. Bir karma tamsayılı doğrusal programlama modeli ve pekiştirmeli öğrenme yinelemeli, açgözlü algoritması olan bir meta-sezgisel algoritma, bu problemin çözüm süresini en aza indirmek için önermişlerdir.

4.4 Atölye Tipi Çizelgeleme Problemleri

Gabel ve Riedmiller [52], atölye çizelgeleme problemlerini, sıralı karar süreçleri olarak yorumlayarak, her kaynağa iş gönderme kararlarını diğer ajanlardan bağımsız olarak veren bir pekiştirmeli öğrenme algoritması kullanarak, deneme yanılma yoluyla, sevk etme davranışını geliştiren uyarlanabilir bir ajan önermişlerdir. Luo [53], dinamik üretim durumlarıyla başa çıkmak ve her bir yeniden çizelgeleme noktasında en uygun eylemi (yani sevkiyat kuralını) öğrenmek için derin Q -ağ geliştirmiştir. Aynı zamanda, bir işlemi seçmek ve bir işlem tamamlandığında veya yeni bir iş geldiğinde uygun bir makineye atamak için altı bileşik dağıtım kuralı önermiştir. Han ve Yang [54], 3B ayrık grafik gönderimine dayanan çalışmalarında, uçtan uca derin pekiştirmeli öğrenme çerçevesini önermişlerdir. Bu çerçevede, bir kodlayıcı ve bir kod çözücünden oluşan değiştirilmiş bir işaretçi ağı, seçilen çizelgeleme özelliklerine göre çizelgelenecek işlemleri kodlamak için benimsemişlerdir. Magalhaes vd. [55], derin Q -öğrenme kullanarak çift kaynak kısıtlı, esnek atölye tipi çizelgeleme problemini çözmek için dikkat mekanizmasına sahip bir kodlayıcı-kod çözücü sinir ağı mimarisi önermişlerdir. Bu özellik, ajanın belirli bir işlemi programda daha uygun bir konuma taşımasını ve tüm işlemlerin işlem süreleri gibi açık problem bilgilerini almasını mümkün kılar. Feng vd. [56], maksimum tamamlanma süresini amaç fonksiyonu olarak ele almış ve esnek atölye tipi çizelgeleme problemini çözmek için derin pekiştirmeli öğrenme algoritması önermişlerdir. Long vd. [57], yapay arı kolonisi algoritması ile yavaş yakınsama hızı ve yerel optimuma ulaşma problemlerini çözmek için, pekiştirmeli öğrenmeye dayalı geliştirilmiş kendi kendine öğrenen yapay arı kolonisi algoritması önermişlerdir. Li vd. [58], hedef olarak maksimum tamamlanma zamanı ve toplam makine iş yükünü optimize etmek için bulanık işlem süresine sahip, çok amaçlı bir esnek atölye tipi çizelgeleme problemi incelemişlerdir. Problemi çözmek için önerilen yöntem, üç kurallı bir başlangıç stratejisi kullanarak yüksek kaliteli bir başlangıç popülasyonu elde etmektedir. Lei vd. [59], büyük ölçekli, dinamik esnek atölye tipi çizelgeleme problemini, otomatik olarak farklı ölçeklere sahip bir dizi alt probleme bölmek için yüksek seviyeli bir katman tasarlamışlardır. Grafik sinir ağına dayalı bir katmanın politikası, bir iş operasyonunu programlamak için eğitilir ve çok katmanlı algılayıcıya dayalı başka bir politika, iş operasyonunu işlemesi için bir makine atamak üzere eğitilir. Chang vd. [60], dinamik esnek atölye tipi çizelgeleme problemini, erken ve geç kalma cezalarını en aza indirmek amacıyla rastgele iş gelişiyile çözmek için derin pekiştirmeli öğrenme önermişlerdir. Problemin ölçeğine göre yumuşak e-açgözlü davranış politikası tasarlamışlardır. Liu vd. [61], dinamik esnek atölye çizelgeleme problemini çözmek için hiyerarşik ve dağıtık bir mimari önermişlerdir. Çift derin Q -ağı algoritması, çizelgeleme ajanlarını eğitmek, üretim bilgileri ve çizelgeleme hedefleri arasındaki ilişkiyi yakalamak ve sürekli iş gelen esnek bir atölye için gerçek zamanlı çizelgeleme kararları almak için kullanmışlardır. Zhang vd. [62], esnek atölye tipi çizelgeleme için çoklu ajan grafikleriyle, derin pekiştirmeli öğrenmeye dayalı DeepMAG adlı bir model önermişlerdir. DeepMAG'in iki önemli katkısı vardır: (1) Derin pekiştirmeli öğrenme ve çok ajanlı pekiştirmeli öğrenmeyi arasındaki entegrasyon. (2) Bir ajan, bir işbirlikçi eylem gerçekleştirmek için komşu ajanlarıyla iş birliği yapmasıdır. Oh vd. [63], esnek atölye tipi çizelgeleme problemini, çok ajanlı olarak yüksek değişkenlikle modelleyerek, bağımsız öğrenenleri, örtük niceliksel ağ ile birleştiren çizelgeleme yöntemini önermişlerdir. Zeng vd. [64], minimum ön alan bilgisi ile ayrık grafikleri durumlar olarak ve bir dizi genel dağıtım kuralını eylem alanı olarak alan esnek bir hibrit çerçeve önermişlerdir. Dikkat mekanizması, durumların öznitelik çıkarımı için grafik temsili öğrenme modülü olarak kullanılır ve her bir durumu en uygun gönderme kuralına eşlemek için öncelikli yeniden oynatma ve gürültülü ağlara sahip çift düellolu derin Q -ağı kullanılır. Cunha vd. [65], makine öğrenimi tekniklerine dayalı atölye tipi çizelgeleme problemlerini çözmek için yenilikçi bir yaklaşım sunmuşlardır. Genel performanslarını iyileştirmek ve mevcut yaklaşımların sunduğu sınırlamaların üstesinden gelmek için pekiştirmeli öğrenmeyi, çizelgeleme

sistemlerine dahil eden yeni bir mimari sunmuşlardır. Khuntiyaporn vd. [66], çok amaçlı, esnek atölye tipi çizelgeleme problemini çözmeye odaklanmışlardır. Önerilen yöntem, Q -Öğrenme algoritmasına sahip bir pekiştirmeli modelidir. Du vd. [67], hem maksimum tamamlanma süresi hem de toplam elektrik fiyatını aynı anda optimize eden bir dağıtım algoritması ve derin Q -ağ tahminine yönelik, hibrit çok amaçlı bir optimizasyon algoritması önermişlerdir. İşlem sırası, makine ataması ve işleme hızı atamasının tümü, üç boyutlu bir çözüm gösterimi kullanılarak açıklanmıştır. Wang vd. [68], gerçekçi üretim ortamını simüle etmek için dinamik, çok amaçlı esnek atölye tipi çizelgeleme problemini ele almışlardır. İş ekleme, iş iptali, iş operasyonu değişikliği, makine ekleme, makine aleti değiştirme ve makine arızası dahil olmak üzere problemde altı dinamik olaya yer vermişlerdir. Araştırmalarında, en uzun iş işleme süresi (maksimum tamamlanma zamanı), ortalama makine kullanımı ve ortalama iş işleme gecikme oranı olmak üzere üç hedefi bir dizi kısıtla birlikte gerçekleştirmek için çözüm sunmuşlardır. Chen vd. [69], süreç kaynak öncelik senaryosu altında esnek atölye tip çizelgeleme problemi modellemiş ve minimum çizelgeleme süresi hedefe ulaşmak için derin pekiştirmeli öğrenmeye dayalı iki katmanlı bir kural çizelgeleme algoritması önermişlerdir. Luo vd. [70], yeni iş eklemeleri ve makine arızaları ile dinamik, kısmi beklemesiz çok amaçlı esnek atölye tipi çizelgeleme problemini incelemişler, hiyerarşik, çözümü için hiyerarşik, çok ajanlı, derin pekiştirmeli öğrenme tabanlı, gerçek zamanlı bir yöntem geliştirmişlerdir. Önerdikleri yöntem, farklı uzay-zamansal ölçeklerde çalışan, üç yakın politika optimizasyonu tabanlı ajan, yani objektif ajani, iş ajani ve makine ajani içerir. Zhou vd. [71], atölye tipi çizelgeleme problemleri için arama alanını azaltan bir OpenAI gym ortamı sunmuş ve çok ajanlı esnek atölye tipi problemler için performansla sahip sezgisel kılavuzlu bir Q -Öğrenme çözümü sunmuşlardır. Popper ve Ruskowski [72], esnek atölye tipi çizelgeleme problemlerini çözmek için derin pekiştirmeli öğrenmeye dayalı çok ajanlı bir sistem önermişlerdir.

4.5 Diğer Çizelgeleme Problemleri

Park vd. [73], pekiştirmeli öğrenme tabanlı, gerçek zamanlı bir çizelgeleyici olan ScheduleNet'i önermişlerdir. ScheduleNet'in karar verme prosedürü, ajan-görev grafiği ile çizelgeleme probleminin durumunu temsil etmeyi, düğüm gömmelerini ve ajanlar ve görevler arasındaki önemli ilişkisel bilgileri kullanmayı içerir. Yang ve Xu [50], derin pekiştirmeli öğrenmeyi kullanarak dinamik iş gelişi ile zeki çizelgeleme ve yeniden yapılandırmayı incelemişler ve akıllı üretimde, akıllı çizelgeleme ve yeniden yapılandırma sistem mimarisini önermişlerdir. Tek makine çizelgeleme problemleri, paralel makine çizelgeleme problemleri, akış tipi çizelgeleme problemleri, atölye tipi çizelgeleme problemleri ve diğer çizelgeleme problemleri başlıkları altında yer verilen makalelere dair yazar, yıl ve makale içeriği bilgilerinin yer aldığı liste Tablo 1'de sunulmuştur. Üretim sistemlerinde, makine çizelgeleme süreçlerinde, ortam dinamik (makine arızaları, işlerin rassal gelişi vd.) olduğu için bu ortama uyum sağlayacak, öğrenebilen, çözüm yöntemlerinin kullanılması kaçınılmazdır. Tablo 1'de görüleceği gibi pekiştirmeli ve/veya derin pekiştirmeli öğrenme yöntemlerinin meta sezgisel algoritmalarla ya da diğer sezgiseller ile dinamik ortamlardaki makine çizelgeleme problemlerinde kullanılması, dinamik çizelge oluşturma imkânı sağlamaktadır. Endüstri 4.0 ve 5.0'e geçiş sürecinde, makine çizelgeleme problemlerinin çözümünde, öğrenme tabanlı yöntemler yardımı ile dinamik çizelgeler sunan metotlar kullanılmak zorundadır.

Tablo 1. Literatürde incelenen makalelerin sınıflandırılması

Tek Makine Çizelgeleme Problemleri			
Yazar	Yıl	Makale İçeriği	
1	Wang ve Usher [28]	2005	Ajan tabanlı, üretim çizelgeleme de Q -öğrenme yöntemini, işlerin tek makineye sevk edilmesinde kullanmışlardır.
2	Wang vd. [29]	2021	Çok durumlu, tek makine sisteminde, esnek önleyici bakımı kullanarak proaktif bir şekilde, makine arızalarını azaltacak, üretim çizelgesi önermişlerdir.
3	Yang vd. [30]	2021	Tek makineli, çok durumlu üretim sisteminde, işleme ve bakım maliyetlerini birlikte dikkate alan pekiştirmeli bir öğrenme yöntemi önermişlerdir.
4	Deliktaş [31]	2022	Çok amaçlı, tek makine probleminde, öğrenme etkisini, serbest bırakma zamanı ile dikkate alan, kendini uyarlayan bir Memetik Algoritma geliştirmişlerdir.
Paralel Makine Çizelgeleme Problemleri			
Yazar	Yıl	Makale İçeriği	
1	Lopes vd. [32]	2019	Paralel makinelerde, rotalama ve çizelgeleme problemlerini çözmek için pekiştirmeli öğrenme tabanlı, çok ajanlı bir çerçeve sunmuşlardır.
2	Liangxun Guo [33]	2020	Dinamik, çok amaçlı, özdeş olmayan paralel makine çizelgeleme problemini, makine hızı farklılıkları, belirsiz görev varış zamanı metriklerine göre çok aşamalı, pekiştirmeli öğrenme yöntemi ile çözmüşlerdir.
3	Chien & Lan [34]	2021	Sıra bağımlı kurulum süresi ile bağımsız, paralel makine çizelgeleme problemini çözmek için derin pekiştirmeli öğrenme ve hibrit genetik algoritmayı birleştiren bir planlama ajanını eğitmek için derin Q ağı önermişlerdir.
Akış Tipi Çizelgeleme Problemleri			
Yazar	Yıl	Makale İçeriği	
1	Arviv vd. [35]	2016	Akış tipi çizelgeleme problemlerinde, iki robot ile iş transferi için işbirlikçi pekiştirmeli öğrenme yöntemi önermişlerdir.
2	Wang ve Tang [36]	2017	Memetik algoritma tabanlı makine öğrenmesi yöntemini, çok amaçlı, permütasyon akış tipi çizelgeleme probleminin çözümü için geliştirmişlerdir.
3	Shao vd. [37]	2018	Aylak süresi olmayan, akış tipi çizelgeleme problemini, toplam gecikme kriteri ile çözmek için karma ayırık öğretim-öğrenme tabanlı meta-sezgisel algoritma önermişlerdir. Algoritma üç aşamadan oluşmuştur.
4	Han vd. [38]	2019	Hibrit akış tipi çizelgeleme problemini çözmek için pekiştirmeli öğrenme yöntemini geliştirmişlerdir. Bir otomobil motoru fabrikasının metal işleme atölyesinde, çizelgeleme sürecinde kullanmışlardır.

5	Zhao vd. [39]	2021	Maksimum montaj tamamlanma süresi minimizasyonu performans kriterini dikkate alan, dağıtılmış, montaj aylak süresi olmayan, akış tipi çizelgeleme problemini çözmek için, pekiştirmeli öğrenme metodunu kullanan, su dalgası optimizasyon algoritması önermişlerdir.
6	Chen vd. [40]	2021	Çoklu makine iş birliği olan akış tipi çizelgeleme problemini, maksimum tamamlama süresini ve toplam makine yükünü en aza indirme performans kriterini dikkate alarak çözmek için pekiştirmeli öğrenmeyi kullanan çok popülasyonlu gri kurt optimizasyon algoritmasını geliştirmişlerdir.
7	Pan vd. [41]	2021	Maksimum tamamlanma süresi minimizasyonu performans kriterli, permütasyon akış tipi çizelgeleme problemini çözmek için derin pekiştirmeli öğrenmeye dayalı bir optimizasyon algoritması önermişlerdir.
8	Cai vd. [42]	2022	Üretim, sevkiyat ve montaj süreçlerinden oluşan, dağıtılmış, montaj hibrit akış tipi çizelgeleme problemini çözmek için Q -öğrenmeyi kullanan bir kurbağa algoritması geliştirmişlerdir.
9	Zhao vd. [43]	2022	Çok amaçlı, enerji etkinliği, dağıtılmış, montaj süreçli beklemesiz akış tipi çizelgeleme problemini çözmek için pekiştirmeli öğrenme güdümlü bir beyin fırtınası optimizasyon algoritması önermişlerdir.
10	Zhao vd. [44]	2022	Sıra bağımlı hazırlık sürelerine sahip, dağıtılmış, heterojen, beklemesiz akış tipi çizelgeleme problemini çözmek için Q -öğrenmeyi kullanan yapay bir arı kolonisi algoritması geliştirmişlerdir.
11	Zhao, Jiang vd. [45]	2022	Sıra bağımlı hazırlık süresi olan enerji verimli, dağıtılmış, beklemesiz bir akış tipi çizelgeleme problemini, tamamlanma süresi ve toplam enerji tüketimi minimizasyonu performans kriterli olarak çözmek için Q -öğrenmeye dayalı, işbirlikçi bir meta-sezgisel algoritma önermişlerdir.
12	Yan vd. [46]	2022	Dağıtılmış, permütasyon akış tipi çizelgeleme problemini, esnek periyodik önleyici bakım ile entegre şekilde çözmek için açgözlülük oranı azalan derin Q ağ tabanlı bir yöntem geliştirmişlerdir.
13	Nahhas vd. [47]	2022	Gerçek yaşamdaki dört aşamalı bir hibrit akış tipi çizelgeleme problemini çözmek için ayrık olay simülasyon modeli ve derin pekiştirmeli öğrenme tekniklerine dayanan bir metod sunmuşlardır.
14	He vd. [48]	2022	Akış tipi çizelgeleme problemini, tamamlanma süresi performans kriterine göre çözmek için bir Q -öğrenme algoritması önermişlerdir.
15	Dong vd. [49]	2022	Permütasyon akış tipi çizelgeleme problemini, geç iş minimizasyonu performans kriterli çözmek için derin pekiştirmeli bir öğrenme yaklaşımı geliştirmişlerdir.
16	Yang vd. [50]	2022	Gerçek zamanlı, akıllı karar verme için derin pekiştirmeli öğrenmeyi kullanan, dinamik iş gelişleriyle, dağıtılmış, permütasyon akış tipi çizelgeleme problemini çözmüşlerdir.
17	Ying & Lin [51]	2022	Dağıtılmış, montaj süreçli, permütasyon akış tipi çizelgeleme problemini, ilişkisiz montaj makinelerini ve sıra bağımlı kurulum sürelerini dikkate alacak şekilde çözmek için bir karma tamsayılı doğrusal programlama modeli ve pekiştirmeli öğrenmeyi kullanan yinelemeli açgözlü algoritma önermişlerdir.

			Atölye Tipi Çizelgeleme Problemleri
Yazar	Yıl	Makale İçeriği	
1	Gabel vd. [52]	2008	Atölye tipi çizelgeleme problemlerini, sıralı karar süreçleri olarak yorumlayıp, her kaynağa iş gönderme kararlarını, diğer ajanlardan bağımsız olarak veren ve bir pekiştirmeli öğrenme algoritması kullanarak davranışını geliştiren ajanlar önermişlerdir.

2	Luo [53]	2020	Araya yeni iş alınan, esnek atölye tip çizelgeleme problemlerini çözmek için derin pekiştirmeli öğrenme tabanlı dinamik çizelge sunmuşlardır.
3	Han & Yang [54]	2021	Esnek atölye tipi çizelgeleme problemlerinin çözümü için derin pekiştirmeli öğrenme tabanlı bir yöntem önermişlerdir.
4	Magalhaes vd. [55]	2021	Çift kaynak kısıtlı, esnek atölye tip çizelgeleme problemini çözmek için derin Q -öğrenme kullanan bir kodlayıcı-kod çözücü sinir ağı mimarisi geliştirmişlerdir.
5	Feng vd. [56]	2021	Maksimum tamamlanma süresi performans kriterli, esnek atölye tipi çizelgeleme problemini çözmek için derin pekiştirmeli öğrenme algoritması önermişlerdir.
6	Long vd. [57]	2022	Esnek atölye tipi çizelgeleme problemini çözmek için pekiştirmeli öğrenmeye dayalı kendi kendine öğrenen yapay arı kolonisi algoritması önermişlerdir.
7	Li vd. [58]	2022	İki amaçlı (maksimum tamamlanma zamanı ve toplam makine iş yükünü optimize edilmesi), bulanık esnek akış tipi çizelgeleme problemini çözmek için üç kurallı bir başlangıç stratejisi kullanan, pekiştirmeli öğrenme tabanlı bir yöntem önermişlerdir.
8	Lei vd. [59]	2022	Büyük ölçekli, dinamik esnek atölye tipi çizelgeleme problemini, otomatik olarak farklı ölçeklere sahip bir dizi alt probleme bölmek için yüksek seviyeli bir katman tasarlamışlardır. Bu problem için uçtan uca hiyerarşik pekiştirmeli öğrenme yöntemi sunmuşlardır.
9	Chang vd. [60]	2022	Dinamik, esnek atölye tipi çizelgeleme problemini, erken ve geç kalma cezalarını en aza indirmek amacıyla rastgele iş gelişimi çözmek için derin pekiştirmeli öğrenme kullanmışlardır.
10	Liu vd. [61]	2022	Esnek atölye tipi çizelgeleme için derin pekiştirmeli öğrenme ile gerçek zamanlı çizelgeleme kararları alan dinamik bir çizelge sunmuşlardır.
11	Zhang vd. [62]	2022	Esnek atölye tipi çizelgeleme için çoklu ajan grafikleriyle, derin pekiştirmeli öğrenmeye dayalı, DeepMAG adlı bir model önermişlerdir.
12	Oh vd. [63]	2022	Yüksek değişkenli, esnek atölye tipi çizelgeleme probleminin çözümü için çok ajanlı, bağımsız öğrenenleri, örtük niceliksel ağ ile birleştiren bir yöntem önermişlerdir.
13	Zeng vd. [64]	2022	Dinamik atölye tipi çizelgeleme problemi için pekiştirmeli öğrenme ve dikkat mekanizmasını kullanan, hibrit zekâ tabanlı yöntem geliştirmişlerdir.
14	Cunha vd. [65]	2021	Atölye tipi çizelgeleme problemlerini çözmek için makine öğrenimi tekniklerine dayalı, pekiştirmeli öğrenme yaklaşımını sunmuşlardır.
15	Khuntiyaporn vd.[66]	2021	Çok amaçlı, esnek atölye tipi çizelgeleme problemini çözmek için Q -Öğrenme algoritmasına sahip bir pekiştirmeli öğrenme modeli önermişlerdir.
16	Du vd. [67]	2022	Esnek atölye tipi çizelgeleme problemi için maksimum tamamlanma süresi ve toplam elektrik fiyatını aynı anda optimize eden bir dağıtım algoritmasını, derin Q -ağ tahmini ile sunmuşlardır.
17	Wang vd. [68]	2022	Belirsiz durumların meydana geldiği (iş ekleme, iş iptali, iş operasyonu değişikliği, makine ekleme, makine aleti değiştirme ve makine arızası) dinamik, çok amaçlı, esnek atölye tip çizelgeleme problemini çözmek için çok amaçlı pekiştirmeli öğrenme yöntemini önermişlerdir.
18	Chen vd. [69]	2022	Süreç kaynak öncelik senaryosu altında, esnek atölye tipi çizelgeleme problemini modellemişler ve minimum çizelgeleme süresi hedefine ulaşmak için derin pekiştirmeli öğrenmeye dayalı iki katmanlı bir kural çizelgeleme algoritması geliştirmişlerdir.

19	Luo vd. [70]	2022	Yeni iş eklemeleri ve makine arızaları ile dinamik, kısmi beklemesiz, çok amaçlı, esnek atölye tipi çizelgeleme problemini çözmek için hiyerarşik, çok ajanlı, derin pekiştirmeli, öğrenme tabanlı, gerçek zamanlı, çizelgeleme yöntemi geliştirmişlerdir.
20	Zhou vd. [71]	2022	Çok ajanlı, atölye tipi çizelgeleme problemleri için pekiştirmeli Q -Öğrenmeye dayalı bir çözüm sunmuşlardır.
21	Popper vd. [72]	2022	Esnek atölye tipi çizelgeleme problemlerini çözmek için derin pekiştirmeli öğrenmeye dayalı çok ajanlı bir sistem konsepti önermiştir.

Diğer Çizelgeleme Problemleri			
	Yazar	Yıl	Makale İçeriği
1	Park vd. [73]	2021	Pekiştirmeli öğrenme tabanlı gerçek zamanlı bir çizelgeleyici olan ScheduleNet'i önermiştir.
2	Kim & Lee [74]	1998	Heterojen makine çizelgeleme probleminin çözümü için genetik takviyeli öğrenme yaklaşımı önermişlerdir.
3	Kim vd. [75]	2020	Esnek bir akıllı üretim sisteminde dağıtılmış zeka için çok etmenli sistem ve güçlendirmeli öğrenme yaklaşımı geliştirmişlerdir.
4	Wang vd. [76]	2022	Bakım ile dağıtılmış, üç aşamalı, montaj çizelgeleme problemi için takviyeli öğrenmeye sahip, uyarlanabilir yapay arı kolonisi algoritması önermişlerdir.
5	Yang & Xu [50]	2022	Derin pekiştirmeli öğrenmeyi kullanarak dinamik iş gelişi ile zeki çizelgeleme ve yeniden yapılandırılmayı incelemiş ve akıllı üretimde akıllı çizelgeleme ve yeniden yapılandırma sistem mimarisi önermişlerdir.

4. SONUÇ VE ÖNERİLER

Pekiştirmeli öğrenme yöntemleri son yıllarda iş çizelgeleme problemlerinin çözümünde aktif olarak kullanılmaktadır. Bu çalışmada, ilk defa pekiştirmeli öğrenme yöntemlerinin çizelgeleme problemlerinin çözümü ile ilgili literatürde yapılan çalışmalar araştırılmıştır. Bu amaçla “scholar.google.com” arama motoru yardımıyla “Reinforcement Learning and scheduling” anahtar kelimeleri kullanılarak, 2003 ile 2023 yılları aralığında tarama yapılmış, tek makine, paralel makine, akış tipi, atölye tipi ve diğer makine çizelgeleme ile doğrudan ilgili 50 adet makale tespit edilmiş ve çalışmalar detaylı olarak incelenmiştir. Yapılan araştırmalar, pekiştirmeli öğrenme algoritmalarının önceden elde edilen bilgileri kullanarak beklenmeyen durumlara hızla uyum sağladığını ve bu şekilde çizelgeleme sürecini hızlandırdığını ortaya koymuştur. Bu özellik, pekiştirmeli öğrenme algoritmalarının gerçek dünya problemlerine daha uygulanabilir hale gelmesini sağlar. Pekiştirmeli öğrenmenin diğer yöntemlere kıyasla avantajları ve güçlü yönleri bulunmaktadır. Literatürde değinilen bu yönleri aşağıda belirtilmiştir.

Pekiştirmeli öğrenme algoritmaları, simülasyonlarla tam bilgiye ihtiyaç duymadan iyi bir şekilde öğrenir ve hızla optimuma yakınsar. Bazı meta sezgisel yöntemler, statik çizelgeleme problemlerinde iyi sonuçlar verir. Ancak bu yöntemler, sistemdeki ani değişikliklere hızlı bir şekilde uyum sağlayamazlar çünkü sistem değiştiğinde tüm programı yeniden oluştururlar. Pekiştirmeli öğrenme algoritmaları ise daha önce elde edilen bilgileri kullanarak çizelgelemeye sıfırdan başlamazlar. Bu nedenle, pekiştirmeli öğrenme yaklaşımı, ani değişikliklere kolayca tepki verebilir ve programı daha hızlı bir şekilde değiştirebilir. Gerçek üretim sistemlerinde makine arızası, işlerin rastgele gelişi, sipariş iptali gibi dinamik durumlar bulunur. Pekiştirmeli öğrenme, bu dinamik sistemi çevreden gelen geribildirimlerle öğrenir ve bu bilgileri yeni ve görülmemiş durumlara genelleme yeteneğine sahiptir. Bu özellikler, pekiştirmeli öğrenmenin uyarlanabilir, esnek ve genişletilebilir bir yaklaşım olmasını sağlar. Bu nedenle, gerçek üretim sistemleri için uygun bir yöntem olabilir. Sevk kuralları, iş sıralama problemlerinde pratik ve kullanışlıdır. Ancak hangi gönderim kuralının hangi durumda uygulanacağına karar vermek uzmanlık gerektirir. Pekiştirmeli öğrenme algoritmaları, gönderim kurallarını seçmek için uygulandığında, sistem durumuna bağlı olarak otomatik karar verme sağlar, karar verme süresini azaltır ve tam otomatik üretim sistemlerinde daha uygulanabilir hale gelir. Ayrıca, pekiştirmeli öğrenme algoritmaları sistemdeki daha fazla özelliği dikkate alabilir, farklı gönderim kuralları arasında geçiş yapabilir ve bunları uygun şekilde birleştirebilir. Bu özellikler, çok amaçlı problemlerde, pekiştirmeli öğrenme algoritmalarına tek gönderim kuralı seçim politikalarına karşı üstünlük sağlar.

Pekiştirmeli öğrenmenin avantajları ve güçlü yönlerinin yanı sıra pratikte uygulanması bazı zorluklar içermektedir. Literatürde değinilen bu yönleri aşağıda belirtilmiştir. Karmaşık, gerçek dünya problemlerinde pekiştirmeli öğrenmenin uygulanması, geniş ve sürekli durum uzaylarıyla başa çıkma zorluğunu beraberinde getirir. Durum uzayının doğru tasarımı ve durum özelliklerinin doğru seçimi, algoritmanın etkinliği ve ölçeklenebilirliği açısından önemlidir. Ödül sisteminin tasarımında kısıtlamalar ve katı kurallar bulunmamaktadır. Ödül sisteminin doğru şekilde tasarlanması, çok sayıda seçenek olduğundan dolayı zor olabilir. Özellikle çok amaçlı problemlerde, ödülün, sisteminin hedeflerin önem derecesine göre tasarlanması önemlidir. Ödül işlevi, her hedefi uygun şekilde temsil etmeli ve dengelemelidir. Pekiştirmeli öğrenmenin ölçeklenebilirliği, problemin tasarımıyla doğrudan ilişkilidir. Tüm durumların Q -tablosunda temsil edilmesi yalnızca küçük ölçekli problemlerde uygulanabilir ve ölçeklendirme zorluğuna yol açar. Ayrıca, problemdeki iş veya makine sayısına özgü durumların tasarımı, daha büyük ölçekli problemlere ölçeklendirmeyi zorlaştırır. Durum toplama veya fonksiyon yaklaşımı gibi yöntemler, bu sorunu çözmek için kullanılır. Problemin tasarımı ve uygun fonksiyon veya durum toplama seçimi, durum-eylem uzayının boyutunu problemin boyutundan bağımsız hale getirir.

Akış tipi, birden fazla üretim aşamasından oluşur ve her aşamada, bir çizelgeleme problemi ortaya çıkarır. Akış tipi çizelgeleme problemlerinde, bu sorunu çözmek için aynı iş sırasını uygulamak gibi yaklaşım kullanılabilir. Ancak, bu yaklaşımlar, algoritmanın sonuçlarını olumsuz etkileyebilir ve her aşamaya

uygulanan algoritma, yüksek boyutlu durum uzayına yol açar. Atölye tip çizelgeleme problemlerinde ise iş tiplerinin farklı rotaları bulunur, bu da bazı işlerin ilk aşamada işlenemeyebileceği anlamına gelir. Bu durumda, her aşamada bir karar verme problemi ortaya çıkarır ve algoritmanın uygulanması zorlaşır, yüksek boyutlu durum uzayı problemiyle karşılaşılır.

Karar verme önemli bir faktör olduğunda, pekiştirmeli öğrenme algoritmasının açıklanabilir olması karar vericiler için önem kazanır. Ancak, birçok makine öğrenimi algoritmasında olduğu gibi, pekiştirmeli öğrenme algoritmasının da açıklanabilir olması eksikliği bulunmaktadır. Ajanın eylemlerinin nedeni karar vericilere açık bir şekilde açıklanamaz. Özellikle, fonksiyon kullanılan büyük boyutlu problemlerde, bir eylemin diğerine tercih edilme nedenini açıklamak karmaşık hale gelir. Pekiştirmeli öğrenme algoritmaları optimum sonuçları garanti etmez.

Gelecekteki araştırmalar için öneriler aşağıda sunulmuştur:

- İncelenen problemi daha gerçekçi hale getirmek için gerçek üretim ortamındaki çizelgeleme problemlerinde sıklıkla karşılaşılan makine arızası, iş iptali, sıraya bağlı kurulum süresi ve öncelik kısıtlamalarına daha fazla yer verilebilir.
- Pekiştirmeli öğrenme algoritmalarının, çok amaçlı problemlere uygulanması derinlemesine analiz edilmelidir, çünkü gerçek hayattaki çizelgeleme problemleri genellikle birden fazla amaç içerir.
- Meta sezgisel teknikler, makine çizelgeleme problemlerinde önemli bir rol oynar ve özellikle büyük ölçekli statik problemlerde iyi sonuçlar verir. Pekiştirmeli öğrenme algoritmalarının performansı, meta sezgisel yöntemlerle karşılaştırılabilir ve algoritmanın üstün ve zayıf yönleri ortaya çıkarılabilir.
- Atölye çizelgeleme problemleri genellikle tamamlama süresi ve geç kalma kriterleriyle ilgilenen çalışmalara odaklanmıştır. Akış süresiyle ilgili kriterlerin incelenmesi gelecekteki araştırmalar için önemli olabilir. Ayrıca, iş gecikmesinin önemi bazen müşteri anlaşmalarına göre değişebilir, bu durumda ağırlıklı geç kalma kriterinin minimizasyonu önemli bir konu haline gelir. Bu nedenle, pekiştirmeli öğrenme algoritmasının gerçek hayattaki çizelgeleme problemlerine uygulanması için bu alanlar üzerinde daha fazla araştırma yapılabilir.
- Pekiştirmeli öğrenme algoritmasının etkinliğini, karşılaştırmalı problemler üzerinde analiz eden çalışmalar, genellikle küçük ölçekli statik problemlerle sınırlıdır. Pekiştirmeli öğrenme algoritmasının büyük ölçekli problemlerdeki etkinliğini araştırmak için daha fazla analiz yapılması gerekmektedir.
- Pekiştirmeli öğrenmenin performansını önemli ölçüde etkileyen öğrenme algoritması çeşitliliği üzerine yapılan çalışmalar sınırlıdır. Farklı öğrenme algoritmalarının performanslarını karşılaştırmak ve analiz etmek literatüre katkı sağlayabilir.

REFERANSLAR

- [1] Engin, O., Kahraman, C. & Yılmaz, M.K. (2009). A Scatter Search Method for Multiobjective Fuzzy Permutation Flow Shop Scheduling Problem: A Real-World Application. U.K. Chakraborty (Ed.): Computational Intelligence in Flow Shop and Job Shop Scheduling. SCI, 230, 169- 189. Springer-Verlag Berlin Heidelberg.
- [2] Engin, O., Yılmaz, M. K., Baysal, M. E & Sarucan, A. (2013). Solving Fuzzy Job Shop Scheduling Problems with Availability Constraints Using a Scatter Search Method. J. of Mult. -Valued Logic & Soft Computing, 21, 317- 334.
- [3] Engin, O., Özmete, A., İpek, S. & Karoğlu, Y.E. (2023). Çizelgeleme Problemlerinin Çözümünde Hibrit Biyocoğrafya Tabanlı Optimizasyon Algoritmasının Kullanımı. Harran Üniversitesi Mühendislik Dergisi, 8(1), 68-77. <https://doi.org/10.46578/humder.1256671>

- [4] Manzak, R., Engin, O. (2023). Akıllı Fabrikalarda Çizelgeleme Yöntemlerinin Analizi, Verimlilik Dergisi, 57, 4, 761- 774. <https://doi.org/10.51551/verimlilik.1136778>
- [5] Oppermann A. (2023). Self Learning AI-Agents Part I: Markov Decision Processes. [Erişim Tarihi: 01.11.2023] <https://towardsdatascience.com/self-learning-ai-agents-part-i-markov-decision-processes-baf6b8fc4c5f>
- [6] Thomas, G. (2009). Multi-Agent Reinforcement Learning Approaches for Distributed Job-Shop Scheduling Problems. Computer Science, 1-173.
- [7] Sutton, R. S., & Barto, A. G. (2015). Reinforcement Learning: An Introduction, Second edition, in progress, 1- 352, The MIT Press Cambridge, Massachusetts London, England.
- [8] Dietterich, T. G. (2000). Hierarchical Reinforcement Learning with the MAXQ Value Function Decomposition. Journal of Artificial Intelligence Research (C. 13).
- [9] Sutton, R. S., & Barto, A. G. (1998). Reinforcement learning: an introduction. MIT Press.
- [10] Wiering, M., Ch, M., Urgan, J. ", & Ch, S. J. (1998). Fast Online $Q(\lambda)$. Machine Learning (C. 33).
- [11] Kayhan, B. M., & Yildiz, G. (2023). Reinforcement learning applications to machine scheduling problems: a comprehensive literature review, Journal of Intelligent Manufacturing. 34, 905-929, Springer. <https://doi.org/10.1007/s10845-021-01847-3>
- [12] De Koning, M. C. T. C. (2020). Fleet Planning Under Demand Uncertainty A Reinforcement Learning Approach. <https://stmed.net/sites/default/files/airport-wallpapers-28369-9089125.jpg>.
- [13] Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., & Hassabis, D. (2015). Human-level control through deep reinforcement learning. Nature, 518(7540), 529-533. <https://doi.org/10.1038/nature14236>
- [14] Li, Y. (2018). Deep Reinforcement Learning. <http://arxiv.org/abs/1810.06339>
- [15] Grondman, I., Busoniu, L., Lopes, G. A. D., & Babuška, R. (2012). A survey of actor-critic reinforcement learning: Standard and natural policy gradients. İçinde IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews (C. 42, Sayı 6, ss. 1291-1307). <https://doi.org/10.1109/TSMCC.2012.2218595>
- [16] Martínez Jiménez, Y. (2012). A Generic Multi-Agent Reinforcement Learning Approach for Scheduling Problems. VUBPRESS Brussels University Press. www.vubpress.be
- [17] Başar, R., Engin, O. (2022). Beklemez Akış Tipi Çizelgeleme Problemlerinin Analizi ve Hibrit Dağınk Arama Yöntemi ile Çözümü, Çanakkale Onsekiz Mart University Journal of Advanced Research in Natural and Applied Sciences, 8 (2) 293- 308. <https://doi.org/10.28979/jarnas.936151>
- [18] Tanyaş, M., & Baskak, M. (2012). Üretim Planlama ve Kontrol. İrfan Yayıncılık.
- [19] Engin, O., Fıđlalı, A. (2002). Akış Tipi Çizelgeleme Problemlerinin Genetik Algoritma Yardımı ile Çözümünde Uygun Çaprazlama Operatörünün Belirlenmesi. Dođuş Üniversitesi Dergisi, 6, 27- 35.

- [20] Engin, O., Engin, B. (2018). Hybrid Flow Shop with Multiprocessor Task Scheduling Based on Earliness and Tardiness Penalties, *Journal of Enterprise Information Management*, 31, 6, 925- 936. <https://doi.org/10.1108/JEIM-04-2017-0051>
- [21] Engin, O., Günaydın, C. (2011). An Adaptive Learning Approach for No-Wait Flowshop Scheduling Problems to Minimize Makespan. *International Journal of Computational Intelligence Systems*, 4, 4, 521- 529.
- [22] Saç, İ., Engin, O. (2018). Bloklama Kısıtlı Akış Tipi Çizelgeleme Problemlerinin Maymun Arama Algoritması ile Çözümü. *Journal of Social and Humanities Science Research*, 5, 24, 1815- 1821.
- [23] Baysal, M. E., Sarucan, A., Büyüközkan, K. & Engin, O. (2022) Artificial Bee Colony Algorithm for Solving multi-objective Distributed Fuzzy Permutation Flow Shop Problem. *Journal of Intelligent & Fuzzy Systems*, 42, 439- 449. <https://doi.org/10.3233/JIFS-219202>
- [24] Külahlı, S., Engin, O., Koç, İ. (2021). A New Hybrid Scatter Search Method for Solving the Flexible Job Shop Scheduling Problems. *Celal Bayar University Journal of Science*, 17, 4, 347- 359. DOI: 10.18466/cbayarfbe.926756
- [25] Baysal, M. E., Durmaz, T., Sarucan, A., Engin, O. (2012). Açık Atölye Tipi Çizelgeleme Problemlerinin Paralel Kanguru Algoritması ile Çözümü. *Gazi Üniv. Müh. Mim. Fak. Der.* 27, 4, 855- 864.
- [26] Vollmann, T. E., Berry, W. L., Whybark, D. C., & Jacobs F.R. (2005). *Manufacturing Planning and Control for Supply Chain Management*. Mc Graw-Hill Book Companies Inc.
- [27] Kılıç, M. (2021). Bir Tekstil Firmasının Boyahane Bölümünde Paralel Makine Çizelgeleme Problemi İçin Bir Matematiksel Model Önerisi ve Farklı Çizelgeleme Kurallarının Karşılaştırılması. Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Konya
- [28] Wang, Y. C., & Usher, J. M. (2005). Application of reinforcement learning for agent-based production scheduling. *Engineering Applications of Artificial Intelligence*, 18(1), 73-82. <https://doi.org/10.1016/j.engappai.2004.08.018>
- [29] Wang, H., Yan, Q., & Zhang, S. (2021). Integrated scheduling and flexible maintenance in deteriorating multi-state single machine system using a reinforcement learning approach. *Advanced Engineering Informatics*, 49. <https://doi.org/10.1016/j.aei.2021.101339>
- [30] Yang, H., Li, W., & Wang, B. (2021). Joint optimization of preventive maintenance and production scheduling for multi-state production systems based on reinforcement learning. *Reliability Engineering and System Safety*, 214. <https://doi.org/10.1016/j.ress.2021.107713>
- [31] Deliktaş, D. (2022). Self-adaptive memetic algorithms for multi-objective single machine learning-effect scheduling problems with release times. *Flexible Services and Manufacturing Journal*, 34(3), 748-784. <https://doi.org/10.1007/s10696-021-09434-7>
- [32] Lopes Silva, M. A., de Souza, S. R., Freitas Souza, M. J., & Bazzan, A. L. C. (2019). A reinforcement learning-based multi-agent framework applied for solving routing and scheduling problems. *Expert Systems with Applications*, 131, 148-171. <https://doi.org/10.1016/j.eswa.2019.04.056>

- [33] Liangxun Guo, Z. Z. H. W. Q. (2020). Optimization of Dynamic Multi-Objective Non-Identical Parallel Machine Scheduling with Multi-Stage Reinforcement Learning. 2020 16th IEEE International Conference on Automation Science and Engineering (CASE). https://doi.org/10.0/Linux-x86_64
- [34] Chien, C. F., & Lan, Y. B. (2021). Agent-based approach integrating deep reinforcement learning and hybrid genetic algorithm for dynamic scheduling for Industry 3.5 smart production. *Computers and Industrial Engineering*, 162. <https://doi.org/10.1016/j.cie.2021.107782>
- [35] Arviv, K., Stern, H., & Edan, Y. (2016). Collaborative reinforcement learning for a two-robot job transfer flow-shop scheduling problem. *International Journal of Production Research*, 54(4), 1196-1209. <https://doi.org/10.1080/00207543.2015.1057297>
- [36] Wang, X., & Tang, L. (2017). A machine-learning based memetic algorithm for the multi-objective permutation flowshop scheduling problem. *Computers and Operations Research*, 79, 60-77. <https://doi.org/10.1016/j.cor.2016.10.003>
- [37] Shao, W., Pi, D., & Shao, Z. (2018). A hybrid discrete teaching-learning based meta-heuristic for solving no-idle flow shop scheduling problem with total tardiness criterion. *Computers and Operations Research*, 94, 89-105. <https://doi.org/10.1016/j.cor.2018.02.003>
- [38] Han, W., Guo, F., & Su, X. (2019). A reinforcement learning method for a hybrid flow-shop scheduling problem. *Algorithms*, 12(11). <https://doi.org/10.3390/a12110222>
- [39] Zhao, F., Zhang, L., Cao, J., & Tang, J. (2021). A cooperative water wave optimization algorithm with reinforcement learning for the distributed assembly no-idle flowshop scheduling problem. *Computers and Industrial Engineering*, 153. <https://doi.org/10.1016/j.cie.2020.107082>
- [40] Chen, R., Yang, B., Li, S., Wang, S., & Cheng, Q. (2021). An Effective Multi-population Grey Wolf Optimizer based on Reinforcement Learning for Flow Shop Scheduling Problem with Multi-machine Collaboration. *Computers and Industrial Engineering*, 162. <https://doi.org/10.1016/j.cie.2021.107738>
- [41] Pan, Z., Wang, L., Wang, J., & Lu, J. (2021). Deep Reinforcement Learning Based Optimization Algorithm for Permutation Flow-Shop Scheduling. *IEEE Transactions on Emerging Topics in Computational Intelligence*. <https://doi.org/10.1109/TETCI.2021.3098354>
- [42] Cai, J., Lei, D., Wang, J., & Wang, L. (2022). A novel shuffled frog-leaping algorithm with reinforcement learning for distributed assembly hybrid flow shop scheduling. *International Journal of Production Research*, 1-19. <https://doi.org/10.1080/00207543.2022.2031331>
- [43] Zhao, F., Hu, X., Wang, L., Xu, T., Zhu, N., & Jonrinaldi. (2022). A reinforcement learning-driven brain storm optimisation algorithm for multi-objective energy-efficient distributed assembly no-wait flow shop scheduling problem. *International Journal of Production Research*. <https://doi.org/10.1080/00207543.2022.2070786>
- [44] Zhao, F., Wang, Z., & Wang, L. (2022). A Reinforcement Learning Driven Artificial Bee Colony Algorithm for Distributed Heterogeneous No-Wait Flowshop Scheduling Problem With Sequence-Dependent Setup Times. *IEEE Transactions on Automation Science and Engineering*, 1-16. <https://doi.org/10.1109/tase.2022.3212786>

- [45] Zhao, F., Jiang, T., & Wang, L. (2022). A Reinforcement Learning Driven Cooperative Meta-Heuristic Algorithm for Energy-Efficient Distributed No-Wait Flow-Shop Scheduling with Sequence-Dependent Setup Time. *IEEE Transactions on Industrial Informatics*, 1-12. <https://doi.org/10.1109/tii.2022.3218645>
- [46] Yan, Q., Wu, W., & Wang, H. (2022). Deep Reinforcement Learning for Distributed Flow Shop Scheduling with Flexible Maintenance. *Machines*, 10(3). <https://doi.org/10.3390/machines10030210>
- [47] Nahhas, A., Kharitonov, A., & Turowski, K. (2022). Deep Reinforcement Learning Techniques for Solving Hybrid Flow Shop Scheduling Problems: Proximal Policy Optimization (PPO) and Asynchronous Advantage Actor-Critic (A3C). <https://hdl.handle.net/10125/79538>
- [48] He, Z., Wang, K., Li, H., Song, H., Lin, Z., Gao, K., & Sadollah, A. (2022). Improved Q-learning algorithm for solving permutation flow shop scheduling problems. *IET Collaborative Intelligent Manufacturing*, 4(1), 35-44. <https://doi.org/10.1049/cim2.12042>
- [49] Dong, Z., Ren, T., Weng, J., Qi, F., & Wang, X. (2022). Minimizing the Late Work of the Flow Shop Scheduling Problem with a Deep Reinforcement Learning Based Approach. *Applied Sciences (Switzerland)*, 12(5). <https://doi.org/10.3390/app12052366>
- [50] Yang, S., & Xu, Z. (2022). Intelligent scheduling and reconfiguration via deep reinforcement learning in smart manufacturing. *International Journal of Production Research*, 60(16), 4936-4953. <https://doi.org/10.1080/00207543.2021.1943037>
- [51] Ying, K. C., & Lin, S. W. (2022). Reinforcement learning iterated greedy algorithm for distributed assembly permutation flowshop scheduling problems. *Journal of Ambient Intelligence and Humanized Computing*. <https://doi.org/10.1007/s12652-022-04392-w>
- [52] Gabel, T., & Riedmiller, M. (2008). Adaptive Reactive Job Shop Scheduling with Reinforcement Learning Agents. *International Journal of Information Technology and Intelligent Computing*.
- [53] Luo, S. (2020). Dynamic scheduling for flexible job shop with new job insertions by deep reinforcement learning. *Applied Soft Computing Journal*, 91. <https://doi.org/10.1016/j.asoc.2020.106208>
- [54] Han, B. A., & Yang, J. J. (2021). A deep reinforcement learning based solution for flexible job shop scheduling problem. *International Journal of Simulation Modelling*, 20(2), 375-386. <https://doi.org/10.2507/IJSIMM20-2-CO7>
- [55] Magalhaes, R., Martins, M., Vieira, S., Santos, F., & Sousa, J. (2021). Encoder-Decoder Neural Network Architecture for solving Job Shop Scheduling Problems using Reinforcement Learning. 2021 IEEE Symposium Series on Computational Intelligence, SSCI 2021 - Proceedings. <https://doi.org/10.1109/SSCI50451.2021.9659849>
- [56] Feng, Y., Zhang, L., Yang, Z., Guo, Y., & Yang, D. (2021). Flexible Job Shop Scheduling Based on Deep Reinforcement Learning. *Proceedings of 2021 5th Asian Conference on Artificial Intelligence Technology, ACAIT 2021*, 660-666. <https://doi.org/10.1109/ACAIT53529.2021.9731322>
- [57] Long, X., Zhang, J., Qi, X., Xu, W., Jin, T., & Zhou, K. (2022). A self-learning artificial bee colony algorithm based on reinforcement learning for a flexible job-shop scheduling problem. *Concurrency and Computation: Practice and Experience*, 34(4). <https://doi.org/10.1002/cpe.6658>

- [58] Li, R., Gong, W., & Lu, C. (2022). A reinforcement learning based RMOEA/D for bi-objective fuzzy flexible job shop scheduling. *Expert Systems with Applications*, 203. <https://doi.org/10.1016/j.eswa.2022.117380>
- [59] Lei, K., Guo, P., Wang, Y., Xiong, J., & Zhao, W. (2022). An End-to-end Hierarchical Reinforcement Learning Framework for Large-scale Dynamic Flexible Job-shop Scheduling Problem. *Proceedings of the International Joint Conference on Neural Networks*, 2022-July. <https://doi.org/10.1109/IJCNN55064.2022.9892005>
- [60] Chang, J., Yu, D., Hu, Y., He, W., & Yu, H. (2022). Deep Reinforcement Learning for Dynamic Flexible Job Shop Scheduling with Random Job Arrival. *Processes*, 10(4). <https://doi.org/10.3390/pr10040760>
- [61] Liu, R., Piplani, R., & Toro, C. (2022). Deep reinforcement learning for dynamic scheduling of a flexible job shop. *International Journal of Production Research*, 60(13), 4049-4069. <https://doi.org/10.1080/00207543.2022.2058432>
- [62] Zhang, J.-D., He, Z., Chan, W.-H., & Chow, C.-Y. (2022). DeepMAG: Deep reinforcement learning with multi-agent graphs for flexible job shop scheduling. *Knowledge-Based Systems*, 110083. <https://doi.org/10.1016/j.knosys.2022.110083>
- [63] Oh, S. H., Cho, Y. I., & Woo, J. H. (2022). Distributional reinforcement learning with the independent learners for flexible job shop scheduling problem with high variability. *Journal of Computational Design and Engineering*, 9(4), 1157-1174. <https://doi.org/10.1093/jcde/qwac044>
- [64] Zeng, Y., Liao, Z., Dai, Y., Wang, R., Li, X., & Yuan, B. (2022). Hybrid intelligence for dynamic job-shop scheduling with deep reinforcement learning and attention mechanism. <http://arxiv.org/abs/2201.00548>
- [65] Cunha, B., Madureira, A., Fonseca, B., & Matos, J. (2021). Intelligent scheduling with reinforcement learning. *Applied Sciences (Switzerland)*, 11(8). <https://doi.org/10.3390/app11083710>
- [66] Khuntiyaporn, T., Songmuang, P., & Limprasert, W. (2021). The Multiple Objectives Flexible Jobshop Scheduling Using Reinforcement Learning. *16th International Joint Symposium on Artificial Intelligence and Natural Language Processing, iSAI-NLP 2021*. <https://doi.org/10.1109/iSAI-NLP54397.2021.9678152>
- [67] Du, Y., Li, J. qing, Chen, X. long, Duan, P. yong, & Pan, Q. ke. (2022). Knowledge-Based Reinforcement Learning and Estimation of Distribution Algorithm for Flexible Job Shop Scheduling Problem. *IEEE Transactions on Emerging Topics in Computational Intelligence*. <https://doi.org/10.1109/TETCI.2022.3145706>
- [68] Wang, H., Cheng, J., Liu, C., Zhang, Y., Hu, S., & Chen, L. (2022). Multi-objective reinforcement learning framework for dynamic flexible job shop scheduling problem with uncertain events. *Applied Soft Computing*, 109717. <https://doi.org/10.1016/j.asoc.2022.109717>
- [69] Chen, Z., Zhang, L., Wang, X., & Gu, P. (2022). Optimal Design of Flexible Job Shop Scheduling Under Resource Preemption Based on Deep Reinforcement Learning. *Complex System Modeling and Simulation*, 2(2), 174-185. <https://doi.org/10.23919/csms.2022.0007>
- [70] Luo, S., Zhang, L., & Fan, Y. (2022). Real-Time Scheduling for Dynamic Partial-No-Wait Multiobjective Flexible Job Shop by Deep Reinforcement Learning. *IEEE Transactions on Automation Science and Engineering*, 19(4), 3020-3038. <https://doi.org/10.1109/TASE.2021.3104716>

- [71] Zhou, H., Gu, B., & Jin, C. (2022). Reinforcement Learning Approach for Multi-Agent Flexible Scheduling Problems. <http://arxiv.org/abs/2210.03674>
- [72] Popper, J., & Ruskowski, M. (2022). Using Multi-Agent Deep Reinforcement Learning For Flexible Job Shop Scheduling Problems. *Procedia CIRP*, 112, 63-67. <https://doi.org/10.1016/j.procir.2022.09.039>
- [73] Park, J., Bakhtiyar, S., & Park, J. (2021). ScheduleNet: Learn to solve multi-agent scheduling problems with reinforcement learning. <http://arxiv.org/abs/2106.03051>
- [74] Kim, G.H., Lee, C.S.G. (1998). Genetic Reinforcement Learning Approach To The Heterogeneous Machine Scheduling Problem, *IEEE Transactions On Robotics And Automation*, 14, 6, 879- 893.
- [75] Kim, Y. G., Lee, S., Son, J., Bae, H., & Chung, B. Do. (2020). Multi-agent system and reinforcement learning approach for distributed intelligence in a flexible smart manufacturing system. *Journal of Manufacturing Systems*, 57, 440-450. <https://doi.org/10.1016/j.jmsy.2020.11.004>
- [76] Wang, J., Lei, D., & Cai, J. (2022). An adaptive artificial bee colony with reinforcement learning for distributed three-stage assembly scheduling with maintenance. *Applied Soft Computing*, 117. <https://doi.org/10.1016/j.asoc.2021.108371>

MIKE Programı ile Kars Çayının Taşkın Modellemesinin Yapılması

İrem Öztürkcü^{1*} , Mehmet Dikici¹ 

¹ İnşaat Mühendisliği Bölümü, Alanya Alaaddin Keykubat Üniversitesi, Antalya, Türkiye.

*235446004@ogr.alanya.edu.tr

mehmet.dikici@alanya.edu.tr

Özet

Günümüzde küresel ısınmanın etkisi ile beraberinde gelen kuraklık ve taşkın sorunları ciddi bir durum haline gelmiştir. Dünyada küresel ısınmadan kaynaklanan iklim değişikliklerinin yanı sıra, şehirlerdeki nüfus sayısındaki artış, insan faaliyetlerinin akarsu ve dere yataklarına müdahalesine ve bundan dolayı taşkın olaylarının artmasına sebebiyet vermektedir. Taşkın olaylarının yaşanması can ve mal kaybına neden olduğu gibi bir ülkenin ekonomik ve sosyal yapısına da bir o kadar zarar vermektedir. Dünya genelinde olduğu gibi ülkemizde de taşkın olaylarında yıllara hasıl olarak artış görülmekte ve bunun sonucunda birçok can ve mal kaybı yaşanmaktadır. Özellikle 2022 yılı içerisinde taşkın olaylarının geçmiş yıllara nazaran artış yaptığı istatistiksel verilerde de gözükmektedir. Bu sebeple akarsu ve dere yataklarında imara açık olan bölgelerde taşkın yayılım alanlarının belirlenmesi ve olası bir taşkın durumunda o bölge içerisinde oluşacak can ve mal kaybının en aza indirgenmesi oldukça önemlidir. Günümüzde taşkın olayının matematiksel olarak modellenmesi için açık kaynak kodlu ve/veya lisanslı birçok farklı program kullanılmaktadır. Bunlara örnek olarak; HEC-RAS ve MIKE gibi programlar verilebilir. Bu yazılımlar, taşkın hadisesinin analizi ve riskinin tespiti konusunda oldukça yarar sağlamaktadırlar. Bu çalışma, Aras Havzası içerisinde yer alan ve Kars/Merkez'den geçen Kars Çayını kapsamaktadır. Arc-GIS programı yardımı ile havzaya ait mevcut Dijital Yükseklik Modeli (DEM) verisine ulaşılmıştır. Elde edilen bu DEM verisi Global Mapper Programı kullanılarak MIKE Programı için uygun hale getirildikten sonra, Devlet Su İşleri Genel Müdürlüğü tarafından elde edilen hidrograf verilerinde bulunan 2, 5, 10, 25, 50, 100, 500, ve 1000 yıllık tekerrür sürelerine sahip debiler kullanılarak MIKE programı yardımı ile taşkın risk analizi yapılmış ve taşkın dağılımları incelenmiştir. Yapılan analiz sonucunda Kars Çayı civarında bulunan yerleşkelerin herhangi bir taşkın riski ile karşı karşıya olmadığı sonucuna varılmıştır.

Anahtar Kelimeler: Aras Havzası, Taşkın Modelleme, Taşkın Debisi, Taşkın Yayılım Haritası, Kars Çayı, MIKE.

Flood Modelling of Kars Stream with MIKE Program

Abstract

Nowadays, droughts and floods caused by the effects of global warming have become a serious situation. In addition to the climate changes caused by global warming, the increasing number of people living in cities is causing human activities to interfere with rivers and stream beds, leading to an increase in flood events. Floods not only cause loss of life and property but also damage the economic and social fabric of a country. As in the world in general, the number of flood events in our country has increased over the years, resulting in the loss of many lives and property. Floods are still occurring in our country, resulting in the loss of many lives and property. Especially in 2022, the statistical data shows that flood events have increased compared to previous years. For this reason, it is very important to determine the flood-spreading areas in the areas open to development in the river and stream beds and to minimize the loss of life and property in this region in the event of a possible flood. Today, many different open sources and/or licensed programs are used for the mathematical modeling of flood events. Examples of these programs are HEC-

RAS and MIKE, and this software is very useful in the analysis and risk assessment of flood events. This study covers the Kars Stream, which is located in the Aras Basin and passes through Kars/Center. The existing Digital Elevation Model (DEM) data of the basin was obtained with the help of the Arc GIS program. After this DEM data obtained was made suitable for the MIKE Program using the Global Mapper Program, the flow rates with 2, 5, 10, 25, 50-, 100-, 500-, and 1000-year recurrence periods found in the hydrograph data obtained by the General Directorate of State Hydraulic Works were used. Flood risk analysis was made and flood distributions were examined with the help of the MIKE program. As a result of the analysis, it was concluded that the settlements around the Kars Stream do not face any flood risk.

Keywords: Aras Basin, Flood Modelling, Flood Flow, Flood Inundation Map, Kars Stream, MIKE.

1. GİRİŞ

Günümüzde doğal afet olarak adlandırılan doğa olayları, insanlık için maddi ve manevi bir kayıp olarak görülse de doğanın kendini yenilemesi ve içerisinde bulunan döngüyü normal bir şekilde devam ettirebilmesi adına çok önemlidir. [1]. Bir afetin büyüklüğünün ölçütü, neden olduğu can kayıpları, sosyal ve ekonomik kayıplar, yaralanmalar ve maddi kayıplardır [2].

Türkiye içerisinde doğal afet denilince akla ilk deprem gelse de sel ve taşkın olayları da depremden sonra can ve mal kaybının en fazla olduğu bir diğer afet türüdür [22]. Taşkınlar ve seller ülkemizde olduğu gibi Dünyada da mal ve can kaybına sebep olup, insanların sosyal ve ekonomik hayatlarını da önemli ölçüde etkilemektedir [3]. Günümüzde meydana gelen taşkınların çeşitli sebepleri bulunmaktadır. Bunlardan başta gelen ilk sebep, kuvvetli yağmur sonucunda gerekli ve yeterli drenaj sisteminin olmamasıdır. Taşkın afetini sadece meteorolojik olarak değerlendirmek doğru bir yaklaşım değildir.

Devam eden sanayileşme ve çarpık kentleşme, akarsu ve dere yataklarında insan faaliyetlerinin artmasına sebebiyet vermektedir. Bundan dolayı akarsu ve dere içerisindeki hidrolojik denge bozulmaktadır. Dünyada ve ülkemizde hala devam etmekte olan dere kenarlarında yapılaşma durumu, dere yatağını kapatmakta veya kesitini daraltmakta ve bunun sonucunda yüksek bir yağış ile birlikte taşkın oluşumuna sebebiyet vermektedir [4]. Toplumumuzda başta eğitim kurumları olmak üzere afet yönetimi hakkında, halkı bilinçlendirecek çalışmalar yapmak oldukça önemlidir. Sistematik bir süreç olan afet yönetiminin ilk aşaması risk yönetimidir. Bu aşamada mal ve can kaybını en aza indirecek risk senaryoları hazırlanarak insanları afet anına hazırlamak elzemdir. Uzaktan algılama teknikleri ve Coğrafi Bilgi Sistemleri (CBS) gibi programlar kullanılarak yararlı olacak güncel harita ve grafiklerin elde edilmesi risk yönetimi aşamasında oldukça önemlidir [5-14]. Doğal dengenin gün geçtikçe giderek bozulması sonucunda son yıllarda etkisi arttıran taşkın olayları neredeyse tüm dünyayı etkileyecek duruma gelmiştir [6]. Ülkemizde 2022 yılı içerisinde meydana gelen taşkın ve sel olaylarının sayısı 450 olarak kaydedilmiştir [7]. Bu durum ülkemizde taşkın ve sel olaylarının sıklıkla yaşandığını göstermektedir. Taşkınlar, doğa olayları devam ettiği sürece varlığını sürdürecektir. Doğal bir döngünün parçası olan taşkınları engellemek mümkün değildir fakat yarattığı zararlı etkileri en aza indirmek mümkündür [8]. Bu etkileri en aza indirmek adına, teknolojinin de gelişmesiyle birlikte birçok bilgisayar programı geliştirilmiştir. Bu programlardan en yaygın olarak kullanılan HEC-RAS ve MIKE programları, hidrolik modeller ve taşkın risk analizleri gibi birçok konuda görsel bir modelleme sağlayarak taşkınların çözümlenmesinde kullanılmaktadır [9].

Literatürde taşkın modellemesi alanında 1 veya 2 boyutta çözümleme sağlayan birçok hidrolojik modelleme yöntemi bulunmaktadır. Bunlardan bazıları şunlardır; Dikici M. Ve Kazezyılmaz-Alhan M. (2018) [6] çalışmalarında Alibeyköy havzası için farklı pik debileri elde etme yöntemleri ile, MIKE 11 NAM programında 50 ve 100 yıllık yağış girdileri ile taşkın hidrografları ve bunun sonucunda 50 ve 100 yıllık taşkın debilerinin karşılaştırılması yapılmıştır. Özcan O. (2017) [1] çalışmasında Ayamama Deresinde çok kriterli karar verme ve HEC-RAS programıyla hidrolojik modelleme yöntemlerini karşılaştırmıştır. Gülbaz S. (2019) çalışmasında WMS, HEC-HMS, HEC-RAS bilgisayar programları ile Türkköse Deresi'nde oluşabilecek taşkınların analizini yapmış ve bunun sonucunda yerleşim bölgesinde taşkından etkilenen alanlar olduğunu tespit etmiştir. Demir F. (2014) [2] çalışmasında Aşağı Sakarya Nehrinde 2,5,10,100,200, 500 yıllık tekerrürlü taşkın debileri kullanılarak, çalışma alanı içerisinde oluşan taşkın yayılımlarını ve risk altında kalan bölgeleri MIKE 11 programı ile göstermiştir. Tektaş Y. ve Polat N (2021) [8] çalışmalarında

Diyarbakır ili sınırları içerisinde bulunan Çakmak Deresi üzerinde HEC-RAS programı ile 1 ve 2 boyutlu hidrolik modelleme oluşturularak $Q500 \text{ m}^3/\text{s}$ debiyi geçirememekte ve bunun sonucunda yerleşim yerleri, tarım alanları ve karayolu gibi birçok alanda taşkın olacağı sonucuna elde edilmiştir. Kaya Ç.M. (2021) [13] çalışmasında Fol Deresi üzerinde HEC-RAS programını kullanarak 1 ve 2 boyutlu hidrolojik modelleri karşılaştırmış bunun sonucunda 1 boyutlu modellerin daha tutarlı sonuçlar ürettiğini tespit etmişlerdir. Ertürk E. Ve Kaya N. (2019) [21] Çalışmalarında Trabzon ili Vakfıkebir ilçesi Kirazlı Deresi'nde HEC-RAS programı ile 1 ve 2 boyutlu hidrolik modelleme yaparak taşkın tekerrür debilerine karşılık gelen su seviyeleri ve taşkın risk dağılımlarını incelemişlerdir. Bunun sonucunda taşkın tehlikesinin olduğu alanlarda ıslah tesislerinin revize edilmesi önleyici tedbirlerin alınması gerektiğini belirlemişlerdir. Demir V. ve Keskin A. Ü. (2022) [20] çalışmalarında Samsun, Mert Irmağı üzerinde HEC-RAS ve FLO-2D programlarını kullanarak 50, 100, 500, ve 1000 yıllık tekerrür debileri için elde edilen model sonuçları doğrultusunda çalışma alanı içerisinde yüksek tehlike seviyesinde taşkın olacağı tespit edilmiştir ve bu sonuç doğrultusunda çeşitli önerilerde bulunulmuştur. Mahnamfar F., Moradi Y. A. ve Ağırlioğlu, N. (2018) [19] çalışmaların da Göksu Deresi'nde oluşacak taşkın risk haritaları 2 boyutlu MIKE 21 programı kullanılarak modellenmiş ve 4 farklı senaryo için taşkın yayılım analizleri yapılmıştır.

Bu çalışma kapsamında, MIKE programı kullanılarak Aras Havzası içerisinde yer alan ve Kars/Merkez'den geçen Kars Çayı'nın hidrolojik modeli oluşturulmuştur. Kars Çayı'nın herhangi bir taşkın anında su altında kalma olasılığı olan alanlar, oluşabilecek can ve mal kayıplarının engellenmesi hedeflenmiştir. Bu amaçla MIKE ve Coğrafi Bilgi Sistemi (CBS) programları kullanılmıştır. Model oluşturulurken CBS programları ile havzaya ait coğrafi bilgiler, MIKE programı ile 2, 5, 10, 25, 50, 100, 500, ve 1000 yıllık tekerrür sürelerine sahip debiler kullanılarak hidrolojik model oluşturulmuş ve Kars Çayı'ndaki akış modellenmiştir. Bunun sonucunda Kars Çayı etrafında bulunan yerleşim alanlarının taşkın risk analizi incelenmiştir.

2. MATERYAL VE METOD

2.1 CBS ve MIKE

Bu çalışmada CBS ve MIKE programları kullanılmıştır. Coğrafi Bilgi Sistemi, verilerin konumsal olarak işlenmesi ve bu verilerin model sonuçlarının sunulması önemlidir. Teknolojinin ilerlemesi ile birlikte Coğrafi Bilgi Sistemlerinin değişik disiplinlerde kullanımı da yaygınlaşmıştır. Coğrafi Bilgi Sistemleri Dünyada yaşanan doğal afetlerin çözümlenmesinde oldukça katkı sağlamaktadır. Ülkemizde afetin yıkıcı etkilerini geçmiş ve günümüzde birçok şekilde görmüş bulunmaktayız [24]. Bu çalışmada CBS programlarından biri olan ArcGIS programı kullanılarak oluşturulan Kars Çayının çalışma alanının dere kesitleri Devlet Su İşleri Genel Müdürlüğünden alınmış olup, taşkın yatağının topografik verisi NASA DEM Elevation Data (1-arc second Resolution SRTM / ASTER DEM)'dan alınmıştır. DSİ'den temin edilen harita ile NASA DEM Elevation Data (1-arc second Resolution SRTM / ASTER DEM)'dan alınan iki harita Global Mapper programı kullanılarak birbiri üzerine oturtulmuş ve sonucunda çalışma alanının MIKE programında kullanılacak formatına ulaşılmıştır.

MIKE programı su yönetimi alanında su modelleme ve simülasyon gibi konularda yaygın bir programdır. Bu çalışma kapsamında MIKE ZERO ile çalışma alanının memba ve mansap sınır şartları oluşturulmuştur. MIKE 21 ile memba ve mansap sınır şartları parametreleri, Manning katsayısı, 2B model kabulleri ve model hesap adım süresi değerleri girilerek akış modeli oluşturulmuş ve çalışma alanı taşkın analizi için hazır hale getirilmiştir.

2.2 Çalışma Alanı: Aras Havzası- Kars Çayı

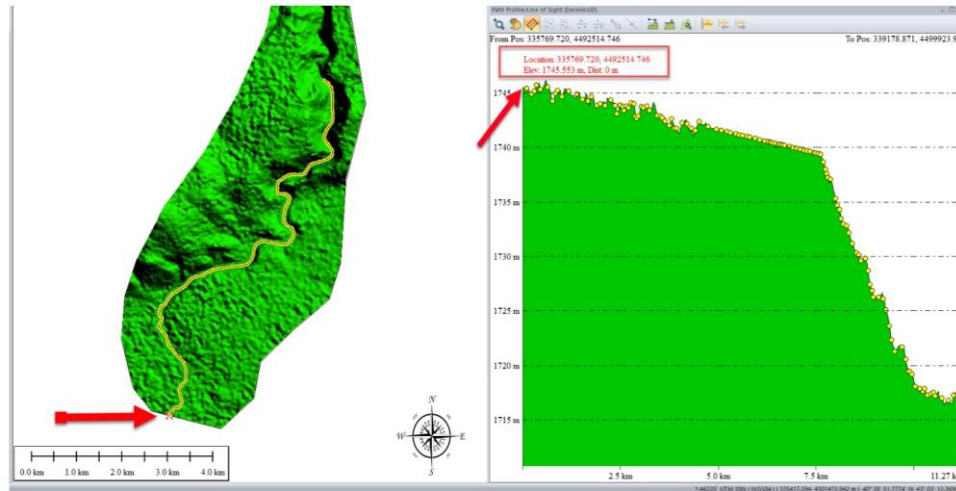
Aras havzasında; Iğdır Ovası, Kars Ovası, Göle ovası, Büyük Sütüce ovası, Hasköy ovası, Çıldır ovası, Ardahan platosu, Çıldır gölü, Aktaş gölü yer almaktadır (Şekil 1). Aras havzasında bulunan Kars çayı bulunduğu iklim sebebiyle hava sıcaklığının -35 derecelere kadar düşmesinden kaynaklı kışın donma sorunu ile karşılaşmaktadır (Şekil 2). Aras havzası ülkemiz içerisinde bulunan 25 havzadan birisidir. Kuzeydoğuda yer alan Aras havzası içerisinde Iğdır, Van, Kars, Erzurum, Ağrı, Ardahan ve Artvin illeri yer almaktadır. Havzanın toplam yüzölçümü 28.114 km^2 , yıllık ortalama yağış değeri $432,4 \text{ mm}$ 'dir [3].

Aras havzası bulunduğu konum itibari ile engebeli ve dağlık bir araziye sahiptir. Bahar ayında havalarda aniden ısınmasından dolayı çay içerisinde donan su bir anda çözülmekte ve taşkına sebebiyet vermektedir. Son 15 yıl içerisinde Kars Çayı civarında bulunan yerleşim yerleri yaz ayı içerisinde taşkın tehlikesi ile karşı karşıyadır. Taşkından çoğunlukla civar köylerde bulunan hayvanlar zarar görmüştür [8].


4-7 Mart 2004 tarihlerinde ülkemiz genelinde ani mevsim geçişlerinden kaynaklanan kar-buz erimelerinden kaynaklı birçok taşkın yaşanmıştır. Aynı bölge içerisinde 2009-2010-2012-2017-2019 yıllarında da birçok taşkın meydana geldiği kayıtlara geçmiştir. Bu sonuçlar doğrultusunda Kars çayında meydana gelen taşkınların öncelik olarak halk ve bölge içerisindeki tarımsal alan ve hayvanları olumsuz etkilediği görülmüştür [10].

2.3 Model Oluşturulması

MIKE programına geçilmeden önce çalışma alanının da uygun düzenlenmelerin yapılması gerekmektedir. Kars Çayının çalışma alanının dere kesitleri Devlet Su İşleri Genel Müdürlüğünden alınmış olup, taşkın yatağının topografik verisi NASA DEM Elevation Data (1-arc second Resolution SRTM / ASTER DEM)'dan alınmıştır. DSİ'den temin edilen harita ile NASA DEM Elevation Data (1-arc second Resolution SRTM / ASTER DEM)'dan alınan iki harita Global Mapper programı kullanılarak birbiri üzerine oturtulmuş ve sonucunda çalışma alanının MIKE programında kullanılacak formatına ulaşılmıştır. Şekil 3 ve Şekil 4'te sağ tarafta nehir aksının boy kesiti, memba ve mansap kotları verilmiştir.



Şekil 3. Kars Çayı'nın topografik durumu ve akarsu memba boy kesiti



Şekil 4. Kars Çayı Havzası'nın topografik durumu ve akarsu mansap boy kesiti

Öncelikle MIKE programı üzerinden yeni bir proje dosyası oluşturulur. Daha sonra ArcGIS programı kullanılarak elde edilmiş olan DEM verisinin programda gösterilmesi ve sınır değerlerinin belirlenmesi için MIKE programı 'MIKE ZERO' bölümünden çalışma alanının ağ yapısı oluşturulup (MESH) çalışma alanının havza girişi ve çıkışı sınır şartları belirlenmiştir. MIKE programındaki üçgen meshler alansal değer tanımlamasıyla oluşturulmaktadır. Çalışma alanında oluşturulan ızgara alanı 625 m²'dir. Programın bu kısmındaki amaç, oluşturmuş olan havzanın sınır değerlerine uygun hidrograflar girilerek 2 boyutta oluşacak taşkın yayılım haritalarına ulaşmaktır (Şekil 6). Bunun için öncelikle MIKE 21'de bir Akış Modeli oluşturulması gerekir. Bunun sonucunda zamana bağlı taşkın yayılım ve maksimum taşkın yayılım haritaları elde edilecektir. Mamba sınır şartı olarak program içerisinde "specified discharge" olarak tekerrür hidrografları tanımlanmıştır. Mansap sınır şartı olarak ise programdaki "free outflow" sınır şartı seçilmiştir MIKE Manning Pürüzlülük Katsayısı 0,032 alınmış ve (Taşkın kanalı-kısa çim) çalışma alanının her bölgesinde aynı Manning katsayısı kullanılmıştır [23]. 2B modelleme Tam St. Venant (Shallow water equations) Sığ Su Denklemleri kabulleri ile oluşturulmuştur. 2 boyutlu Sığ Akım Denklemleri, denklem (1), (2), (3)'de verilmektedir. Model hesap adım süresi 1 saniye alınmıştır.

$$\frac{\partial h}{\partial t} + \frac{\partial(uh)}{\partial x} + \frac{\partial(vh)}{\partial y} = 0 \quad (1)$$

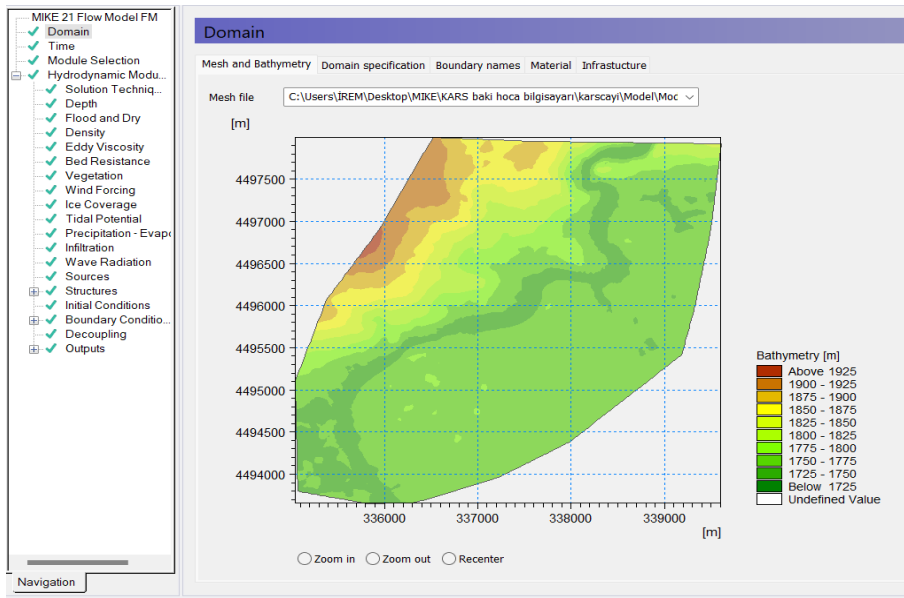
$$\frac{\partial(uh)}{\partial t} + \frac{\partial(u^2h + \frac{1}{2}gh^2)}{\partial x} + \frac{\partial(uvh)}{\partial y} = -gh\left(\frac{\partial b}{\partial x} + s_{fx}\right) \quad (2)$$

$$\frac{\partial(vh)}{\partial t} + \frac{\partial(uvh)}{\partial x} + \frac{\partial(v^2h + \frac{1}{2}gh^2)}{\partial y} = -gh\left(\frac{\partial b}{\partial y} + s_{fy}\right) \quad (3)$$

Burada u ve v sırasıyla x-y yönlerindeki hız bileşenlerini, h su derinliğini, b taban yüksekliğini, s_{fx} (4) ve s_{fy} (5) x-y yönlerindeki sürtünme katsayılarını ve g yerçekimi katsayılarını temsil etmektedir [25]

$$s_{fy} = \frac{n^2 v \sqrt{u^2 + v^2}}{h^{\frac{4}{3}}} \quad (4)$$

$$s_{fx} = \frac{n^2 u \sqrt{u^2 + v^2}}{h^{\frac{4}{3}}} \quad (5)$$



Şekil 6. MIKE 21 ile akış modelinin oluşturulması

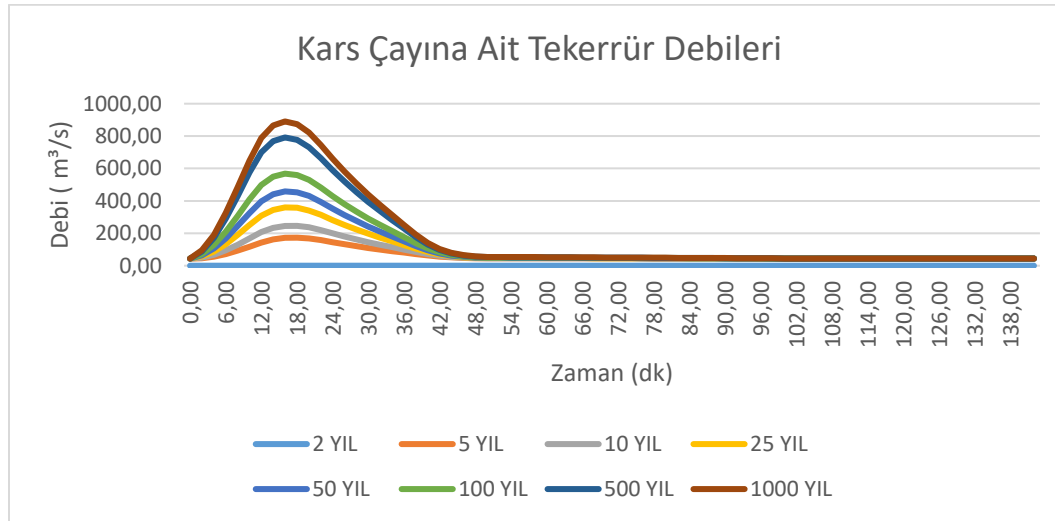
Tablo 1. 2B model kabulü ve çözüm tekniklerine ait parametreler

ÇÖZÜM TEKNİKLERİ	
Sığ Su Denklemleri	Zaman Entegrasyonu: Yüksek mertebeden
	Yer Ayrışması: Yüksek mertebeden
	Minimum Zaman Adımı: 0.01 (sn)
	Maksimum Zaman Adımı: 1 (sn)
	Kritik CFL Numarası: 0.8
Taşıma Denklemleri	Minimum Zaman Adımı: 0.01 (sn)
	Maksimum Zaman Adımı: 1 (sn)
	Kritik CFL Numarası: 0.8
Sayısal Parametreler	Riemann Faktörü: 1
	Riemann Çözücü Türü: HLLC

3. BULGULAR

3.1 Tekerrür Debileri

Bu çalışmada Kars Meteoroloji Bölge Müdürlüğünden ulaşılmış 2 dakikalık periyot ve yıllara göre taşkın debileri gösterilmektedir. Öncelikle programın 'MIKE ZERO' bölümünden 'Times Series' sekmesi açılır ve hidrograflar oluşturulur. (Şekil 7)



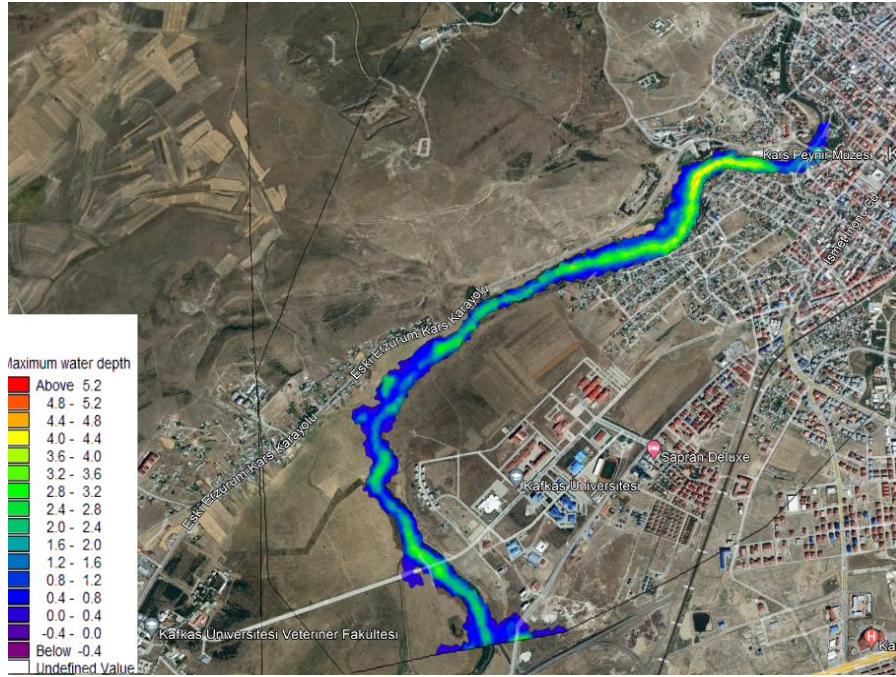
Şekil 7. Kars Çayı hidrograf değerlerinin grafik ile gösterimi

3.2 MIKE to Google Earth

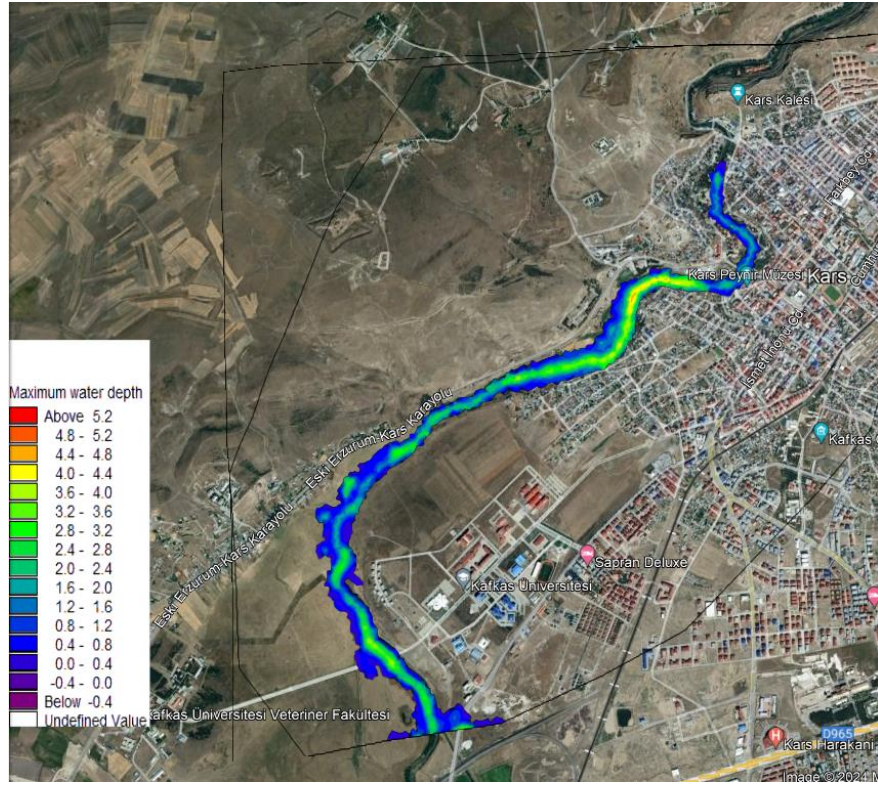
MIKE 21’de oluşturulan akış modeli analiz edildikten sonra zamana bağlı debilerin havza içinde hesaplanan en büyük su derinliği, en yüksek akım hızı ve toplam su derinliği gibi sonuçlara ulaşılır. Daha sonra MIKE to Google Earth uygulamasından taşkın yayılımları harita üzerinde gösterilir. (Şekil 8-Şekil 15)




Şekil 8. Kars Çayı üzerinde 2 yıllık maksimum taşkın yayılımı



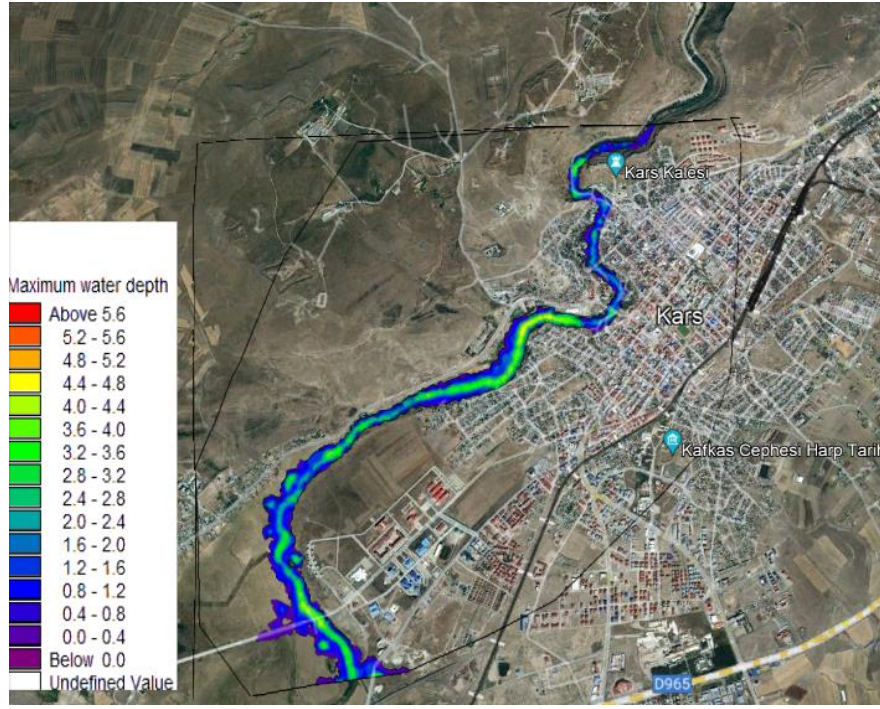
Şekil 9. Kars Çayı üzerinde 5 yıllık maksimum taşkın yayılımı



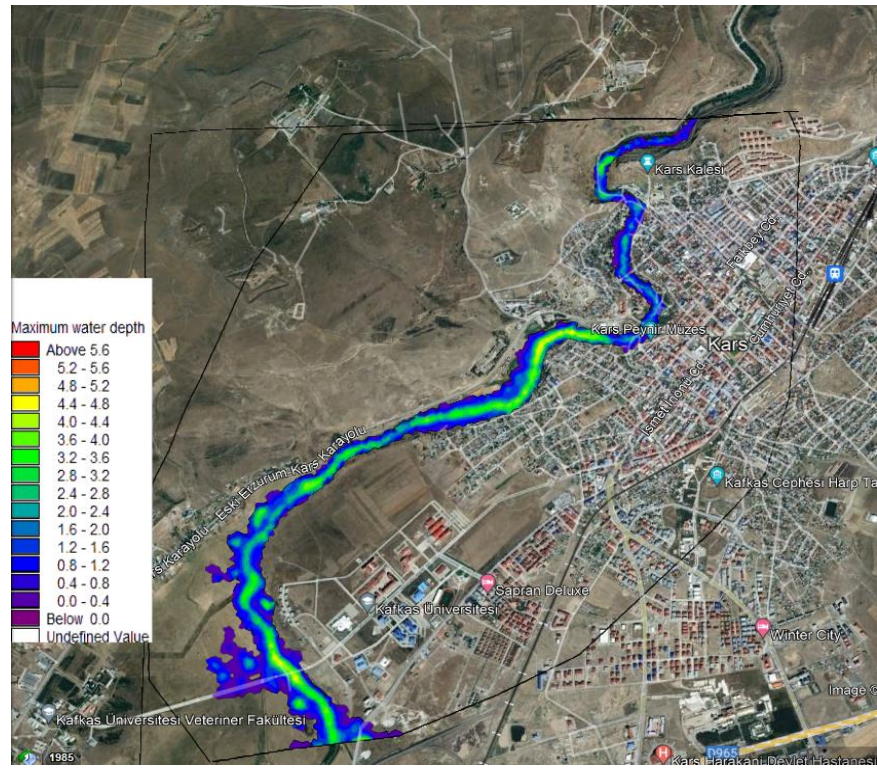
Şekil 10. Kars Çayı üzerinde 10 yıllık maksimum taşkın yayılım




Şekil 11. Kars Çayı üzerinde 25 yıllık maksimum taşkın yayılım




Şekil 12. Kars Çayı üzerinde 50 yıllık maksimum taşkın yayılım



Şekil 13. Kars Çayı üzerinde 100 yıllık maksimum taşkın yayılım



Şekil 16. Kars Çayı üzerinde yıllara göre su derinliklerinin okunduğu nokta ve koordinatları



Şekil 17. Yıllara göre su derinliklerinin değişim grafiği

Şekil 16 ve Şekil 17’de elde edilen bulgulara göre örneğin; 2 yıllık yağış verilerinde, su yüksekliğinin 2 saat 20 dakika sonra artmaya başlaması, o saate kadar havzaya herhangi bir su girişinin olmadığı anlamına gelmektedir. 1000 yıllık yağış verilerinde ise, su yüksekliğinin 50 dakika sonra artmaya başlaması o dakikaya kadar havzaya herhangi bir su girişinin olmadığı anlamına gelmektedir. Sonuç olarak zamana bağlı 2 boyutlu bir hidrolik modelleme yapıldığında, havza üzerinde seçilen bir noktadaki maksimum su derinliklerinin yıl ile doğru orantılı bir şekilde arttığı ve havzaya suyun girme hızının da yine yıl ile doğru orantılı bir şekilde artış gösterdiği gözlemlenmiştir.

4. SONUÇ

Bu çalışma kapsamında Aras Havzası içerisinde bulunan ve Kars/Merkezden geçen Kars Çayının hidrolik modeli oluşturulmuştur. Bu kapsamda CBS tabanlı Arc-GIS programı ile çalışma alanının dere güzergahları elde edilmiş daha sonrasında elde edilen taşkın yatağının topografik verisi NASA DEM Elevation Data (1-arc second Resolution SRTM / ASTER DEM)'dan alınmıştır. DSİ'den temin edilen harita ile NASA DEM Elevation Data (1-arc second Resolution SRTM / ASTER DEM)'dan alınan iki harita Global Mapper programı kullanılarak birbiri üzerine oturtulmuş ve sonucunda çalışma alanının MIKE programında kullanılacak formatına ulaşılmıştır. MIKE ZERO ve MIKE 21 kullanılarak hidrolojik model oluşturulmuştur. Daha sonrasında 2, 5, 10, 25, 50, 100, 500, ve 1000 yıllık tekerrür sürelerine sahip debiler hidrolojik modele girilmiştir. Son olarak elde edilen hidrolojik analizler sonucunda taşkın yayılım haritaları elde edilmiştir. Elde edilen bu haritalar uydu görüntüsü üzerinde gösterilerek, eğer taşkın riski varsa bunun hangi alanları etkileyebileceği belirlenmiştir.

Yapılan bu çalışma ile aşağıdaki sonuçlara varılmıştır:

- Taşkın riski taşıyan dere ve bölgelerin kolay ve hızlı bir şekilde modellenebilmesi için örnek bir çalışma yapılmıştır. Arc-GIS, Global Mapper ve MIKE bilgisayar programları kullanılarak taşkın yayılım haritalarının nasıl oluştuğu ve bu haritaların uydu üzerinde nasıl gösterildiği, 2B hidrolojik bir modellemenin nasıl oluşturulduğu ve taşkın yatağı içerisindeki su derinliklerinin nasıl elde edildiği gösterilmiştir.
- Havzaya suyun giriş süresi ve derinliklerinin yıllar ile doğru orantılı bir şekilde artış gösterdiği görülmüştür.
- Hidrolojik modele girilen; yıllara göre taşkın debileri sonucunda oluşan taşkın yayılım haritalarından da görüldüğü gibi Kars Çayı üzerinde, 1000 yıllık taşkın debisi ile bile mevcut yerleşim yerleri için bir taşkın riski olmayacağı sonucuna varılmıştır. Buna rağmen dere yataklarında yerleşimin önlenmesinin gerekli olduğu bilinmelidir.

REFERANSLAR

- [1] Özcan, O. (2017). Taşkın Tespitinin Farklı Yöntemlerle Değerlendirilmesi: Ayamama Deresi Örneği. Doğal Afetler ve Çevre Dergisi, 9–9. <https://doi.org/10.21324/dacd.267200>
- [2] Aşağı Sakarya Nehri Adapazarı Kesim Taşkın Risk Tayini Yüksek Lisans Tezi (n.d.)
- [3] Tarım ve T. C., Bakanlığı, O., Yönetimi, S., & Müdürlüğü, G. (n.d.). Aras Havzası Taşkın Yönetim Planı Yönetici Özeti.
- [4] Çanta, E. E., Prof., D., & Akıncı, H. (n.d.). Artvin Çoruh Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Anabilim Dalı Kemalpaşa (Artvin) İlçesinde 1 ve 2 Entegre Hidrolik Model ile Taşkın Yayılım Haritalarının Üretilmesi Yüksek Lisans Tezi.
- [5] Gülbaz, S. (2019). Sayısal Modeller ile Taşkın Yayılım Haritasının Oluşturulması ve Risk Altında olan Alanların Belirlenmesi: Türk köse Deresi Örneği. Doğal Afetler ve Çevre Dergisi, 5(2), 335–349.
- [6] Dikici, M., & Melek Kazezyılmaz-Alhan, C. (n.d.). Alibeyköy havzası için farklı hidrolojik modelleme yöntemleri ile taşkın debilerinin belirlenmesi.
- [7] 2022-Yılı-Doga-Kaynakli-Olay-Istatistikleri. (N.d.).
- [8] Tektaş, Y., & Polat, N. (2021). HEC-RAS ile Taşkın Modelleme ve Sentinel-2 Uzaktan Algılama Görüntüsünden Taşkın Hasar Analizi: Diyarbakır İli Çakmak Deresi Çınar Bölgesi Örneği. Turkish Journal of Remote Sensing.
- [8] Fazıl Akkoç, N. (n.d.). Aras Havzası Kars Çayı 1D ve 2D Taşkın analizi.

- [9] Demir V., Beden N., Keskin A. Ü. “Taşkın modelleme yöntemlerinin gözden geçirilmesi ve karşılaştırılması” Avrupa Bilim ve Teknoloji Dergisi Özel Sayı 28, S. 1013-1021, Kasım 2021
- [10] Mühendisliği Hidrolik Anabilim Dalı Danışman, İ., & Doç. Ali Arda ŞORMAN Eskişehir Anadolu Üniversitesi Fen Bilimleri Enstitüsü, Y. (2017). Aras Havzasında HEC-HMS ile Hidrolojik Modelleme ve Akım Tahmini Tufan Kacar Yüksek Lisans Tezi
- [11] Dere, G. (n.d.). Kurtköy Deresi Taşkın Yayılım- Tehlike Risk Haritalarının Belirlenmesi Yüksek Lisans Tezi.
- [12] Akkaya, U. (n.d.). Meriç ve Tuna Nehirlerinin Edirne Şehir Merkezi Kısımında 2 Boyutlu Taşkın Modellemesi Doktora Tezi.
- [13] Kaya Ç.M. (2021) 1B ve 2B Taşkın Modellemesinin Karşılaştırılması: Fol Deresi Örneği
- [14] Muammer, H. B., Şafak, B., Gündoğdu, T., Maruf, M., Mustafa, Y., Oktay, E., Nihan, G., Filiz, K., Kadiroğlu, T., Kerem, N., Sercan, K., Eren, Z., Hasan, S., & İlgen, G. (n.d.). Türkiye’de Afet Yönetimi ve Doğa Kaynaklı Afet İstatistikleri Disaster Management and Natural Disaster Statistics in Turkey
- [15] Dikici, M., & Aksel, M. (2019). Havza büyüklüğüne Göre En Uygun Taşkın Debisi Hesap Yönteminin Bulunması Doğu-Akdeniz Havzası Örneği. Alkü Fen Bilimleri Dergisi, 1(3), 120-131.
- [16] Üyüklüoğlu M. “HEC-RAS ile taşkın bölgelerinin modellenmesi” Bozok Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı Yüksek Lisans Tezi 2015
- [17] Abdul, S., Hashemi, M., Danışmanları, T., Üyesi, Ö., Saka, F., Hasan, Ö. Ü., & Babacan, T. (n.d.). Karabük Bulak Havzasında En Uygun Sentetik Birim Hidrograf Yönteminin Belirlenmesi 2023 Yüksek Lisans Tezi İnşaat Mühendisliği.
- [18] Lisans, Y., Nussaibah, T., & Raja, B. (n.d.). Ankara Üniversitesi Sosyal Bilimler Enstitüsü Coğrafya Anabilim Dalı Şehir Taşkın Modellemesi: Bodrum Örneği.
- [19] Barajının Mansap Tarafındaki Meskûn Bölgelerin Taşkın Risk Analizi, E., Mahnamfar, F., Abdollahzadeh Moradi, Y., Ağırlioğlu, N., Mühendisliği Bölümü, İ., & Üniversitesi, S. (2018). Elmalı Barajının Mansap tarafındaki Meskûn Bölgelerinin Taşkın Risk Analizi. <http://www.ishad.info>
- [20] Demir, V., & Ülke Keskin, A. (2022). Taşkın Tehlike Haritalarının Oluşturulması (Samsun, Mert Irmağı Örneği). Türkiye Coğrafi Bilgi Sistemleri Dergisi, 4(1), 47–54. <https://doi.org/10.56130/tucbis.1120501>
- [21] Ertürk, E., & Kaya, N. (2019). Taşkın Tehlike Alanlarının Oluşturulması: Trabzon İli Vakfıkebir İlçesi Kirazlı Deresi Örneği. In Fırat Üniversitesi Müh. Bil. Dergisi (Vol. 31, Issue 2).
- [22] Yönetimi, S., & Müdürlüğü, G. (n.d.). Taşkın Yönetimi.
- [23] Davis, H. E. (n.d.). MeGRA W-HItr, Civil Engineering Series.
- [24] Bülent, Ö., Murat, N., & Hüseyin, G. (1997). Coğrafi Bilgi Sistemi ile Deprem Bölgelerinin İncelenmesi, Bayındırlık ve İskân Bakanlığı. In Afet İşleri Genel Müdürlüğü.
- [25] Amir Muhammad Jafari. (n.d.).

Gıda ve Yem İçin Hızlı Alarm Sistemi (RASFF)'nde Bulunan 2022 Yılı Gıda ve Gıda ile Temas Eden Madde Bildirimleri

Rabia Aydođdu^{ID}, Merve Turan^{ID}, Derya Deniz Şirinyıldız^{ID}, Aslı Yorulmaz*^{ID}

Gıda Mühendisliği Bölümü, Aydın Adnan Menderes Üniversitesi, Aydın, Türkiye.

*asliyorulmaz@adu.edu.tr

Özet

Gıda ve Yem için Hızlı Alarm Sistemi (RASFF) gıda zincirinden kaynaklanan ve insan sağlığı riskleri belirlendiğinde, hızlı müdahale ve bilgi alışverişini sağlayan bir sistemdir. Bu çalışmada RASFF veri tabanında yer alan 2022 yılına ait gıda ve gıda ile temas eden maddelere ilişkin bildirimler incelenerek detaylı bir rapor oluşturulmuştur. RASFF sisteminde yer alan veriler; bildirim türü, bildirim yapan ülke, ürün kategorisi, bildirim konusu, risk derecesi, bildirim kaynağı ve alınan tedbirlere göre sınıflandırılmıştır. Toplam 4113 bildirim tespit edilmiştir ve en çok bildirimde bulunan ürün grubu 832 uyarı ile meyve ve sebzeler olmuştur. En çok rapor edilen sorun %23,36 ile pestisitler iken, bunu %22,98 ile mikrobiyal sorunlar takip etmiştir. Bildirimlerin %60,13'lük kısmı ciddi risk derecesine sahip uyarılardır. Toplam bildirimlerin 1474'ü sınır reddi, 1133'ü alarm, 957'si dikkat gerektiren bilgi, 548'i takip gerektiren bilgi iken; kalan 1 adedi ise uygunsuzluk bildirimi şeklinde sınıflandırılmıştır. En fazla bildirim yapan ülke 538 uyarı ile Hollanda olmuştur ve bunu 535 uyarı ile Almanya takip etmiştir. Bildirimlerin önemli bir kısmı (1453 adet) sınır kontrolleri sırasında oluşturulmuştur. Bildirimler sonucunda genellikle ürünler resmi olarak alıkonulmuş ve piyasadan çekilmiştir.

Anahtar Kelimeler: Gıda güvenliği, Hızlı alarm sistemi, Gıda ve yem için hızlı alarm sistemi (RASFF), RASFF bildirimleri.

Rapid Alert System for Food and Feed (RASFF) Notifications for Food and Food Contact Materials in 2022

Abstract

The Rapid Alert System for Food and Feed (RASFF) is a system that enables rapid response and information exchange when human health risks arising from the food chain are identified. In this study, a detailed report was prepared by analyzing the notifications regarding food and food contact materials in the RASFF database for 2022. The data present in the RASFF system are classified according to notification type, notifying country, product category, notification subject, risk degree, notification basis, and measures taken. A total of 4113 notifications were detected, and the most notified product group was fruit and vegetables with 832 notifications. The most reported problem was pesticides with 23.36%, followed by microbial problems with 22.98%. The 60.13% of the notifications are the ones with a serious risk degree. 1474 of the total notifications were border rejection, 1133 were alert, 957 were information notifications for attention, 548 were information notifications for follow-up, and the remaining 1 notification was classified as a non-conformity notification. The Netherlands was the most notifying country with 538 notices, followed by Germany with 535 notices. Most of the notifications (1453 notifications) were generated during border controls. As a result of the notifications, products were usually officially detained and withdrawn from the market.

Keywords: Food safety, Rapid alert system, Rapid alert system for food and feed (RASFF), RASFF notifications.

1. GİRİŞ

Gıda güvenliği, tüketici sağlığını korumak için gıdaların üretim, taşıma ve depolanmaları sırasında fiziksel, kimyasal ve biyolojik risklere karşı alınan tedbirleri ifade etmektedir. Artan dünya nüfusu ile birlikte, gıda kalitesinin ve güvenliğinin sağlanması hususu daha da önemli bir konu haline gelmiştir. Dünya Sağlık Örgütü'ne göre her yıl dünyada yaklaşık 600 milyon insanın yani 10 kişiden 1'inin kontamine gıdaları tüketmekten hastalandığı ve 420.000 kişinin aynı nedenden dolayı hayatını kaybettiği tespit edilmiştir [1]. Bu sebeple küresel gıda güvenliğinin sağlanması için hızlı ve güvenilir yaklaşımların geliştirilmesi ve etkin kullanımı önem arz etmektedir. Gıda ve Yem için Hızlı Alarm Sistemi (RASFF) gıda zincirinden kaynaklanan halk sağlığı riskleri belirlendiğinde hızlı müdahale ve bilgi alışverişini sağlamak amacıyla, 1979'da Avrupa Birliği tarafından kurulan bir sistemdir. Hızlı Alarm Sistemi'nin üyeleri halk sağlığını tehdit edecek herhangi bir riskin saptanması durumunda RASFF portalına bildirim yapmaktadır. Bu portal aracılığıyla 7 gün /24 saat veri akışı sağlanmaktadır. 10 Ocak 2011 tarihli (AB) 16/2011 sayılı Komisyon Tüzüğü [2] ve RASFF Kullanım Kılavuzuna uygun olarak, RASFF portalında yer alan bildirimler; referans numarası, tarihi, son güncelleme, türü, alıcı ülke veya ülkeler, AB pazarındaki dağılımına ilişkin bilgiler, ürün kategorisi ve ürünün menşei bilgilerini içermektedir [3].

RASFF portalında yer alan bildirimler; sınır iadesi, alarm, dikkat gerektiren bilgi, takip gerektiren bilgi ve haber şeklinde sınıflandırılmaktadır [4]. Alarm bildirimleri, piyasada ciddi bir sağlık riski oluşturan gıda, yem veya gıda ile temas eden madde tespit edildiğinde kullanılır ve acil müdahale gerektirir. Böylece söz konusu ürünün piyasada olup olmadığının tespiti ve ilgili işlemlerin yapılabilmesi için gerekli bilgi sağlanır. Sınır iadesi bildirimlerinde, ürünler Avrupa sınırlarında kontrol noktalarında test edilerek bloke edilir ve ürünlerin Avrupa pazarına ulaşması engellenir. Takip ve dikkat gerektiren bilgi bildirimleri ürünün piyasaya arz edilmediği, artık piyasada yer almadığı veya riskin hızlı önlem alınmasını gerektirmediği durumlarda kullanılır. Haber bildirimleri, diğer bildirim türlerinde sunulamayan ancak üye ülkelerdeki gıda ve yem kontrol yetkilileri için önemli kabul edilen gıda veya yem güvenliği bilgileriyle ilgilidir. Hızlı Alarm Sistemine yapılan bildirimler ile zaman içerisinde halk sağlığı için önemli bir veri tabanı oluşmuş durumdadır. Bu veri tabanındaki bildirimler kullanılarak farklı bilimsel çalışmalar ortaya konmuştur. Çebi ve Olhan [5] yaptıkları çalışmada 2011-2015 yılları arasında Türkiye kaynaklı gıdalara ilişkin RASFF bildirimlerini taramışlar ve ürün gruplarına göre, en fazla bildirim meyve ve sebzeler ile sert kabuklu yemişler olduğunu; en yaygın tehlike grubunun ise mikotoksin ve pestisit bulaşığı olduğunu vurgulamışlardır. Kürekçi ve Şahin'in [6] 1992-2018 yılları için yaptıkları benzer bir taramada kanatlı eti ve ürünlerine ilişkin bildirimler incelenmiş ve en yaygın bildirilen tehlikenin patojen mikroorganizmalar veya toksinleri olduğu bulgulanmıştır. Leuschner ve ark. [7] 2002 ve 2010 yılları arasında sisteme kaydedilen bildirimleri taradıkları çalışmalarında, gıdalarda en yaygın görülen biyogenik aminlerin balık ürünlerindeki histamin olduğunu tespit etmişlerdir. Kuğu ve ark. [8] yaptıkları çalışmada RASFF sistemine 2021 yılı boyunca yapılan gıda ve gıda ile temas eden madde bildirimlerini incelemişler ve en sık rastlanan tehlike grubunun pestisitler olduğunu, en çok bildirimde bulunan ürün kategorisinin meyve ve sebzeler olduğunu ve vakaların çoğunluğunun ciddi risk derecesine sahip olduğunu ortaya koymuşlardır. Mevcut çalışmanın amacı RASFF sistemindeki 2022 yılına ait gıda ve gıda ile temas eden maddelere ilişkin bildirimleri incelemek ve ayrıntılı bir rapor hazırlamaktır. Çalışma kapsamında 2022 yılı içinde sisteme bildirilen uyarılara ilişkin konu, kaynak, tür, ürün grupları, bildirimde bulunan ülke, risk derecesi ve alınan önlemler hakkında bilgiler derlenmiş ve detaylarıyla sunulmuştur.

2. MATERYAL VE YÖNTEM

Bu çalışma kapsamında RASFF veri tabanındaki gıda ve gıda ile temas eden maddeler başlığı altında 01/01/2022- 31/12/2022 dönemi için bildiride bulunan veriler incelenmiştir. Elde edilen veriler Microsoft Office Excel 365 kullanılarak değerlendirilmiş; bildirim türü, bildirim yapan ülke, ürün kategorisi, bildirim konusu, risk derecesi, bildirim kaynağı ve alınan tedbirlere göre sınıflandırılarak ilgili tablolar oluşturulmuştur.

3. BULGULAR VE TARTIŞMA

RASFF portalı, gıda ve gıda ile temas eden maddelerdeki risklere ilişkin bilgilere erişmek için kullanılmıştır. 01/01/2022- 31/12/2022 tarihleri arasında RASFF portalındaki gıda ve gıda ile temas eden ürünlerin bildirimlerinin incelenmesi sonucunda toplam 4113 bildirim yapıldığı tespit edilmiştir. 2022 yılındaki bildirimler bu sistemde “gıda” ve “gıda ile temas eden madde” olarak sınıflandırıldığında gıda grubu için 3895, gıda ile temas eden madde grubu için 218 bildirim kaydedildiği görülmüştür.

3.1 Konularına göre Bildirimler

Gıda ve gıda ile temas eden maddelere ilişkin bildirimlerin konularına göre sınıflandırması Tablo 1’de verilmiştir. Pestisit kalıntıları %23,36 ile RASFF’da en çok rapor edilen sorun olmuştur. Etilen oksit, klorpirifos, klorpirifos-metil, prokloraz, piridaben, asetamiprid ve karbenzim en fazla görülen pestisitler arasında yer almıştır. RASFF’ın 2021 yılı raporuna göre 2019-2021 yılları arasında gıdalardaki pestisit kalıntılarının belirgin bir şekilde arttığı, 2021 yılında ise dünya tarihinde kaydedilen en yüksek değere ulaştığı görülmüştür [4]. Benzer bir şekilde Kuğu ve ark. [8] tarafından yapılan çalışmada 2021 yılında gıdalardaki en çok problemin pestisit kalıntısı olduğunu gözlemlenmiştir.

RASFF portalında 2022 yılı için en fazla bildirimde bulunan ikinci tehlike grubu %22,98 ile gıdalardaki mikrobiyal sorunlar, örneğin; *Salmonella spp.*, *Listeria spp.*, *Escherichia coli*, *Bacillus spp.*, parazit, anisakis, maya ve küf varlığı olmuştur. RASFF’ın 2021 raporuna göre patojenik mikroorganizmalar, son birkaç yılda toplam bildirim sayısında bir miktar azalma olsa da gıda ürünlerinde çok önemli bir tehlike kategorisi olmaya devam etmiştir [4]. *Salmonella spp.*, *Listeria spp.*, *Escherichia coli*, *Bacillus spp* gıdalarda varlığı en fazla bildirilen patojenlerdir. *Salmonella spp.* varlığı, 594 bildirim ile mikroorganizmalar arasında en önemli tehlike olmuştur ve bu bildirimlerin neredeyse yarısı (286 adet) kanatlı eti ve kanatlı eti ürünleri kategorisinde tespit edilmiştir. Asya-Pasifik bölgesinden gelen gıdaların mikrobiyolojik güvenliği üzerine yapılan bir çalışmada, 2000–2020 yılları arasında RASFF veri tabanındaki bildirimler analiz edilerek değerlendirilmiş ve buna göre gıdalardan izole edilen her 10 patojenden yaklaşık *yedi tanesinin* *Salmonella* cinsinden olduğu görülmüştür [9].

Tablo 1. Konularına göre bildirim sayısı ve oranları

Bildirim Konusu	Bildirim Sayısı (adet)	Bildirim Oranı (%)
Pestisit kalıntısı	961	23,36
Mikrobiyal sorunlar	945	22,98
Mikotoksin varlığı	486	11,82
İzinsiz katkı maddeleri veya renk maddesi, limiti aşan katkı maddesi miktarı, kalıntı	209	5,08
Alerjenler alerjen varlığı veya etikette belirtilmemiş, beyan edilmemiş alerjenler	187	4,55
Metal ve ağır metaller	166	4,04
Yenilikçi gıda	139	3,38
Yabancı cisim	119	2,89
Kontaminantlar	112	2,72
Migrasyon	104	2,53
Ambalaj deformasyonu	90	2,19
Sertifika, sağlık sertifikası, giriş belgesi ve diğer belgelerin bulunmaması	87	2,12
İlaç/uyuşturucu varlığı	71	1,73
Plastik, bambu, diğer bitkisel liflerden sofraya takımları/izinsiz bambu (lifi) kullanımı	70	1,70

Zayıf ve yetersiz kontrol	52	1,26
Histamin varlığı	33	0,80
Hile	32	0,78
Organoleptik (tat ve koku) modifikasyon, viskozite problemleri, bozulma (duyusal, acılaşıma)	31	0,75
Yetkisiz şirket, kuruluş, ülke, operatör sorunu	31	0,75
Pirolizidin alkaloidleri, bitkide ikincil metabolitler	29	0,71
Sülfidler, sülfadimetoksin, çok yüksek sülfür dioksit içeriği	27	0,66
Benzo(a)piren ve polisiklik aromatik hidrokarbonlar (PAH'lar), benzoik asit ve benzoatlar	23	0,56
GDO, ışınlama	18	0,44
Antibiyotik	15	0,36
Yasadışı ithalat girişimi	9	0,22
Sağlık sorunu (bozulmuş, yedikten sonra hastalanmış, ağızda yanık, zehirlenme, yutma tehlikesi, salgın)	8	0,19
Diğer	59	1,43

Gıdalardaki mikotoksin varlığı, 2022 yılı RASFF verilerinde %11,82 ile üçüncü önemli sorun olarak öne çıkmıştır. Aflatoksin probleminin çoğunluğunun fındık, fındık ürünleri ve tohumlar kategorisinde yer aldığı gözlemlenirken; okratoksin sorununun ise en fazla meyve ve sebzelerde olduğu tespit edilmiştir. Nogales ve ark. [10] tarafından yapılan bir çalışmada 1979-2020 yılları arasında RASFF verileri incelenmiş, mikotoksinlerin en fazla rapor edilen tehlike türü olduğu tespit edilmiştir. Benzer bir başka çalışmada ise 2004-2019 yılları arasındaki kuru incir bildirimleri incelenmiş ve en çok endişe duyulan tehlikenin aflatoksin varlığı olduğu belirtilmiştir [11]. Aflatoksinler, *Aspergillus flavus* ve *A. Parasiticus* tarafından üretilen bir grup toksik metabolitler olup; insan sağlığı üzerindeki güçlü karsinojen, mutajenik, immünosupresif, teratojenik, östrojenik ve tremorojenik etkileri olan bileşiklerdir [12]. Doğada farklı aflatoksin türleri bulunmasına rağmen; B₁, B₂, G₁ ve G₂ önemli gıda kontaminantları olarak kabul edilmektedir. Türk Gıda Kodeksi Bulaşanlar Tebliği'nde kuru incir için aflatoksin B₁ ve toplam aflatoksin üst limitleri sırasıyla 8 ve 10 ppb olarak belirlenmiştir [13]. Pestisit, mikrobiyal sorunlar ve mikotoksin varlığını takiben izinsiz katkı maddeleri veya renk maddesi ya da limiti aşan katkı maddesi miktarı, kalıntı problemi %5,08 oran ile portalda dördüncü sırada yer alan problem olmuştur. Bu kategoriye E110, E122, E123, E124, E127, E171, E200, E202, E210, E407, E410, E522, E625, E554 katkı maddeleriyle; turuncu II, Sudan I, III ve IV, E128- Kırmızı 2G gibi gıda boya renkleri girmektedir. Bu grubu %4,55 ile alerjenler, alerjen varlığı veya etikette belirtilmemiş, beyan edilmemiş alerjenler takip etmektedir. Kuğu ve ark. [8] tarafından yapılan çalışmada 2021 yılında gıda katkı maddeleri rapor edilen en büyük dördüncü tehlike olurken; alerjenler ise yedinci sıradaki risk grubunu oluşturmuştur. Çınar ve ark. [14] 2009-2016 yılları arasındaki bildirimleri taramışlar ve gıda katkı maddesi uyarısının ilgili yıllar içinde en fazla 2015 yılında yapıldığını bildirmişlerdir. Metal ve ağır metal grubu (borat, bromür, krom, iyot, civa, gümüş, kolloid gümüş, kadmiyum, siyanür, demir, nikel, kobalt, magnezyum L-treonat, selenyum, alüminyum, azot, lityum, kurşun, iyot, hidrojen siyanid) %4,04 ile önemli tehlikeler grubu arasında yer almıştır. Kadmiyum (61), civa (48), kurşun (31) ile en fazla bildirilen metal türleri olmuştur. Kadmiyum daha çok meyve ve sebzeler (29) kategorisinde gözlenirken; civa, balık ve ürünleri (44) kategorisinde yer almıştır. Nogales ve ark. [10] ile Piglowski [15] tarafından yapılan ve RASFF verilerinin incelendiği çalışmalarda metaller ve ağır metaller en çok gözlenen dördüncü tehlike kategorisinde yer almıştır.

3.2 Kaynağına göre Bildirimler

Kaynaklarına göre bildirimlerin dağılımı Tablo 2’de verilmiştir. Tüm bildirimlerin %40,26’sı sınır kontrolleri sırasında oluşturulmuştur. Sınır kontrollerinde oluşturulan bildirimlerin 1453 adedi ürünlerin gözümlenmesine alınması durumunda, 137 adedi ürünlerin geçişine izin verilmesi sırasında, 33 adedi gümrükte yapılan sevkiyatta ve 33 adedi ürünlerin varış noktasına gönderilmesi sırasında oluşturulmuştur. Bildirimlerin %29,91’i piyasadaki resmi kontroller sırasında (1230), %20,62’si üretici firmaların kendi kontrolleri sırasında (848) ve %4,77’si tüketici şikâyeti sonrası (196) oluşturulmuştur. Çiftçi ve ark. [16] 2000-2020 yılları arasındaki RASFF verilerini incelemişler ve en fazla piyasadaki resmi kontroller sırasında problemlili ürünlerin belirlendiğini bildirmişlerdir.

Tablo 2. Kaynağına göre bildirim sayısı ve oranları

Kaynağına göre bildirimler	Bildirim sayısı (adet)	Bildirim oranı (%)
Sınır kontrolü sırasında	1656	40,26
Piyasadaki resmi kontroller sırasında	1230	29,91
Üretici firmaların kendi kontrolleri sırasında	848	20,62
Tüketici şikâyeti sonrası	196	4,77
Medyanın takibi üzerine	95	2,31
İzleme sistemi sonucu	47	1,14
Gıda zehirlenmesi	28	0,68
Üye olmayan ülkelerde gerçekleştirilen resmi kontrollerde	9	0,22
Talep sonucu	3	0,07
Bilgi yok	1	0,02

3.3 Türlerine göre Bildirimler

Gıda ve Yem için Hızlı Alarm Sistemi (RASFF) portalında gıda ve gıda ile temas eden maddelere ilişkin 2022 yılında yapılan bildirimlerin türlerine göre dağılımı Tablo 3’te verilmiştir. Bu bildirimler alarm, sınır reddi, dikkat gerektiren bilgi, takip gerektiren bilgi ve uygunsuzluk olmak üzere beş grupta incelenmiştir. En fazla olan bildirim türü %35,84 oranı ile sınır reddi (1474) olmuştur. Bunu %27,55 ile alarm (1133), %23,27 ile dikkat gerektiren bilgi (957), %13,32 ile takip gerektiren bilgi (548) ve son olarak %0,02 ile uygunsuzluk (1) takip etmiştir. Sınır reddi bildirimlerinin büyük bir çoğunluğu meyve ve sebzeler kategorisinde yer almıştır. RASFF’in 2021 yılı raporuna göre tüm bildirimlerin %31,6’sı sınır reddi (1457) ve %31,6’sı alarm bildirimleri (1455) olmuştur [4].

Tablo 3. Türlerine göre bildirim sayısı ve oranları

Bildirim türü	Bildirim sayısı (adet)	Bildirim oranı (%)
Sınır iadesi bildirimleri	1474	35,84
Alarm bildirimleri	1133	27,55
Dikkat gerektiren bilgi bildirimleri	957	23,27
Takip gerektiren bilgi bildirimleri	548	13,32
Uygunsuzluk bildirimleri	1	0,02

3.4 Ükelere göre Bildirimler

RASFF portalındaki 2022 yılına ait veriler incelendiğinde gıda ve gıda ile temas eden maddeler için bildirim gönderen ülkelerin dağılımı Tablo 4’te sunulduğu gibidir. En fazla bildirimde bulunan ülke 538 uyarı ile Hollanda ve ikinci olarak 535 uyarı ile Almanya olmuştur. Bu ülkeleri sırasıyla Belçika (376),

İspanya (318), Polonya (305), İtalya (301), Fransa (263), Bulgaristan (242), Yunanistan (143), Danimarka (113), İsveç (93), Finlandiya (82), Letonya (79), İrlanda (78), Romanya (75), Çekya (65), İsviçre (60), Avusturya (53), Hırvatistan (53) ve Litvanya (53) izlemiştir. 50'den daha az bildirimde bulunan ülkeler ise diğer başlığı altında yer almıştır. Bu ülkeler ise sırasıyla Kıbrıs (48), Slovenya (47), Portekiz (46), Slovakya (33), Norveç (25), Estonya (20), Avrupa Komisyonu (20), Macaristan (19), Lüksemburg (17), Malta (11) ve İzlanda (2)'dir. Geçmiş yıllara ilişkin RASFF verileri incelendiğinde 2019 ve 2020 yılında Almanya'nın en fazla bildirimde bulunduğu, 2021 yılında ise Polonya'nın en fazla bildirimde bulunduğu görülmüştür [4].

Tablo 4. Ükelere göre bildirim sayısı ve oranları

Ülke adı	Bildirim sayısı (adet)	Bildirim oranı (%)
Hollanda	538	13,08
Almanya	535	13,01
Belçika	376	9,14
İspanya	318	7,73
Polonya	305	7,42
İtalya	301	7,32
Fransa	263	6,39
Bulgaristan	242	5,88
Yunanistan	143	3,48
Danimarka	113	2,75
İsveç	93	2,26
Finlandiya	82	1,99
Letonya	79	1,92
İrlanda	78	1,90
Romanya	75	1,82
Çekya	65	1,58
İsviçre	60	1,46
Avusturya	53	1,29
Hırvatistan	53	1,29
Litvanya	53	1,29
Diğer	288	7,00

3.5 Risk Derecelerine göre Bildirimler

Risk derecelerine göre bildirimlerin sınıflandırılması Tablo 5'te verilmiştir. Tüm bildirimler (4113 bildirim); ciddi, kararsız, ciddi değil ve risksiz olmak üzere 4 kategoride sınıflandırılmıştır. Risk kararları ile ilgili olarak vakaların %60'ı ciddi (2473), %27'si kararsız (1129), %11'i ciddi değil (466), %1'i ise risksiz (45) olduğu tespit edilmiştir. Ciddi bildirimlerin çoğunluğu meyve ve sebzeler ile fındık, fındık ürünleri ve tohumlar grubunda yer almıştır.

Tablo 5. Risk derecelerine göre bildirim sayısı ve oranları

Risk derecesi	Bildirim sayısı (adet)	Bildirim oranı (%)
Ciddi risk derecesi	2473	60,13
Kararsız kalınmış	1129	27,45
Ciddi olmayan risk derecesi	466	11,33
Risksiz	45	1,09

3.6 Ürün Kategorisine göre Bildirimler

Bildirimlerin ürün kategorilerine göre dağılımı Tablo 6'da gösterilmiştir. En fazla bildirimde bulunan ürün grubunun 832 bildirim ile meyve ve sebzeler olduğu tespit edilmiştir. İkinci sırayı 480 bildirim ile fındık ürünleri ve tohumlar grubu takip ederken, üçüncü sırada ise 369 bildirim ile diyetetik gıdalar, gıda takviyeleri ve güçlendirilmiş gıdalar grubu yer almıştır. Beyan edilen diğer ürün grupları arasında; kümes hayvanı eti ve kümes hayvanı eti ürünleri (329), otlar ve baharatlar (300), hububat ve unlu mamuller (269), balık ve ürünleri (240), gıda ile temas eden malzemeler (212), et ve et ürünleri (kümes hayvanları hariç) (184), diğer gıda ürünleri/karışık (163), hazırlanmış yemekler ve atıştırmalıklar (106) yer almıştır. Piglowski'nin [17] 2008-2015 yılları arasındaki RASFF bildirimlerini taradığı çalışmada en çok bildirim yapılan ürün kategorilerinin meyve ve sebzelerle fındık ve tohumlar olduğu görülmektedir.

3.7 Alınan Tedbirlere göre Bildirimler

RASFF portalına bildirilen riskli ürünler için alınan tedbirlere ait liste Tablo 7'de verilmiştir. RASFF portalında 2022 yılına ait toplam 4113 bildirim bulunmasına rağmen; bildirimler tek tek incelendiğinde toplam 4824 adet tedbir alındığı görülmektedir. Alınan tedbirlerin sayısının sistemdeki uyarıların sayısından fazla olmasının sebebi bazı bildirimler için birden fazla tedbir uygulanmış olmasıdır. Risk içerdiği tespit edilen ürünler için uygulanan en yaygın tedbirlerin, ürünün resmi olarak alıkonulması (676) ve piyasadan çekilmesi (610) olduğu bulgulanmıştır. Bunu sırasıyla alıcının/alıcıların bilgilendirilmesi (416), ürünlerin tüketiciden geri çağırılması (414), yetkililerin bilgilendirilmesi (399), yeniden gönderme veya imha etme (280), ürünlerin imha edilmesi (218), para iadesi (210), kamu uyarısı-basın açıklaması (172), daha güçlü bir kontrol sistemi (162), göndericiye iade etme (160), yeni ürün gönderimi (136), ısıl işlem uygulama (107), ürünlere el konulması, alıkonma (104), stokta ürün tutmama (103), göndericiyi bilgilendirme (89), geri çekme/geri çekme işlemlerinin izlenmesi (57), ticaret yasağı - satış yasağı (55), gümrük mühürleri altına alınması (55 bildirim) iken; 231 ürün için hiçbir önlem belirtilmemiş, 47 adet ürün hakkında ise herhangi bir işlem yapılmamıştır. Piglowski'nin [18] 1981-2020 yılları arasındaki pestisitler konusundaki RASFF bildirimlerini incelediği çalışmada, riskli ürünler için uygulanan en yaygın tedbirin ürünlerin imhası olduğu görülmektedir.

Tablo 6. Ürün kategorisine ait bildirim sayısı ve oranları

Ürün Kategorisi	Bildirim sayısı (adet)	Bildirim oranı (%)
Meyve ve sebzeler	832	20,23
Fındık, fındık ürünleri ve tohumlar	480	11,67
Diyetetik gıdalar, gıda takviyeleri ve güçlendirilmiş gıdalar	369	8,97
Kanatlı eti ve kanatlı eti ürünleri	329	8,00
Otlar ve baharatlar	300	7,29
Tahıllar ve unlu mamuller	269	6,54
Balık ve ürünleri	240	5,84
Gıda ile temas eden malzemeler	212	5,15
Et ve et ürünleri (kümes hayvanları hariç)	184	4,47
Hazır yemekler ve atıştırmalıklar	106	2,58
Süt ve süt ürünleri	95	2,31
Çift kabuklu yumuşakçalar ve bunların ürünleri	75	1,82
Kakao ve kakao ürünleri, kahve ve çay	75	1,82
Kabuklular ve bunların ürünleri	66	1,60
Şekerleme	65	1,58
Çorbalar, et suları, soslar ve çeşniler	44	1,07

Katı ve sıvı yağlar	42	1,02
Gıda katkı maddeleri ve tatlandırıcılar	41	1,00
Alkolsüz içecekler	30	0,73
Kafadanbacaklılar ve bunların ürünleri	25	0,61
Alkollü içecekler	24	0,58
Buzlar ve tatlılar	23	0,56
Yumurta ve yumurta ürünleri	10	0,24
Bal ve arı sütü	3	0,07
İnsan tüketimi için su (diğer)	3	0,07
Şarap	3	0,07
Gastropodlar	2	0,05
Hayvansal yan ürünler	1	0,02
Yem malzemeleri	1	0,02
Doğal maden suları	1	0,02
Diğer gıda ürünü / karışık	163	3,96

Tablo 7. Alınan tedbirlerin bildirim sayısı ve oranları

Alınan tedbirler	Bildirim sayısı (adet)	Bildirim oranı (%)
Resmi olarak alıkoyma	676	14,01
Ürünün piyasadan çekilmesi	610	12,65
Alıcının/alıcıların bilgilendirilmesi	416	8,62
Ürünlerin tüketiciden geri çağırılması	414	8,58
Yetkilileri bilgilendirme	399	8,27
Yeniden gönderilecek veya imha edilecek ürün	280	5,80
Önlem belirtilmemiş	231	4,79
Ürünlerin imha edilmesi	218	4,52
Para iadesi	210	4,35
Kamu uyarısı-basın açıklaması	172	3,57
Daha güçlü bir kontrol sistemi	162	3,36
Göndericiye iade etme	160	3,32
Yeni ürün gönderimi	136	2,82
Isıl işlem	107	2,22
Ürünlere el konulması, alıkonma	104	2,16
Stokta ürün tutmama	103	2,14
Göndericiyi bilgilendirme	89	1,84
Geri çekme/geri çekme işlemlerinin izlenmesi	57	1,18
Gümrük mühürleri altına alma	55	1,14
Ticaret yasağı- satış yasağı	55	1,14
İşlem yapmama	47	0,97
Diğer önlemler	123	2,55

4. SONUÇ

Gıda ve Yem için Hızlı Alarm Sistemi (RASFF) veri tabanındaki bilgileri tüm dünyada tüketicilere, şirket sahiplerine ve yetkililerin kullanımına sunmaktadır. Böylelikle gıda güvenliğinin sağlanması için hızlı ve kolay bir şekilde bilgi aktarımı sağlanmaktadır. Bu çalışmada Gıda ve Yem için Hızlı Alarm Sistemi'nde yer alan 2022 yılına ait “gıda” ve “gıda ile temas eden madde” kategorisindeki tüm bildirimler değerlendirilmiştir. Yapılan değerlendirmelerde en fazla bildirimde bulunan ürün grubunun meyve ve sebzeler olduğu tespit edilmiştir. Fındık, fındık ürünleri ve tohumlar ile meyve ve sebzelerde en sık rastlanan problemlerin sırasıyla mikotoksin varlığı ve pestisit kalıntıları olduğu tespit edilmiştir. Ayrıca bu ürünlerin ciddi risk kategorisinde olduğu tespit edilmiş ve tedbir olarak da genellikle resmi olarak alıkonma ve piyasadan çekilme yaptırımları uygulanmıştır. Mevcut çalışma ile ortaya konan bulguların, insan sağlığı açısından söz konusu risklerin kontrol altına alınmasına yönelik denetim ve önlemlerin artırılması ile gıda üreticisi ve tüketicilerin farkındalıklarını artırmaya yönelik gerçekleştirilecek çalışmalara katkıda bulunması umulmaktadır.

REFERANSLAR

- [1] WHO (2023). Gıda Güvenliği. <https://www.who.int/es/news-room/fact-sheets/detail/food-safety>. (accessed 30.04.2020).
- [2] European Commission. (2011). Commission Regulation (EU) No 16/2011. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A32011R0016> (accessed 28.04.2023).
- [3] Parisi, S., Barone, C., Sharma, R. K. (2016). Chemistry and Food Safety in the EU (RASFF). Springer, pp.7-8. <https://doi.org/10.1007/978-3-319-33393-9>.
- [4] RASFF (2023). Food Safety. https://food.ec.europa.eu/safety/acn/reports-and-publications_en. (accessed 12.04.2023).
- [5] Çebi, S. Y., Olhan, E. (2017). Avrupa birliği gıda ve yemde hızlı alarm sisteminin Türkiye'nin gıda ürünleri ihracatı üzerine etkilerinin değerlendirilmesi. Tarım Ekonomisi Dergisi, 23(1), 133 - 144. <https://doi.org/10.24181/tarekoder.325641>.
- [6] Kürekci, C., Şahin, Ş. (2019). Kanatlı eti ve ürünleri hakkında RASFF sistemine yapılan bildirimler. 5. Uluslararası Beyaz Et Kongresi, 24-28 Nisan 2019, Antalya.
- [7] Leuschner, R., Hristova, A., Robi, T., Hugas, M. (2013). The rapid alert system for food and feed (RASFF) database in support of risk analysis of biogenic amines in food. Journal of Food Composition and Analysis, 29(1), 37-42. <https://doi.org/10.1016/j.jfca.2012.09.004>.
- [8] Kuğu, N., Yılmaz, K., Deniz Şirinyıldız, D., Yorulmaz, A. (2022). Analysis of RASFF notifications: 2021 food and food contact material data review. The Journal of Food, 47 (6), 962-970. <https://doi.org/10.15237/gida.GD22071>.
- [9] Dada, A. C., Somorin, Y., Ateba, C., Onyeaka, H., Anyogu, A., Kasan, N. A., Odeyemi, O. (2021). Microbiological hazards associated with food products imported from the Asia-Pacific region based on analysis of the rapid alert system for food and feed (RASFF) notifications. Food Control, 129, 108243. <https://doi.org/10.1016/j.foodcont.2021.108243>.

- [10] Nogales, A., Cantallops, M. M., Mor'on, R. D., Tejedor, A. J. (2023). Network analysis for food safety: Quantitative and structural study of data gathered through the RASFF system in the European Union. *Food Control*, 145, 109422. <https://doi.org/10.1016/j.foodcont.2022.109422>.
- [11] Deniz Şirinyıldız, D., Yorulmaz, A. (2019). Gıda ve yem için hızlı alarm sisteminde yer alan kuru incir kaynaklı bildirimler. HASAT Uluslararası Tarım ve Orman Kongresi, 21-23 Haziran 2019, Ankara.
- [12] Huong, B. T. M., Brimer, L., Dalsgaard, A. (2016). Dietary exposure to aflatoxin B₁, ochratoxin A and fumonisins of adults in Lao Cai province, Viet Nam: A total dietary study approach. *Food and chemical toxicology*, 98, 127-133. <https://doi.org/10.1016/j.fct.2016.10.012>.
- [13] TKG. (2023). Türk Gıda Kodeksi Gıda Maddelerindeki Bulaşanların Maksimum Limitleri Hakkında Tebliğ. Resmi Gazete Tarihi: 05.11.2023. Resmi Gazete Sayısı: 32360. Ankara.
- [14] Çınar, S., Yılmaz, S. N., Aydın, E., Yorulmaz, A. (2017). Gıda ve yem için hızlı alarm sistemi (RASFF) 2009-2016 Türkiye raporu. *Türk Tarım -Gıda Bilim ve Teknoloji Dergisi*, 5(8), 873-882. <https://doi.org/10.24925/turjaf.v5i8.873-882.1155>.
- [15] Pięłowski, M. (2018). Heavy metals in notifications of rapid alert system for food and feed. *Int. J. Environ. Res. Public Health*, 15(2), 365. <https://doi.org/10.3390/ijerph15020365>.
- [16] Çiftçi, N., Karadeniz, Ş., Deniz Şirinyıldız, D., Yorulmaz, A. (2022). Gıda ve yem için hızlı alarm sisteminde yer alan çevresel kirletici bildirimleri. *Food and Health*, 8(2), 92 - 102, 01.04.2022. <https://doi.org/10.3153/FH22009>.
- [17] Pięłowski, M. (2017). Product categories and hazard categories in the RASFF notifications: dependences between chosen variables. *Quality Assurance and Safety of Crops & Foods*, 9 (3), 335-344, <https://doi.org/10.3920/QAS2016.1004>.
- [18] Pięłowski, M. (2022). Notifications on pesticide residues in the rapid alert system for food and feed (RASFF). *International Journal Environmental Research and Public Health*, 19, 8525. <https://doi.org/10.3390/ijerph19148525>.

Adapting Object Detection Models for Multi-Target Detection Utilizing Radars

İbrahim Rıza Hallaç^{1*}, Deniz Akbaba¹, Gökhan Gökçe¹, S. Gokhun Tanyer^{2,3}, Peter F. Driessen³

¹Department of Computer Engineering, Alanya Alaaddin Keykubat University, Antalya, Türkiye.

²MulticoreWare Inc. San Jose, CA, USA, INNOVTECH, Victoria, Canada

³Department of Electrical and Computer Engineering, University of Victoria, Victoria BC, Canada.

*ibrahim.hallac@alanya.edu.tr

Abstract

This paper investigates the use of Deep Learning (DL) in multiple input multiple output (MIMO) radar target detection, focusing on azimuth and elevation estimation. Traditional methods face challenges like interference and reflections, especially in multi-target scenarios. Feature extraction conventionally relies on range correlation, Doppler filtering, and angle beamforming, followed by detection after constant false alarm rate (CFAR) processing. However, early data sparsification by bin selection often leads to information loss, particularly with large data cubes required for practical implementation. DL techniques offer an alternative, specifically in azimuth and elevation detection at earlier stages of radar data processing. We developed a convolutional neural network (CNN) model that achieved Mean Square Errors (MSE) of 0.149 for azimuth and 0.168 for elevation on single-target data from 5,000 samples. The model's performance in dual-target scenarios showed MSEs ranging from 0.838 to 1.845, tested on 8,000 samples from a dataset of 72,000. This paper details the model development process, its impact on radar target detection, and potential future research directions involving the substitution of multi-bin DL blocks with traditional methods.

Keywords: Radar processing pipeline, MIMO radar, Multi-target detection, Machine learning, Convolutional neural network.

Radarla Çoklu Hedef Tespiti için Nesne Tanıma Modellerinin Uyarlanması

Özet

Bu makale, çoklu giriş çoklu çıkış (MIMO) radar hedef tespitinde için Derin Öğrenme tekniğinin uygulamasını, özellikle azimut ve yükseklik tahminine odaklanarak ele almaktadır. Geleneksel yöntemler, özellikle çoklu hedef senaryolarında parazit ve yansıma gibi zorluklarla karşı karşıya kalmaktadır. Özellikle çıkarımı, genellikle menzil korelasyonu, Doppler filtreleme, açı demetleme ve sabit yanlış alarm oranı (CFAR) işleminden sonra tespit adımlarını içeren klasik radar sinyal işleme hattına dayanmaktadır. Ancak, erken aşamada veri seyreltilmesi, pratik uygulamalar için gereken büyük veri küplerinde bilgi kaybına yol açabilmektedir. Derin Öğrenme teknikleri, azimut ve yükseklik tespiti için alternatif bir yaklaşım sunmaktadır. Geliştirdiğimiz evrimsel sinir ağı (CNN) modeli, 5000 örnekten oluşan tek hedefli veri üzerinde azimut için 0.149 ve yükseklik için 0.168 Ortalama Kare Hata (MSE) değerleri ile yüksek performans göstermiştir. İki hedefli senaryolarda ise model, 72.000 örneklilik veri setinden 8000 test örneği üzerinde 0.838 ile 1.845 arasında MSE değerleri elde etmiştir. Bu makale, model geliştirme sürecini, radar hedef tespitindeki etkisini ve Derin Öğrenme ile geleneksel yöntemlerin entegrasyonuna yönelik potansiyel gelecek araştırma yönlerini detaylı bir şekilde ele almaktadır.

Anahtar Kelimeler: Radar işleme hattı, MIMO radar, Çoklu hedef tespiti, Makine öğrenimi, Evrimsel sinir ağı.

1. INTRODUCTION

Radar stands for Radio Detection and Ranging. The history of radar technology is lengthy and fascinating. The concept of using radio waves to detect objects was first proposed during the late 1880s by German physicist Heinrich Hertz, but it wasn't until the 1930s that serious developmental work on radar began. Radar technology was essential to military operations during World War II because it allowed for the identification and tracking of adversarial ships and aircraft. The advancement of radar technology after the war led to its widespread usage in civil applications including weather forecasting and air traffic control. The radar data was processed using traditional signal processing techniques to extract environmental data. However, the limits of traditional signal processing techniques utilized in radar systems have come to limit more recently. These constraints make it difficult to detect things in congested situations and make it difficult to discern between weak and strong signals. Additionally, traditional methods require significant expertise and manual tuning of parameters, which can be time-consuming and error-prone.

In object detection, deep learning algorithms are typically divided into two main categories: two-stage models that provide higher accuracy, and one-stage models that offer faster processing [1]. However, the application of these advanced algorithms, such as Mask R-CNN [2] and YOLO [3], to radar target detection is challenging due to the fundamental differences in the type of data collected. Radar sensors gather complex numbers that lack spatial locality, which is different from the pixel-based information these algorithms are built to process. In this study, we focus on using CNNs and machine learning to identify radar targets, specifically aiming to predict their azimuth and elevation. Our objective is to develop a target detection system using CNNs that overcomes the limitations of traditional signal processing techniques and improves radar performance.

Radar transmits radio waves and detects their reflection on objects to determine their properties. MIMO (Multiple Input Multiple Output) radar uses multiple transmit and receive antennas to improve radar performance. Normally, complex formulas are used to extract features from radar data which is called traditional signal processing. The captured radar data is often called the radar-data-cube since it is formed in a 3D matrix of (time-signal samples, pulses, and virtual receivers). Here we are interested in the third step which is finding a target's azimuth, elevation, magnitude, and phase with Deep Learning Techniques as a "proof of concept".

Traditional signal processing methods are outdated and have problems that formulas cannot overcome. These are interference which is detecting a weak target next to a strong target and reflection which is when signals scatter and create blind spots in detection. While reviewing the literature we noticed that this is typically done in 3 blocks using pre-compiled models to detect targets from the radar data. However, they are just detecting the targets and classifying them. We have elected to focus on predicting the azimuth and elevation of a target to integrate with traditional methods.

We started to build a model for one-target samples. After deciding on the structure of the model, which is a convolutional neural network (CNN), and fine-tuning hyperparameters, we achieved Mean Square Errors (MSE) of 0.149 for azimuth and 0.168 for elevation on 5000 test samples. We then built and trained a CNN using a dataset of 72,000 samples, each with two targets, achieving MSEs ranging from 0.838 to 1.845 on 8000 test samples. Our study explains why target detection cannot be performed using only the last phase of MIMO radar data and presents models that can be used instead, along with their hyperparameters. This will also shed light on future studies. Finally, cross-checking the calculations made using the data obtained here with traditional methods will open the way for studies that will obtain more accurate results.

Artificial intelligence and machine learning have been effective techniques in recent years for enhancing radar performance. In particular, Convolutional Neural Networks (CNNs) have demonstrated promise in the detection and classification of objects in radar data.

The process of radar target detection can be broken down into three fundamental stages: detection, classification, and tracking. This method utilizes a radar data cube dataset to effectively train a machine

learning (ML) model. Each radar data cube contains a 3D matrix of (time-signal samples, pulses, and virtual receivers) for extracting the target features such as size, velocity, range, elevation, and azimuth. Target detection entails finding prospective targets in the radar data, target classification entails categorizing each target (e.g., an airplane, a bird, etc.), and target tracking entails monitoring each target's movement over time. The common approach when using AI make use of all this information and forgo traditional signal processing methods to learn entirely from scratch. Instead, we have opted to combine AI with traditional approaches with the context-free part of the whole data cube, even though there has been a lot of study on utilizing AI for target detection and classification.

In our method, we use the part of the radar data cube that consists of virtual receivers to train a CNN model with deep learning. The reason for this is that conventional methods are more efficient at other steps. Azimuth and elevation of the target are output by the model. To achieve high accuracy in predicting the azimuth and elevation of the target, we fine-tuned the hyperparameters in our model. We tested the performance of our CNN model on data sets of different sizes and complexity.

The incorporation of machine learning and artificial intelligence is the latest chapter in the long history of continuous innovation in radar technology. Our goal is to improve the accuracy and robustness of radar systems by focusing on the prediction of azimuth and elevation of the target, paving the way for further research in this field. We believe that our approach could be useful for various applications such as autonomous vehicles, air traffic management, and military surveillance.

To summarize, this work presents a novel method for radar target detection using CNNs, especially for determining the azimuth and elevation of a target as an example. Our work demonstrates the potential of CNN models to improve radar performance and helps in the development of more reliable and accurate radar systems, especially for cases where target power is distributed over multiple bins.

2. LITERATURE REVIEW

Radar target detection is an important task in a variety of applications, including FMCW radar systems for motor vehicles [4], maritime traffic surveillance, and air traffic control. It is a system that uses radio waves to detect objects, their distance, direction, and speed. In recent years, machine learning techniques such as artificial neural networks and deep learning have been applied to improve the accuracy and efficiency of radar target detection.

A comprehensive review of machine learning techniques used in radar signal processing was provided by Lang et al. (2020), covering a wide range of topics such as target detection, classification, and tracking [5]. Similarly, Jiang et al. (2022) provided a review of the various artificial neural networks and deep learning techniques used in radar target detection [6]. These studies highlight the potential of machine learning techniques to improve the accuracy and efficiency of radar target detection.

Several studies have proposed adapting the YOLO (You Only Look Once) model for radar target detection. Kim et al. (2020) proposed a YOLO-based approach for simultaneous target detection and classification in FMCW radar systems for vehicles [4] and achieved high accuracy and real-time performance. Zhou et al. (2019) proposed YOLO-RD, a lightweight object detection network for range-Doppler radar imaging [7]. Lira-YOLO, a lightweight model for ship detection in radar images [8], was proposed by Long et al. (2020), which achieves high accuracy while maintaining real-time performance.

Pica et al. (2021) proposed a new SAR target detection approach based on YOLO and very deep multicanonical correlation analysis [9], which achieves high accuracy and robustness to variations in target orientation and aspect angle.

In addition, Baird et al. (2020) proposed a CNN-LSTM network for improving target detection in real maritime long-range surveillance radar data [10], which achieves high accuracy and robustness to variations in target orientation and aspect angle. Kumar and Kumar (2021) proposed a deep convolutional neural

network-driven neuro-fuzzy system for moving target detection from radar signals [11], which achieves high accuracy and robustness to variations in target motion.

Zhang (2022) provided a survey of the various convolutional neural network-based approaches that have been applied to target detection in SAR images [12]. The study covers a range of topics, including target detection, classification, and tracking, and provides an overview of the state of the art in this field. These studies demonstrate the potential of machine learning techniques, especially YOLO-based approaches, to improve the accuracy and efficiency of radar target detection.

In summary, machine learning techniques, especially those based on YOLO, utilize the entirety of the data to generate localized outcomes, showing considerable promise in enhancing the accuracy and efficiency of radar target detection across various applications. However, it is important to note that these methods are not directly comparable to our approach, which integrates machine learning CNN models with traditional techniques to accurately pinpoint the target's position. Additionally, the specific data used in our project does not support target localization in the manner typical of such images.

This study includes many carefully planned and conducted empirical experiments. Rather than detailing the findings of each experiment, summaries of the results are provided in their respective sections. This allows readers to easily follow and understand the specific details of each experiment. In the conclusion, the most important findings are discussed in depth, according to the main goals of the study. This approach clearly presents the overall framework and key findings of the study, while also giving readers access to detailed analyses of the experiments.

3. DATA SYNTHESIS

Training and test data are synthesized using a monostatic MIMO radar with 16 receivers and 16 transmitter elements without loss of generality. The received signal pattern for the antenna array at the direction (u, v) can be calculated by

$$g(u, v) = \mathbf{b}\mathbf{r} \quad (1)$$

where the received signal at the virtual receivers (VRXs) form the received signal (column) vector \mathbf{r} of length P , and \mathbf{b} is the steering (column) vector evaluated at (u, v) . One can oversample (u, v) uniformly for the received signal pattern

$$u_m = \frac{2m'}{Mq_\phi} - 1, \quad \text{for } 0 \leq m' < Mq_\phi \quad (2)$$

$$v_n = \frac{2n'}{Nq_\theta} - 1, \quad \text{for } 0 \leq n' < Nq_\theta \quad (3)$$

and where the received signal is the superposition due to each target

$$r_{rx,s}(p) = \sum_{t=1}^T \sigma_{c,t} e^{j\pi(mu_t + nv_t)} \quad (4)$$

where T is the total number of targets in the far-field, and $p = 1, 2, \dots, P_s < MN$ are the VRXs created by available M TX and N RXs located on the grid points (m, n) . Equation (4) provides the received signal at the VRX elements and (1) provides the synthesized received pattern to measure the radar performance metrics, namely, the peak-to-side-lobe ratio (PSLR) and the beam width (BW) calculated in the usable field of view (uFOV) of the antenna. The SNR of signals is calculated using normally distributed noise at the antenna elements.

4. DATASET

We have utilized two distinct types of datasets, each comprising sensor data, target azimuth, elevation, absolute amplitude, and SNR. Sensor data consists of 192 complex numbers representing raw radar data values. Azimuth and elevation denote the polar coordinates of the target. Absolute amplitude measures the target's reflectivity, and SNR indicates the noise level in the data.

One approach to handling radar signal data in deep learning involves using neural networks specifically designed to process complex-valued inputs, weights, and activations. This method does not require additional preprocessing and is straightforward but remains underexplored. In our exploration of using deep learning techniques for traditional radar signal processing in object detection, our primary goal is to leverage state-of-the-art object detection models, such as YOLO, which are typically applied to 2D or 3D image inputs. Consequently, we have chosen to propose baseline CNN models for this purpose. Accordingly, we have implemented basic preprocessing of the complex numbers. This preprocessing involves treating the real and imaginary parts of each number as separate features and exploring additional properties that can be derived from complex numbers, such as their angles.

The general structure of the datasets remains consistent, differing primarily in the number of targets and noise levels. Specifically, the single-target dataset contains 180,000 samples with mixed noise values, while the two-target dataset includes 90,000 samples, each with a 20dB noise level. We have partitioned each dataset into training, validation, and test sets, with ratios of 64%, 16%, and 20%, respectively.

5. EXPERIMENTS AND RESULTS

This section describes the experiments performed with two different data sets and the results obtained. First, we focused on training CNN models and optimizing hyperparameters to improve their performance. Building on the findings from these initial experiments, we further developed our CNN models to improve their effectiveness in dual-target scenarios. The following subsections describe the methodology applied, the experimental setups, and the results of these efforts, highlighting how the iterative refinements have incrementally improved the accuracy and effectiveness of our target detection models.

5.1 Experiments on Single-Target

We began our experiments using a simple CNN architecture to determine if deep learning could effectively learn azimuth and elevation values, compared to traditional signal processing methods. Our initial model, shown in Figure 1, used one-dimensional convolutional layers and dense layers. We experimented with the model by adding more convolutional and dense layers and placing max pooling layers between them for enhanced performance. We also included dropout layers to help prevent overfitting.




Figure 1. Initial CNN model with 1D convolutions

As we refined our model, several critical questions emerged regarding the optimal setup for our specific problem. Key considerations included:

1. Choosing additional input features beyond the real and imaginary parts, with options ranging from 192×2 to $192 \times N$.
2. Deciding on the input shape, with possibilities such as 192×3 , 3×192 , or 571×1 to manage three features from 192 sensors.

3. Selecting between one-dimensional and two-dimensional convolution types.
4. Investigating the impact of various layer types such as pooling and dropout layers on model performance.

Instead of conducting extensive experiments to finalize these parameters, we used an intuitive approach to determine the most effective settings for our dataset of single-target samples. In our investigations into the optimal configuration for our CNN model tailored for a single-target dataset, we arrived at several key conclusions from the considerations outlined above. The decisions that yielded the best results are summarized as follows:

- **Input Shape:** The input shape of 192 x 3 (real part, imaginary part, and angle) proved to be the most effective.
- **Convolution Layers:** Using two convolutional layers provided the best performance. Two-dimensional (2D) convolution was found to be slightly more effective than one-dimensional (1D) convolution.
- **Pooling Layers:** Contrary to expectations, max-pooling layers negatively impacted our model's performance. While these layers generally reduce overfitting and computational load by compressing feature maps, they also lead to the loss of critical information, which is especially detrimental in precise tasks such as single-target detection.
- **Dropout Layers:** The inclusion of dropout layers was beneficial. These layers helped prevent overfitting by randomly dropping units during the training process.

According to these settings, the results of the best-performing model with 2D convolution layers are shown in Table 1. In addition to Mean Square Error (MSE), we used an additional metric called 'Angle Error' for our evaluations. This metric is calculated by taking the square root of the sum of the squares of the azimuth and elevation errors for each prediction.

Table 1. Results for single-target dataset

	Azimuth	Elevation	Angle
MSE	0.149	0.168	0.253
Std	0.132	0.159	0.171
50%	0.112	0.128	0.219
Max Error	1.082	2.457	2.458

5.2 Experiments on Two Targets with Equal RcSS

Moving to a two-target dataset, we adapted our best model from the single-target experiments to handle multiple targets without changing the hyperparameters. This required reworking the output layer to perform regression on multiple azimuth and elevation values simultaneously. To better understand the input structure, Figure 2 provides an overview of the sensor and target data and illustrates a single example from the dataset.

Table 2. Sample values from the two-target dataset

	Sensor Data	Num. of Targets	Target-1 Azimuth	Target-1 Elevation	Target-2 Azimuth	Target-2 Elevation
	1 -0.393112, 0.254718	2	-10.424340	-4.574590	79.002089	-8.630493
	2 0.656807, 0.418274
Data-1
	191 -1.289922, -0.102665
	192 -0.504360, 0.784353

In our investigation of the two-target dataset, we evaluated various modifications to our CNN model. In this section, we summarize the results, focusing on which modifications improved accuracy and which did not. We explain the successful techniques that improved the performance of our model, as well as the

modifications that fell short of expectations. These findings are important for refining our approach to CNN architectures for complex radar signal processing tasks with multiple targets. In the following, we divide the results into two categories to provide a clear analysis of our experimental results.

Improvements in Accuracy:

- **Changing Input Shape and Parameters:** Adding the magnitude of real and imaginary values and Cartesian x and y values to the input parameters, along with changing the filter size and adding an extra dense layer, improved the model's accuracy.
- **Increased Output in Dense Layer:** Modifying the output layer to include Angle1 and Angle2 improved accuracy, though results were still not optimal.
- **Optimization Adjustments:** Switching to the relu activation method, adam optimizer, and mae for the loss function were determined as the best parameters.
- **Training Duration:** Extending training to 200 and 300 epochs showed slight improvements.

That Did Not Help:

- **Max Pooling Layer:** Adding max pooling layers negatively affected the model.
- **Additional Convolutional and Dense Layers:** Initially adding more layers increased the error rate without reaching desired levels.
- **Change in Activation Methods:** Switching to elu and selu activation methods, and later mixed methods (tanh and sigmoid), did not yield positive effects.
- **L1 and L2 Kernel Regularizers:** Both L1 and L2 regularizers did not improve the model significantly.
- **Extended Training Beyond 300 Epochs:** Further extending training led to overfitting, without significantly lowering the maximum error rate.
- **Swapping Target Data in Problematic Subsets:** Attempting to address issues in a subset of the data by swapping azimuth and elevation of targets did not resolve the high error rates.

Table 3. Results for two-target dataset

	Azimuth1	Elevation1	Angle1	Azimuth2	Elevation2	Angle2
MSE	0.838	1.845	2.211	0.934	0.968	1.875
Std	1.324	1.619	1.895	1.229	1.463	1.637
50%	0.504	1.412	1.682	0.611	0.560	1.447
Max Error	14.730	14.372	14.965	14.954	14.573	13.482

Transitioning to a two-target dataset, we adapted our best model from the single-target experiments to handle multiple targets.

6. CONCLUSION AND FUTURE WORK

In this study, we proposed and evaluated CNN models for azimuth and elevation estimation in radar target detection, focusing on both single and dual-target scenarios. Our experiments demonstrated that using two-dimensional convolution layers, a specific input shape (including the angle, magnitude of real and imaginary values, and Cartesian x and y values), and dropout layers significantly improved model performance. While we aimed to apply deep learning object detection architectures like YOLO for multiple target detection, the nature of our data—consisting only of complex signal numbers—prevented us from converting it into spatial information suitable for region proposal and object localization. Our approach

shows promise compared to traditional radar processing methods and offers a potential direction for future research in radar signal processing.

In future work, we plan to extend our research to the following areas:

- **In-Cabin Detection:** Identifying the presence of children or pets inadvertently left inside a vehicle.
- **Fall Detection:** Monitoring for fall incidents to enhance the safety of the elderly.
- **Posture Detection:** Analyzing posture for health and safety applications, and others.

Additionally, we will explore multi-target scenarios, integration with traditional methods, and the potential of incorporating an autoencoder model into our input layer to better represent radar signals.

7. AUTHOR CONTRIBUTIONS

Ibrahim Riza Hallac: Conceptualization, Methodology, Validation, Formal analysis, Investigation, Resources, Data curation, Writing – original draft, Writing – review & editing.

Deniz Akbaba and Gökhan Gökce: Equally contributed to the development of the methodology, conducting experiments, and reporting the results.

S. Gokhun Tanyer: Proposed the idea, administered the project and supervision, created the datasets, and contributed to review & editing.

Peter F. Driessen: Project administration, funding acquisition, and contributed to review & editing.

REFERENCES

- [1] Z.-Q. Zhao, P. Zheng, S. Xu, and X. Wu, "Object detection with deep learning: A review," *IEEE Trans. neural networks Learn. Syst.*, vol. 30, no. 11, pp. 3212–3232, 2019.
- [2] K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask r-cnn," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 2961–2969.
- [3] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 779–788.
- [4] W. Kim, H. Cho, J. Kim, B. Kim, and S. Lee, "YOLO-based simultaneous target detection and classification in automotive FMCW radar systems," *Sensors*, vol. 20, no. 10, p. 2897, 2020.
- [5] P. Lang et al., "A comprehensive survey of machine learning applied to radar signal processing," *arXiv Prepr. arXiv2009.13702*, 2020.
- [6] W. Jiang, Y. Ren, Y. Liu, and J. Leng, "Artificial neural networks and deep learning techniques applied to radar target detection: A review," *Electronics*, vol. 11, no. 1, p. 156, 2022.
- [7] L. Zhou, S. Wei, Z. Cui, and W. Ding, "YOLO-RD: A lightweight object detection network for range doppler radar images," in *IOP Conference Series: Materials Science and Engineering*, 2019, vol. 563, no. 4, p. 42027.
- [8] Z. Long, W. E. I. Suyuan, C. U. I. Zhongma, F. Jiaqi, Y. Xiaoting, and D. Wei, "Lira-YOLO: A lightweight model for ship detection in radar images," *J. Syst. Eng. Electron.*, vol. 31, no. 5, pp. 950–956, 2020.
- [9] M. Amrani, A. Bey, and A. Amamra, "New SAR target recognition based on YOLO and very deep multi-canonical correlation analysis," *Int. J. Remote Sens.*, vol. 43, no. 15–16, pp. 5800–5819, 2022.
- [10] Z. Baird, M. K. McDonald, S. Rajan, and S. J. Lee, "A cnn-lstm network for augmenting target detection in real maritime wide area surveillance radar data," *IEEE Access*, vol. 8, pp. 179281–179294, 2020.

- [11] M. Bharat Kumar and P. Rajesh Kumar, "Deep Convolutional Neural Network driven Neuro-Fuzzy System for Moving Target Detection Using the Radar Signals," J. Inf. \& Knowl. Manag., vol. 21, no. 01, p. 2250010, 2022.
- [12] Y. Zhang and Y. Hao, "A survey of SAR image target detection based on convolutional neural networks," Remote Sens., vol. 14, no. 24, p. 6240, 2022.