


MÜHENDİSLİK ALANINDA YAPAY ZEKA - 2

Editörler:

Prof. Dr. Murat SARIKAYA

Doç. Dr. Mustafa Kemal BALKİ

Öğr. Gör. Volkan ÇAVUŞ



MÜHENDİSLİK ALANINDA YAPAY ZEKA-2

EDİTÖRLER

Prof. Dr. Murat SARIKAYA
Doç. Dr. Mustafa Kemal BALKİ
Öğr. Gör. Volkan ÇAVUŞ

BÖLÜM YAZARLARI

Prof. Dr. Cenk SAYIN
Doç. Dr. Dilek GÜMÜŞ
Doç. Dr. Fatih GÜMÜŞ
Dr. Öğr. Üyesi Ahmet KARAOĞLU
Dr. Öğr. Üyesi Hasan DİRİK
Dr. Öğr. Üyesi Hüseyin ŞAHİNER
Dr. Öğr. Üyesi Salih DAĞLI
Öğr. Gör. Dr. Hüseyin SÖYLER
Öğr. Gör. İsmail Umut DURAN
Öğr. Gör. Yakup İRİM

Akademik unvan ve harf sırası gözetilerek sıralanmıştır.

Bu kitapta yer alan her bölümün tüm sorumluluğu (görseller, tablolar, çizelgeler, çizimler, grafikler, direkt alıntılar, etik/kurum izni vb.) yazarlara aittir.

Herhangi hukuki bir olumsuzlukta Çizgi Kitabevi Yayınları ve kitap editörü hiçbir konuda bir yükümlülük ve hukuki sorumluluğu kabul etmez, hukuki yükümlülük altına alınamaz. Her türlü hukuki yükümlülük ve sorumluluk ilgili bölüm yazar(lar)ına aittir.

Çok bölümlü/yazarlı olan bu kitap maddi bir değer ile alınıp satılamaz. Kitapta yer alan bilgiler alıntı yapılmak ve ilgili alıntıya atıf yapılmak koşulu ile kaynak gösterilmek üzere bilimsel ya da ilgili araştırmacılar tarafından kullanılabilir.

ÇİZGİ
K İ T A B E V İ

Çizgi Kitabevi Yayınları (e-kitap)
Eğitim Bilim

Genel Yayın Yönetmeni
Mahmut Arlı

©Çizgi Kitabevi
Aralık 2024

ISBN: 978-625-396-383-5
Yayıncı Sertifika No: 52493

KÜTÜPHANE BİLGİ KARTI
- Cataloging in Publication Data (CIP) -
EDİTÖRLER

SARIKAYA, Murat | BALKİ, Mustafa Kemal | ÇAVUŞ, Volkan
MÜHENDİSLİK ALANINDA YAPAY ZEKA-2

Sayfa Düzeni ve Kapak Tasarımı
Ozsum Academy
Tel: +90 541 191 57 41

Baskıya Hazırlık: Çizgi Kitabevi Yayınları
Tel: 0332 353 62 65- 66

ÇİZGİ KİTABEVİ

Sahibiata Mah. Alemdar Mah.
M. Muzaffer Cad. No:41/1 Çatalçeşme Sk. No:42/2
Meram/**Konya** Çağaloğlu/**İstanbul**
(0332) 353 62 65 - 66 - (0212) 514 82 93
www.cizgikitavebi.com
f t i / cizgikitavebi

İÇİNDEKİLER

İÇİNDEKİLER	iv
ÖNSÖZ	v
BÖLÜM 1: ATIKSU ARITIMINDA YAPAY ZEKA UYGULAMALARI <i>Dilek GÜMÜŞ & Fatih GÜMÜŞ</i>	1-21
BÖLÜM 2: İLETİM HATTI KORUMADA BULANIK MANTIK UYGULAMALARI <i>Hasan DİRİK</i>	22-54
BÖLÜM 3: KALİTE KONTROL PROSESLERİNDE YAPAY ZEKA UYGULAMALARI <i>Yakup İRİM & Salih DAĞLI</i>	55-83
BÖLÜM 4: BİYODİZEL KULLANILAN BİR DİZEL MOTORDA ÇOK KRİTERLİ KARAR VERME YÖNTEMİYLE OPTİMUM ÇALIŞMA KOŞULLARI VE YAKIT KARIŞIMININ BELİRLENMESİ <i>Cenk SAYIN</i>	84-111
BÖLÜM 5: YAYILMA MODELLERİYLE EL ALETLERİNİN GÖRSEL TEMSİLİ <i>İsmail Umut DURAN</i>	112-129
BÖLÜM 6: TÜRKÇE DOĞAL DİL İŞLEME VE GELECEĞİ <i>Ahmet KARAOĞLU</i>	130-145
BÖLÜM 7 NÜKLEER MÜHENDİSLİKTE YAPAY SİNİR AĞLARININ UYGULAMALARI <i>Hüseyin ŞAHİNER</i>	146-157
BÖLÜM 8 ALTERNATİF ENERJİ KAYNAKLARININ KULLANIMI İLE FOSİL YAKIT KULLANIMININ YAPAY ZEKA İLE KARŞILAŞTIRILMASI VE MALİYET ANALİZİ <i>Hüseyin SÖYLER</i>	158-172

Bölüme ulaşmak için 

ÖNSÖZ

Son yıllarda yapay zekâ (Artificial Intelligence, AI), bilim ve mühendisliğin her alanında ortaya çıkan problemlere devrim niteliğinde çözümler sunmaktadır. Bu kitap, içerdiği kapsamlı konular sayesinde farklı disiplinlerde yapay zeka uygulamalarının potansiyelini ortaya koymak amacıyla literatüre kazandırılmıştır. Bu kitabın amacı hem akademik camiada hem de endüstri ve diğer kullanıcılar arasında bu teknolojilere dair farkındalığı artırmak, mevcut gelişmeler hakkında okuyucuları haberdar etmek ve yenilikçi yaklaşımlar ortaya koymaktır.

Kitap içeriğine kısaca değinecek olursak, ilk olarak günümüzün önemli konularından biri olan çevresel sürdürülebilirlik, yapay zeka perspektifinden ele alınmaktadır. “Atık Su Arıtımında Yapay Zeka Uygulamaları” başlıklı bölümde, doğal kaynakların korunmasına yönelik yenilikçi çözüm önerileri sunulmaktadır. Bunun yanı sıra, elektrik mühendisliği alanında önemli bir konu olan güç sistemleri için bir bölüm bulunmaktadır. Bu bölümde enerji sistemlerinde güvenliği arttırmak için yapay zeka uygulamalarından bahsedilmektedir.

İmalat sektöründen sağlık sektörüne kadar geniş bir yelpazede yer bulan kalite kontrol süreçleri, yapay zekanın yeteneklerinden faydalanılarak daha verimli hale getirilmesi için farklı yaklaşımlar sunmaktadır. Kitabın bölümlerinde yer verilen “Kalite Kontrol Proseslerinde Yapay Zeka Uygulamaları” bu bakımdan değerli görülmektedir. Bunun yanında, “Yapay Zeka ile Resim Oluşturma Eğitimi” gibi bölümler ise, yapay zeka uygulamalarının sanat ile olan etkileşimine örnek teşkil etmektedir.

Dil işleme teknolojilerinin gelişimi, özellikle Türkçe gibi dil yapısı karmaşık diller için ayrı bir öneme sahiptir. “Türkçe Doğal Dil İşleme ve Geleceği” bölümü, bu alanda karşılaşılan zorluklar ve bu zorluklara yönelik çözümleri kapsamlı bir şekilde ele almaktadır. Nükleer enerji konusu dünyada enerji üretiminde önemli ve kritik bir yere sahip olmasına rağmen güvenirliliği konusunda halen tartışmalar devam etmektedir. Bu kitapta, “Nükleer Alanda Yapay Sinir Ağları Kullanımı” bölümü nükleer enerjinin daha güvenli ve verimli kullanılabilmesi için yapay sinir ağlarının sunduğu fırsatlara odaklanmaktadır.

Son olarak, enerjinin önemi ve ekosistemimiz üzerindeki etkilerine değinen “Alternatif Enerji Kaynaklarının Kullanımı ile Fosil Yakıt Kullanımının Azaltılması” başlıklı bölüm, temiz enerji kullanımı ve çevresel sürdürülebilirlik için farkındalık yaratmayı amaçlamaktadır.

Mühendislik ve bilim dünyasında yapay zeka uygulamalarına dair çeşitli bilim alanlarında farklı perspektifler sunan bu kitabın, akademisyenlere, öğrencilere ve sektör çalışanlarına ilham kaynağı olacağına inanıyoruz. Kitabın hazırlanmasında emeği geçen tüm yazarlara ve yayınevi çalışanlarına en içten teşekkürlerimizi sunuyoruz.

Keyifli ve ilham verici okumalar dileğiyle,

EDİTÖRLER

Prof. Dr. Murat SARIKAYA
Doç. Dr. Mustafa Kemal BALKI
Öğr. Gör. Volkan ÇAVUŞ
Aralık 2024

BÖLÜM 1

ATIKSU ARITIMINDA YAPAY ZEKA UYGULAMALARI

Dilek GÜMÜŞ

Doç. Dr., Sinop Üniversitesi, Mühendislik ve Mimarlık Fakültesi,
Çevre Mühendisliği Bölümü, dgumus@sinop.edu.tr

 0000-0001-7665-3057

Fatih GÜMÜŞ

Doç. Dr., Sinop Üniversitesi, Fen Edebiyat Fakültesi,
Biyoloji Bölümü, fgumus@sinop.edu.tr

 0000-0002-4660-7591

İçinde bulunduğumuz yüzyılda dünyanın hızlı nüfus artışı ve yoğun sanayileşmesiyle birlikte çevre kirliliği, su kaynakları üzerinde olumsuz etkileri olan küresel bir sorun haline gelmiştir. Suya olan talebin artmasının yanı sıra su kirliliği sorunu da giderek ciddi bir hal almış ve atıksu arıtımı önem kazanmıştır.

Tüm canlıların hücresel faaliyetlerinin gerçekleştiği biyolojik sistemlerin yanı sıra çok sayıdaki endüstriyel tesisler ve hatta su ve atıksu arıtma tesisleri dahi sürdürülebilir temiz suya ihtiyaç duyarlar. Her yıl yaklaşık 300-400 milyon ton kirleticinin küresel su kaynaklarına deşarj edildiği düşünüldüğünde bu durumun su kaynaklarımız üzerinde ne denli ciddi bir tehdit oluşturduğu anlaşılmaktadır (Tariq ve Mushtaq, 2023). Küresel iklim değişikliğinin su kaynaklarımız üzerindeki olumsuz etkilerini ve enerji üretimindeki su kullanımını da hesaba kattığımızda bu durum daha da karmaşık hale gelmekte ve atıksu arıtımının önemini ortaya koymaktadır (Teodosiu vd., 2018).

Atıksuların arıtımı, kullanılmış suların tekrar çevreye deşarj edilmeden önce kirleticilerden arındırılmasını sağlayan bir işlemdir. Belediye ve endüstriyel atıksu arıtma tesisleri, alıcı ortama deşarj edilebilecek kalitede atıksu oluşturmak üzere tasarlanmıştır. Tesislerden çıkan atıksuların çevre mevzuatlarının gerektirdiği deşarj kalite standartlarına uyması beklenir. Deşarj standartlarını sağlayacak etkin, çevre dostu ve düşük maliyetli bir arıtma sisteminin tasarımı sınırlı su kaynaklarımızı korumak için kritik öneme sahiptir.

Dünyanın dört bir yanındaki araştırmacılar suyla ilgili uygulamaları iyileştirmenin yollarını aramaktadır. Yeni yöntemler geliştirmek ya da mevcut yöntemler için verimliliği artırmak ve tesislerin enerji tüketimlerini düşürmek için etkili ve yenilikçi teknolojilere acilen ihtiyaç duyulmaktadır (Malviya ve Jaspal, 2021). Son birkaç yıldır yapılan çalışmalarda ise bu sorunu

çözmeye yardımcı olmak için en uygun, ekonomik ve akıllı modelleri geliştirmek için yapay zeka uygulamalarından faydalanılmaya odaklanılmıştır (Lowe vd., 2022).

Yapay zeka (YZ), sorunları insan zekası sistemine benzer bir şekilde çözen, akıllı sistemler inşa etmekle ilgilenen, bilgisayar biliminin bir dalıdır. YZ uygulamalarındaki birincil amaç, öğrenme, algılama, problem çözme ve muhakeme etme gibi insan bilgisi ve yeteneği gerektiren işlevleri bilgisayar vasıtasıyla geliştirmektir (Alam vd., 2022). Mevcut verilere dayalı bir sistemi öğrenme, uyarlama ve karar alma konusunda benzersiz özellikleri nedeniyle son dönemde hızlı bir yükseliş yaşıyor ve YZ tabanlı sistemlerin entegrasyonu nedeniyle kullanım alanı sürekli olarak genişliyor (Ghahramani vd., 2020). Hayatın her alanında hızla büyüyen yapay zeka, ulaşımdan sağlığa, akıllı şehirlerden e-ticarete, finansdan akademiye aklımıza gelebilecek pek çok alanda gerçek dünya uygulamalarına sahip (Al Kuwaiti vd., 2023; Bharadiya vd., 2023; Allam ve Dhunny, 2019) ve daha birçok önemli alanda etki yaratması bekleniyor.



Hemen hemen tüm disiplinler arası alanlarda yer bulan YZ sistemlerine su endüstrileri de yatırım yapmaktadır. Araştırmalara göre bu yatırımların 2030 yılına kadar 6,3 milyar dolara ulaşması öngörülmektedir. YZ sistemlerine bağlı olarak arıtma tesislerindeki kimyasal kullanımının optimize edilmesi ile tesislerin işletme maliyetlerinde yaklaşık %20 ila %30 oranlarında tasarruf edilmesi beklenmektedir (Alam vd., 2022). Bununla birlikte yapay zekanın su arıtımındaki uygulamaları ile sistemlerin esnekliğine, birbirleriyle entegrasyonuna, tasarım kolaylığına ve geliştirilebilirliğine olanak tanınması nedeniyle de süreci kolaylaştırıcı rol oynayacağı tahmin edilmektedir.

Bu bölümde su kirleticilerine ve hangi sektörlerin atıksu üretebileceğine dair genel bir bakış açısı sağlanması için ilk olarak atıksularda bulunması muhtemel olan kirleticilerden ve atıksuların arıtımında kullanılan yöntemlerden bahsedilmektedir. Daha sonra ise atıksu arıtımında yapay zeka modellerinin kullanımı açıklanmaktadır.

ATIKSULARDA BULUNAN KİRLİTİCİLER ve KİRLİLİK KAYNAKLARI

Atıksular en genel ifadeyle kentsel alanlardan, endüstrilerden ve tarımsal faaliyetlerden kaynaklanan atıksular olarak değerlendirilebilir (Şekil 1). Atıksularda bulunan kirleticiler de çıktıkları kaynağa göre değişkenlik gösterebilirler. Kentsel yerleşim, gelişmiş ülkelerde su kirliliğinin başlıca sebebidir. Kentsel alanlardan kaynaklanan evsel atıksular kategorisinde değerlendireceğimiz kanalizasyon sularında, biyolojik oksijen ihtiyacı (BOİ) ve kimyasal oksijen ihtiyacı (KOİ) yüksektir ve suda bulunan çözünmüş oksijen miktarını azaltır. Mikrobiyal kirlilik, tüketildiğinde tifo, kolera vb. gibi hastalıklara yol açan doğal bir su kirliliği biçimidir. Suda bulunan mikroorganizmalar görünmez ve sadece bazı yönlerden koku veya renk ile karakterize edilir. Suda fazla miktarda biyolojik olarak parçalanabilir maddelerin bulunması mikrobiyal büyümeyi teşvik ederek sudaki oksijen içeriğini tüketir. Bu, aerobik organizmaların yayılmasını azaltır ve sülfür, amonyak vb. gibi tehlikeli kimyasallar üreten anaerobik mikrobiyal büyümeyi artırır (Saravanan vd., 2021). Bununla birlikte kanalizasyon atıksularında farmasötik ilaç kalıntıları, yapay tatlandırıcılar, kişisel bakım ürünleri, böcek kovucular, hormonlar ve alev geciktiriciler gibi yeni ortaya çıkan kirleticiler de yer alabilir. Su kaynaklarındaki bu kirleticilerin bitkilere, karasal-sucul organizmalara ve diğer besin kaynaklarına ulaşması genel besin zincirinin etkilenmesine yol açabilir. Modern yaşamla beraber ortaya çıkan yeni kirleticiler atıksu karakteristiğini değiştirerek karmaşık etkileşimler oluşturabilir ve bu durum da geleneksel arıtma tesislerinde yeni tasarım kriterlerinin ortaya çıkmasına ve geleneksel teknolojilerin revize edilmesi zorunluluğuna yol açabilir (Shah vd., 2020). Kentsel alanlardaki katı atık depolama sahalarında oluşan sızıntı suları da son derece kirli bir atıksudur ve yeraltı ve yüzey sularını tehdit eden bir atıksu karakteristiğine sahiptir. Basit uçucu yağ asitlerinden, fenoller, hidrokarbonlar, klorlu alifatikler, fulvik ve humik maddeler ve inorganikler (iz elementler, ağır metaller) gibi yüksek molekül ağırlıklı bileşiklere kadar çeşitli organik madde türlerini içeren çok karmaşık bir atıksudur (Dereli vd., 2021).

Endüstriyel kökenli kirlilik ise çeşitli endüstrilerin üretim proseslerinden kaynaklanan atıksulardır. Muazzam atıksu miktarları, atıksu bileşimi ve endüstri sayısı göz önüne alındığında su kirliliğinin başlıca nedenlerinden biri olarak kabul edilmişlerdir. Endüstriyel atıksuda bulunan başlıca kirleticiler arasında ağır metaller, boyalar, pestisitler, herbisitler, ilaçlar ve diğer aromatik bileşikler yer alır. Tekstil, boya, madencilik ve petrokimya endüstrileri gibi pek çok endüstriden çıkan atıklar, insan sağlığı için tehlike oluşturan toksik kimyasallar içerir (Qin vd., 2020). Endüstriyel su kirliliği sektörel bazda değişkenlik gösterebilmektedir. Örneğin elektroliz, elektrokaplama ve metal eritme gibi çeşitli endüstriyel işlemler ve çevredeki kimyasal kirleticiler atıksuda ağır metal kirliliğine neden olmaktadır. Ağır metaller teratojenik ve kanserojen etkilerinden dolayı sağlık endişeleri nedeniyle sucul ortamlarda istenmeyen kirleticilerdendir (Saleh vd., 2022). Petrol endüstrisi, yüzey suyu ve yeraltı suyu kirliliğine en büyük katkıda

bulunanlardan biridir (Mroue vd., 2020). Petrol endüstrisinin yanı sıra, radyoaktif endüstrinin de su kirliliği sorunu üzerinde büyük bir etkisi vardır (Bonavigo vd., 2009). Gıda endüstrisi atıksuları karmaşık organik kirleticiler içerebildiği için yüksek konsantrasyonda Biyolojik Oksijen İhtiyacı (BOİ) içeren atıksulardır. Kok fabrikası atıksuyu çeşitli polinükleer hidrokarbonlar içerdiği için kirlilik kaynağı oluşturabilir. Kimya endüstrisinin atıksuyu, soğutma sıvıları olarak yaygın olarak kullanılan poliklorlu bifeniller gibi çeşitli kanserojen bileşikler içerebilir (Altowayti vd., 2022).

Tarım endüstrisi, dünya çapında temiz suyun en büyük kullanıcısıdır. Tarım faaliyetlerinin mevcut uygulaması arazinin ve ekosistemin bozulmasına neden olmuş ve tarımdaki su kirliliği sorunları modern uygulamalarla birlikte küresel olarak artmıştır. Tarımsal faaliyetlerden kaynaklanan su kirliliğine neden olan unsurlardan biri de yapay veya organik gübre kullanımlarıdır. Azot içeren gübrelerin bol miktarda kullanılması nedeniyle su kaynaklarının nitrit iyonu ile kirlenmesi giderek artmıştır. Nitrit iyonu, alkol, fenoller ve aminler gibi birçok organik bileşiğe karşı oldukça reaktif olan nitrik asit oluşturan suda bulunabilen en tehlikeli kimyasallardan biridir (Altowayti vd., 2019). Gübrelerin dışında, pestisitler de modern tarım uygulamalarında yaygın olarak kullanılmaktadır. Bazıları Avrupa'da yasaklanmış olan 1200'den fazla pestisit ve herbisit şu anda dünyada kullanılmaktadır (Rad vd., 2022). Dolayısıyla tarım arazilerinin atık suyu, yüksek konsantrasyonda pestisit veya herbisit içerebilme potansiyeli barındırmaktadır.

Sonuç olarak kentsel alanlardan kaynaklanan kanalizasyon atıksuları, çöp sahalarından sızmalar, endüstrilerden kaynaklanan deşarjlar, tarım arazilerinde pestisit ve gübrelerin aşırı kullanımı gibi etkenlerle su kaynaklarımız kirlenir ve su kalitesi sürekli değişir. Suyun kalitesini doğru bir şekilde tahmin etmek, hem su kirliliği kontrolü hem de doğru su yönetimi açısından oldukça önemlidir. Atıksu arıtma yönteminin seçiminde ve arıtma tesislerinin tasarımında atık suyun fiziksel, kimyasal ve biyolojik özellikleri dikkate alınır ve tasarım parametreleri bu doğrultuda belirlenir.



Şekil 1. Su Kirliliği Kaynakları

ATIKSU ARITIM YÖNTEMLERİ

Atıksuyun arıtılarak istenilen standartlara ulaştırılabilmesinde doğru arıtma teknolojinin seçimi son derece önemlidir. Arıtma sisteminin etkinliği kadar arıtmanın maliyeti ve yönetilmesi gereken çevresel etkiler de dikkate alınması gereken pek çok faktörü barındırmakta ve arıtma yönteminin seçiminde etkili olmaktadır. Atıksuların arıtılmasında çeşitli fiziksel, kimyasal, biyolojik ve fizikokimyasal yöntemler kullanılmaktadır. Fiziksel yöntemler çöktürme, filtrasyon ve gazdan arındırma gibi yöntemleri kapsamaktadır. Çöktürme işlemi, atıksu arıtımının birinci basamaklarından biridir. Sudaki kirletici parçacıkların yer çekimi ile çökerek sudan ayrılması işlemine karşılık gelir. Durgun su koşullarında süspanse haldeki partiküller dibe çökerek sıvıdan ayrılırlar. Filtrasyon işlemi, kirleticileri boyutlarına göre giderme prensibine göre uygulanan bir arıtma işlemidir. Prosesde kullanılan filtreler, suda bulunan kirletici türlerine göre arıtılmış suyun kullanım amacına göre değişkenlik gösterir. İki ana atıksu filtrasyon türü partikül filtrasyonu ve membran filtrasyonudur. Filtrasyon işlemi askıda kalan parçacıkları, partikül maddeleri , bakteri, virüs vb. gibi mikroorganizmaları ve diğer kimyasal kirleticileri gidermek için kullanılabilir. Suyu endüstriyel, tarımsal ve evsel amaçlar için yeniden kullanılabilir hale getirmek için kullanılan membran teknolojisi, farklı atıksu akışlarından gelen atık suyu arıtmak için ideal bir teknoloji olarak ortaya çıkmıştır. Membran teknolojisi, safsızlıkları temelde istenen seviyelere düşürmede ve atıksuları yeniden kullanıma sunmada başarılı olduğu keşfedilen en etkili teknolojilerden biridir (Bera vd., 2022).



Şekil 2. Atıksu Arıtma Yöntemleri

Gaz giderme işlemi ise çözülmüş gazların atıksudan uzaklaştırılması işlemine verilen isimdir. Sıvıdaki çözülmüş gaz miktarının gazın kısmi basıncıyla orantılı olduğunu belirten Henry yasasına dayanır. Gaz giderme, atıksudan karbondioksit gazının uzaklaştırılması için uygun

maliyetli bir yöntemdir ve gazı sıyırarak suyun pH'ını artırır (Cohen & Kirchmann, 2004). Amonyak sıyırma işlemi de kütle transferi prensibine dayanarak atık suyun hava ile temas ettirilerek atıksuda bulunan amonyak gazının sıyrıldığı bir yöntem olarak uygulanmaktadır (Kinidi vd., 2018).

Atıksudaki kirleticilerin uygun bir şekilde bertarafı veya son ürünlere dönüştürülmesi için çeşitli kimyasal işlemlerin kullanıldığı kimyasal ve fizikokimyasal arıtma yöntemleri mevcuttur. Bu yöntemlerden bazıları; Koagülasyon ve flokülasyon, kimyasal çöktürme, adsorpsiyon, iyon değişimi, ozonlama ve enerji yoğun sistemler olarak adlandırılan çeşitli elektrokimyasal ve ileri oksidasyon yöntemleridir. Fizikokimyasal bir yöntemi içeren koagülasyon ve flokülasyon işlemi çeşitli pıhtılaştırıcı kimyasalların yardımıyla kirleticileri uzaklaştırma prensibine dayanır. Çoğu durumda, koagülasyon ve flokülasyon işlemi aynı anda gerçekleştirilir. Koagülasyon yöntemi kullanılarak atıksudan %40 oranında organik madde ve azot giderilebilmektedir (Loloei vd., 2014). Kimyasal çöktürme, daha çok atıksulardan ağır metallerin uzaklaştırılması için kullanılan yöntemlerden biridir. Çözünen metal elementler ve çökeltici maddeler arasındaki kimyasal etkileşim yoluyla, iyonik metaller çözünmeyen parçacıklara dönüştürülür ve çöktürme ile sudan uzaklaştırılmış olur. Hidroksit çökmesi, karbonat çökmesi ve sülfür çökmesi uygulanan yöntemler arasındadır. Kimyasal çöktürme genellikle katyonik metallerin uzaklaştırılması için kullanılır.

Ozonlama işlemi, atıksu arıtımında daha çok mikro kirleticilerin oksidasyonunda ve dezenfeksiyon işlemlerinde kullanılır. Koku, tat ve renk veren maddelerin uzaklaştırılmasında etkin bir yöntemdir (Lim vd., 2022). Adsorpsiyon prosesi, atıksulardan organik ve inorganik kirleticilerin uzaklaştırılması için kirleticilerin bir adsorban üzerine fiziksel veya kimyasal bağlarla sabitlenmesi işlemini içermektedir. Su arıtımında yaygın olarak kullanılan yöntemlerden biridir. Genellikle kullanılan adsorbanlar aktif karbonlardır çünkü bunlar büyük gözenekli yüzey alanına, kontrol edilebilir gözenek yapısına, termo-kararlılığa, ve hazırlanan adsorban atık ürünlerden elde ediliyorsa, düşük maliyete sahiptir. Çeşitli giderim metodolojileri ile kıyaslandığında adsorpsiyon, ekonomikliği ve işletme kolaylığı nedeniyle en yaygın kullanılan yöntemlerden biri olarak kabul edilir (Largitte & Pasquier, 2016).

İyon değişimi atıksu arıtma proses tesislerinde demineralizasyon amacını yerine getirmek için bir iyonu diğeriyle değiştirmek için kullanılır. İyon değişim sistemleri genellikle döngüsel bir temelde çalıştırılan iyon değişim reçineleri içerir. Bu sistemlerde 2 tip iyon değişim reçinesinden faydalanılır, biri katyon reçineleri ve diğeri anyon değişim reçineleridir. Yaygın olarak kullanılan zeolitler, killerin dışında çeşitli sentetik iyon değişim reçineleri de kullanılmaktadır (Zhang vd., 2024). Son yıllarda, elektrokimyasal teknolojiler, atıksu arıtımı başta olmak üzere birçok çevresel soruna alternatif bir çözüm sunmaktadır. Arıtma yönteminde elektronların kullanımı çok yönlü,

verimli, uygun maliyetli, kolayca otomatikleştirilebilir ve temiz bir reaktif sağlamaktadır. Sistemin verimliliğinin en belirleyici yönü elektrot seçimindeki maliyet ve etkinliktir. Refrakter organik maddeler, mikroorganizmalar ve azot türleri gibi atık sularda normalde bulunan çok çeşitli kirleticilerin gideriminde etkinlikleri kanıtlanmıştır. Deponi alanlarından gelen sızıntı sularının arıtımında, petrokimya, tekstil, gıda ve tarım endüstrisi de dahil pek çok endüstriyel atıksular da bu teknoloji ile etkili bir şekilde arıtılabilmektedir (Martínez-Huitle & Panizza, 2018). Sistemlerin kompakt tasarımı, ve dezenfeksiyon yeteneklerinin yanında yenilenebilir enerji kaynaklarının kullanımındaki artışlar elektrokimyasal sistemleri atıksuyun yeniden kullanımına yönelik çalışmalar için uygun bir teknoloji haline getirmiştir.

Su arıtımında kullanılan biyolojik yöntemler çözünmüş ve askıda organik kimyasal bileşenlerin biyolojik bozunma yoluyla uzaklaştırıldığı sistemlerdir, optimum miktarda mikroorganizmanın organik maddeleri parçalaması için kullanıldığı, doğal, kendi kendini temizleme işlemini tekrarlamaları için uygulanan süreçlerdir. En yaygın kullanılan klasik aktif çamur sistemlerinde mikroorganizmalar atıksudaki organik maddeleri kullanırlar ve sedimantasyonla uzaklaştırılan yoğun biyokütleyle sahip yeni mikrobiyal hücreler üretirler. Bu sistemler düşük maliyet oranıyla karakterize edilirler ancak sistemde oluşan çamurun zaman zaman uzaklaştırılması gerektiği için ikincil bir maliyet söz konusu olabilir. Biyolojik işlemler aerobik, anaerobik ve anoksik koşullar gibi farklı reaktör ortamlarında gerçekleşir (Meena vd., 2019). Aktif çamur sistemlerinin farklı modifikasyonlarında nitrifikasyon ve denitrifikasyon gerçekleştirilerek azot ve fosfor gibi sudaki besin maddelerinin giderimi de sağlanarak sucul ortamlarda ötrofikasyon riski bertaraf edilmektedir (Narayanan & Narayan, 2019). Günümüz koşullarında, deşarj edilen atıksu miktarı artarken ve atık sularda bulunan kirletici türleri çeşitlenirken, atıksu arıtma yöntemleri geliştirilmeye devam etmektedir. Mevcut arıtma tekniklerinin her biri kendi içinde avantaj ve dezavantaj barındırmaktadır. Farklı arıtma tekniklerinin avantajlarını birleştiren ve dezavantajlarını azaltan hibrit sistemler de son dönemde araştırmacılar tarafından yoğun bir şekilde önerilmektedir (Kim vd., 2022; Ejraei vd., 2019).


Yapay zeka (YZ) tekniklerinin atıksu arıtımına entegrasyonu devrim niteliğinde bir yaklaşımdır (Safeer vd., 2022). Atıksu arıtımının sürdürülebilirliğini ve verimliliğini daha da artırmak ve karmaşık sorunlara çözüm bulmak için yapay zeka ve makine öğrenimi ve gibi son teknolojiyi içeren yeni bir araştırma dalgası ortaya çıkmıştır. Bu yeni yaklaşımlar, arıtma tesislerinin tasarımında parametrelerin optimizasyonunda, kapsamlı bir şekilde veri kümelerinin analizinde, büyük ölçekli arıtma proseslerinin gerçek zamanlı olarak tahmin edilmesinde ve karmaşık sorunlara akılcı çözümler üretmede büyük bir potansiyele sahiptir.

YAPAY ZEKA TEKNİKLERİ

Yapay sinir ağları (Artificial neural network)

Yapay sinir ağı (YSA), insan beynini ve sinir sistemini taklit eden ve beyindeki sinir ağları çalışma prensibine benzer şekilde hareket eden bir yapay zekâ dalıdır. YSA ampirik modellerin bir örneğidir ve karmaşık doğrusal olmayan süreçlerin matematiksel bir yaklaşımı yoluyla girdileri ve çıktıları ilişkilendirir (Matheri vd., 2021). Bir YSA'nın temel yapıları giriş katmanı, gizli tabakalar ve çıkış katmanı olarak 3 tabakadan oluşur (Şekil 3). Giriş katmanında verilerden oluşan girdinin ağırlıklı toplamının hesaplanmasıyla modele tanıtılması işlemi yapılır, gizli tabakalarda, veriler işlenir ve nihai olarak çıktı katmanında YSA sonuçlarının üretimi gerçekleşir (Çavuş & Sarıkaya, 2021; Wong, 2018). YSA'nın gizli katman sayısı arttıkça, YSA daha karmaşık doğrusal olmayan modeller oluşturabilir ve ifade yeteneği artar.

En yaygın kullanılan YSA modelleri çoğunlukla Tekrarlayan Sinir Ağları, Evrişimli Sinir Ağları, Bulanık Sinir Ağları ve Derin Sinir Ağları'nı içerir (Zhang vd., 2023).



Şekil 3. Atıksu arıtımı uygulamaları için YSA modeli örneği


Makine Öğrenmesi

Makine öğrenmesi (MÖ) yapay zekanın bir dalıdır. MÖ'nin temel amacı, verilerden öğrendiklerine dayanarak doğru tahminler veya kararlar alabilen tahmini modeller oluşturmak ve zor sistemleri yönetilebilir uygulamalara basitleştirmektir (Dey, 2016).

Makine öğrenmesi ile, bilgisayarın verinin bir kısmını öğrenerek karşılık gelen bilgi ve kuralları elde etmesinden sonra, verinin başka bir kısmının tahmin edilmesi sağlanır. Makine öğrenmesinin süreçleri şunları içerir: (I) Veri toplama ve temizleme; (II) Özellik mühendisliği; (III) Algoritmaların seçimi; (IV) Model değerlendirilmesi ve doğrulama. Bazı durumlarda iyi performans gösteren MÖ modelleri oluşturmak, doğrusal olarak gelişmeyebilir ve gerçek geri bildirimle dayalı uygun ayarlamalar gerektirebilir. Algoritma seçimi ve model eğitimi sürecinde, veri kümesinin

yetersiz veya kalitesinin düşük olduğu durumlar ideal eğitimi zorlaştırabilir. Daha sonra, örnek sayısını artırmak veya yanlış örnekleri silmek de dahil olmak üzere daha fazla veri kümesi oluşturmak gerekebilir. Elde edilen veriler mümkün olduğunca mevcut sorunu yansıtmalıdır. Veri kalitesi dağılımın çeşitliliğini içerir. Veriler oluşturulurken, gürültü verisini en aza indirme ve tarafsız örnekleme, veri kalitesi açısından önemlidir. Modellerin genelleme yeteneğini sağlamak için, eğitim ve test verilerinin genellikle aynı dağılımda örneklenmesi gerekir. Makine öğreniminde, genelleme yeteneği, geliştirilen bir modelin bilinmeyen verileri tahmin etme yeteneğini ifade eder. Örnekleme yöntemi temsili olmadığında, aşırı uyuma yol açabilir. Aşırı uyum, modelin eğitim setinde mükemmel tahmin performansı göstermesi, ancak doğrulama setinde ve test setinde zayıf performans göstermesi anlamına gelir. Veri kalitesini sağlamak üzere, büyük veri setlerinin mevcudiyeti, makine öğrenmesi yönteminde model eğitimini o kadar elverişli hale getirir. (Zhang* vd., 2023).

En yaygın kullanılan MÖ modelleri arasında Temel Bileşen Analizi, Karar Ağacı, Destek Vektör Makinesi, Parçacık Sürüsü Optimizasyonu, Rastgele Orman, K-En Yakın Komşu, Kendini Organize Eden Harita ve Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi gibi MÖ'de bu işlemleri gerçekleştirebilen birçok algoritma mevcuttur (Wang vd., 2023).



Derin öğrenme (DÖ), makine öğrenmesinin alt dalı olarak kullanılan bir teknolojidir. Artan veri sayısı ile bu verilen analizin yapılması, konuşmayı tanıma, görüntülerden nesne tanıma, tahmin yapma gibi pek çok görevi yapabilmek için tasarlanan bir algoritma sınıfıdır. Katman sayısı modelin derinliğini belirleyen bir unsurdur. Çok sayıda veri girişinden ayırt edici nitelikleri kendisi öğrenir. Sisteme veri girişi ne kadar çok olursa öğrenme o kadar iyi gerçekleşir ve tahminler gerçeğe o kadar yakın olur.

Arama Algoritması (AA)

Yapay Sinir Ağları (YSA) ve Makine Öğrenimi (MÖ) dışında, AA'lar da Genetik Algoritma (GA) ve Genetik Programlama (GP) dahil olmak üzere yaygın olarak kullanılan YZ modelleridir. GP,

biyolojik evrimsel süreçlerden esinlenmiş GA tabanlı bir evrimsel hesaplama tekniğidir. Regresyon, sınıflandırma ve optimizasyon sağlamak için bilgisayar programlamasının oluşturulmasını ve seçilmesini otomatikleştiren bir algoritmaya sahiptir. Diğer MÖ algoritmalarının aksine, GP, rastgele bir başlangıç popülasyonu üreterek ve ardından evrimleşmek için GA'yı kullanarak otomatik olarak gerçekleştirilir. GP, güçlü bir uyarlanabilirliğe ve genelleme yeteneğine sahiptir ve genellikle görüntü tanıma ve tahmin gibi oldukça doğrusal olmayan veya net bir analitik biçimi olmayan problemlerin çözümünde kullanılır (Wang vd., 2023).

Yeni geliştirilen denetlenen makine öğrenmesi tekniklerinden biri de Gen ifadesi Programlama Yöntemi (GPY) genetik algoritma (GA) ve genetik programlamanın (GP) birleşimidir. Önerilen yöntemin temel ilkesi, insanın genetik sistemine benzemektedir. GPY modellemesinde, gözlenen ve modellenen veriler, protein kodlama bölgelerini içeren birkaç genden oluşan kromozomlar olarak kabul edilir. Bu tekniğin temel amacı, gerçek gözlenen verilere göre birkaç bağımsız değişkeni bir hedef parametreye ilişkilendiren bir matematiksel fonksiyon bulmaktır (Aghdam vd., 2023).

YZ modellerinin yaygın olarak kullanılan performans göstergeleri, ortalama karesel hata (MSE), kök ortalama karesel hata (RMSE), karesel hatanın toplamı (SSE), ortalama mutlak hata (MAE) ve ortalama mutlak yüzde hata (MAPE) gibi değerlerdir. Hata değerleri, modelin tahmin edilen değeri ile örnek verilerin gerçek değeri arasındaki farktır. Aralarındaki farkın ne kadar az olursa gerçek verilerle model verilerinin o kadar uyumlu olduğunun göstergesidir (Zhang vd., 2023).

ATIKSU ARITIMINDA YAPAY ZEKA UYGULAMALARI

Atıksu arıtımında yapay zeka sistemleri, veri toplama için su kalitesi izlemede, laboratuvar ölçekli yapılan araştırmalarda, proses tasarımı, proses parametrelerinin optimizasyonunda ve proses performanslarının tahmininde uygulama alanı bulmaktadır (Wang vd., 2023). Çok sayıda atıksu arıtma uygulamasında yapay zeka teknikleri uygulanmıştır.



Şekil 4. Atıksu Arıtımında Yapay Zeka Uygulamaları

Yapay zeka, algoritmalarının kullanımı, atıksu arıtımının çeşitli aşamalarını optimize etmek için mikrobiyal aktivite, KOİ, BOİ pH, azot, fosfor, ağır metal gibi çeşitli kirletici parametrelerin konsantrasyonlarının izlenmesi ve çeşitli cihazlar ve sensörlerden gelen verilerin gerçek zamanlı analizi için uygulama alanı bulmaktadır (Saboe vd. 2021). Su kalitesi izleme çevre koruma açısından son derece önemlidir. Su kalitesi verilerindeki anormal değişimler karar vermeyi ve çevre korumayı ciddi şekilde etkileyebileceğinden su kalitesinin izlenmesinde yapay zeka destekli hassas sensörlerin kullanımı, beklenmeyen değerlerin erken tespitinde ve tedbir alımında önemli olmaktadır.

Qin ve ark. (2012) bir kampüs atıksuyu arıtma tesisi için makine öğrenme tekniklerini kullanan atıksu kalitesi izleme sistemi önerdiler. Atıksuyu arıtan elektrokoagülasyon-elektroflotasyon (EC-EF) pilot tesisinin atık sularındaki KOİ, Toplam Askıda Katı Maddeler (TAKM) ve Yağ ve Gres konsantrasyonlarını izlemek için bir UV/Vis spektrometresi ve bir bulanıklık ölçer içeren çok sensörlü bir su kalitesi izleme sistemi uyguladılar. Atıksuyun kalitesini tahmin eden modeller oluşturdular. İzleme sistemi sahada test ederek tatmin edici sonuçlar elde ettiler. Kullandıkları tekniğin su kalitesinin çevrimiçi izlenmesi için potansiyeli olduğunu ortaya koydular.




Shyu ve ark. (2023) yaptıkları bir çalışmada yerinde atıksu arıtma sisteminin su kalitesini tahmin etmek için makine öğrenme algoritmalarını kullanan hassas bir sensör geliştirdiler. KOİ, TAKM ve E. coli konsantrasyonları dahil olmak üzere temel su kalitesi parametreleri doğru bir şekilde tahmin eden hassas sensörlerle yaklaşık iki yıl boyunca sahada çalışma imkanı buldular. Zamansal ve mekansal su kalitesi verilerini, dört makine öğrenimi algoritmasını tahmin performansını değerlendirmek için kullandılar. Bu algoritmalar, yani kısmi en küçük kareler regresyonu, destek vektör regresyonu, kübist regresyon ve kantil regresyon sinir ağı, algoritmalarıydı. Bulanıklık, renk, pH, NH_4^+ , NO_3^- ve elektriksel iletkenlik dahil olmak üzere satır içi olarak ölçülebilen su kalitesi parametreleri, KOİ, TAKM ve E. coli'yi tahmin etmek için model girdileri olarak seçtiler. Sonuçta kübist regresyon modelinin, %24,8'lik bir MAPE ve 0,99'luk bir R^2 ile TAKM için en iyi tahmin performansını sağladığını ifade ettiler. Modellerin hiçbirinin E. coli için en iyi tahmin sonuçlarını elde edemediğini belirttiler. Araştırmacılar, atıksu veri kümesindeki KOİ, TAKM ve E. coli konsantrasyonlarındaki büyük dalgalanmaların göz önüne alındığında, önerilen hassas sensör modellerinin KOİ ve TAKM'yi yeterli şekilde tahmin ettiğini ancak E. coli tahmininin nispeten daha az doğru olduğunu ve daha fazla iyileştirme gerektiği belirttiler. Son olarak arıtma tesisindeki su kalitesi veri kümelerinin nispeten küçük olmasına rağmen, makine öğrenimi tabanlı hassas sensörlerin çevrimdışı parametrelerin yararlı tahminler sağlayabileceğini ve atıksu arıtımındaki proseslerde ayarlamalar yapmak için kullanılabilecek gerçek zamanlı izleme yetenekleri olduğunu rapor ettiler.

Sheik ve ark. (2024) yaptıkları yeni bir çalışmada, atıksu parametrelerini tahmin etmek için 7 farklı uyarlanabilir makine öğrenimi modeli kullanmışlardır. Araştırmacılar bir Belediye Atıksu Arıtma Tesisinde parametrelerin tahmininde hassas sensörler olarak uyarlanabilir ve makine öğrenimi modellerinin potansiyel uygulamasından ilham almıştır. Uzun Kısa Süreli Bellek (LSTM), Çift Yönlü LSTM (BiLSTM), Zaman Farkı (TD), Tam Zamanında Öğrenme (JIT), Hareketli Pencere (MW) ve uyarlanabilir stratejilerin birleştirilmesi (JITTD ve JITTDMW), Destek Vektör Regresyonu (SVR) ve Yapay Sinir Ağı (YSA) gibi uyarlanabilir stratejilerden MÖ mimarilerine

kadar değişen yedi farklı uyarlanabilir ve MÖ algoritmasını incelemiş ve karşılaştırmışlardır. Sonuçlara göre, Çift Yönlü Uzun Kısa Süreli Bellek algoritması sürekli olarak tüm değişkenler için %3,12 ile %9,75 arasında değişen bir hata oranıyla atıksu parametrelerinin en doğru tahminini sağlamıştır. KOİ, amonyak, pH ve TAKM için bu model, önerilen diğer altı modele kıyasla daha düşük korelasyon katsayısı değerleriyle ($<0,7$) düşük hatalar (MAE değerleri; 1,54, 0,1, 0,22 ve 1,14) üretmiştir. Araştırmacılar iletkenlik, KOİ, TAKM, pH, amonyak, Uzun Kısa Süreli Bellek ve uyarlanabilir stratejilerin birleştirilmesi, 1 ile 8 arasındaki MAE değerleriyle iyi performans gösterdiğini ancak çözünür reaktif fosfatı (SRP) tahmin etmede zorluk çektiği belirtmişlerdir.

Yapay zeka ile entegre edilmiş akıllı sensörler, sürekli izleme ve anında veri analizi sağlayarak arıtma süreçlerinin uyarlanabilirliği, verimliliği ve etkinliğinde önemli iyileştirmelere yol açtığı araştırmacılar tarafından belirtilmiştir. Yapay sinir ağları ve makine öğrenimi gibi YZ teknolojilerinin bu süreçleri optimize etmede entegrasyonunu halen geliştirilmektedir ve YZ destekli uygulamaların atıksu arıtımında dönüştürücü bir etki yaratacağı araştırmacılar tarafından vurgulanmaktadır. Gerçek dünya uygulamalarına entegrasyonu için çalışmalar hızlı bir şekilde devam etmektedir. Bununla birlikte veri gereksinimleri, model yorumlanabilirliği ve YZ'nın mevcut altyapılarla entegrasyonu halen iyileştirilmesi gereken alanlardır.



El-Shafeiy ve ark. (2023) çok değişkenli derin öğrenme tekniğine dayalı su kalitesi sensörü izleme için bir çalışma gerçekleştirdiler ve su kalitesinin gerçek zamanlı değişimlerine bakarak etkili bir anomali tespiti sunarak, su kalitesi sorunlarına işaret edebilecek beklenmeyen parametreleri veya değerleri belirlemeye ve işaretlemeye olanak tanıyan bir sistem önerdiler. Araştırmacılar son teknoloji bir derin öğrenme algoritması olarak Uzun Kısa Süreli Bellekli Çok Değişkenli Çoklu Evrişimli Ağlar'ı önermiş ve gerçek zamanlı su kalitesi izlemeye tanıtarak uygulamasını yapmışlardır. Su kalitesi izleme senaryolarına yerleştirilen sensörlerden elde edilen gerçek dünya bilgilerini kullanarak önerilen YZ tekniğini doğrulamak için kapsamlı testler gerçekleştirdiler. Bu çalışmalarının sonuçlarına göre, %92,3'lük etkileyici bir doğruluk oranıyla

anormallikleri tespit etme zorluğunu ele almak için tasarlanmış olan YZ teknolojisinin olağanüstü etkinliğini kanıtlamışlardır.

Nadiri vd. (2018), atıksu arıtma tesislerini araştırdılar ve araştırmacılar karmaşık fiziksel, kimyasal ve biyolojik arıtma prosedürlerinin simülasyonunu önlemek için söz konusu tesisler için bir bulanık mantık modelleri algoritması önerdiler. Bildirdikleri sonuçlara göre, denetlenen komite modeli, araştırılan diğer alternatif yöntemlere kıyasla atıksu arıtma tesislerinin atıksu kalitesi parametrelerini daha yüksek doğrulukla tahmin etme yeteneğine sahipti.

Yapay zeka modellerinin en yaygın kullanıldığı alanlardan biri de, proses tasarımları ve laboratuvar ölçeğindeki araştırmalardır.

Praveen ve ark. (2021) yaptıkları çalışmada farklı deneysel parametrelerim, Yapay Sinir Ağı vasıtasıyla yer fıstığı kabuğundan elde edilen biyokömürün adsorban olarak kullanıldığı bir adsorpsiyon çalışmasında katyonik bir boyanın giderim performansı üzerindeki etkileri araştırılmıştır. Kooh ve ark. (2022), tarafından su bitkisi *Azolla pinnata*'dan methylene blue boyasının adsorbe edilmesi ve giderilmesi konusunda yapılan bir laboratuvar çalışmasındaki veriler farklı yapay zeka modelleri kullanılarak analiz edilmiş ve çeşitli modeller tarafından öngörülen sonuçlar yüksek bir doğruluk oranına ulaşmıştır.

Ahmed ve ark. (2020) boya giderimi üzerine yaptıkları bir adsorpsiyon çalışmasında neodimyum modifiyeli düzenli mezogözenekli bir karbon adsorban üzerine adsorpsiyonunun modellenmesi için yapay sinir ağlarını (YSA) kullandılar. YSA modelinin, başlangıç konsantrasyonu, reaksiyon süresi ve adsorban dozajının adsorpsiyon çalışmasında parametreler olarak seçildiğini, giderim verimliliğinin ise çıktı olarak kabul edildiğini ve modelin adsorpsiyon deneyleri verileriyle eğitildiğini ve doğrulamasının yapıldığını belirttiler. Çalışmada YSA modeli ilk olarak optimum yapısı 3-6-1 olan üç katmanlı geri yayılım ağı kullanılarak geliştirildi. Model, gizli katmanda girdi olarak teğet sigmoid transfer fonksiyonunu kullanırken, çıktı katmanında doğrusal bir transfer fonksiyonu kullanıldı. Modellenmiş verilerle deneysel veriler arasındaki karşılaştırma, adsorpsiyon sürecini makul bir doğrulukla tanımlamak için YSA modelinin uygulanabilirliğini gösteren yüksek derecede korelasyon ($R^2=0,9832$) sağlandı.

Narayana ve ark. (2021), kirletici ağır metal olarak kurşun giderimi ile deney parametreleri arasındaki ilişkiyi araştırmak ve optimum işletme parametrelerini belirlemek için dört katmanlı bir mimariye sahip bir sinir modeli kurguladılar. Çalışmalarda değişkenlerin ağır metal giderimi üzerindeki etkisi duyarlılık analizi ile tahmin edildi.

Endüstriyel atıksuların arıtımında, arıtılacak atıksu kompleks bir atıksu olduğu için birden fazla kirleticinin etkileşiminden bahsedilebilir. Bu durumda da arıtma mekanizması karmaşık ve modelleme daha zordur. Mendoza-Castillo ve ark. (2018) tarafından yayınlanan bir çalışmada

polimetal adsorpsiyon sistemini modellemek ve kirleticilerin giderim prosesindeki rekabetçi yapısını tahmin etmek için yapay sinir ağını kullandılar, çalışmalarında aktivasyon fonksiyonunun seçimini, eğitim değişkenlerini analiz ederek ağ yapılarını optimize ettiler. Yapay sinir ağı eğitim değişkenlerinin uygun şekilde seçilmesinin, metal karışımlarının karmaşık adsorpsiyon davranışını modellemenin ve tahmin etmenin güvenilirliğini artırmada önemli bir rol oynadığını rapor ettiler.

Bhagat ve ark. (2021) tarafından yürütülen tamamlanmış bir çalışmada bakır iyonlarının adsorpsiyon prosesiyle giderimine odaklanılmıştır. Adsorban olarak attapulgit kilinin kullanıldığı araştırma çalışmasında bir yapay sinir ağı, bir destek vektör makinesi ve bir ızgara optimizasyonu tabanlı rastgele ormanı içeren üç model geliştirilmiş ve optimum tahmin biçimini belirlemek için modeller birbirleriyle karşılaştırılmıştır. Çalışma verileri eğitim ve test için ikiye bölündü ve %80'i eğitim için, kalan %20'si ise test için kullanıldı. YSA modeli, ilk gizli katmanın beş düğüm, ikinci gizli katmanın ise üç düğüm içerdiği dört katmanlı bir modelden (bir giriş katmanı, iki gizli katman ve bir çıktı katmanı) oluşuyordu. Her nöron doğrusal bir çıktı fonksiyonuna dayanıyordu. Her modelde farklı girdi kümeleri kullanılarak testler çalıştırıldı. Girdi kümeleri şunları içeriyordu: (I) başlangıç bakır konsantrasyonu; (II) başlangıç bakır konsantrasyonu ve adsorban dozajı; (III) başlangıç bakır konsantrasyonu, adsorban dozajı ve temas süresi; (IV) başlangıç bakır konsantrasyonu, adsorban dozajı, temas süresi ve pH; (V) başlangıç bakır konsantrasyonu, adsorban dozajı, temas süresi, pH ve NaNO_3 konsantrasyonu . Modellerin beş girdinin hepsini kullanarak en iyi performansı gösterdiği bildirildi. Sonuç olarak araştırmacılar bu çalışma için rastgele ormanı ve yapay sinir ağı modellerinin 0,99'dan büyük korelasyon katsayıları ile doğruluk açısından en iyi performansı gösterdiğini belirttiler.

Çeşitli boyalar içeren endüstriyel atık suların arıtımını optimize etmek için yapılan yeni bir çalışmada Chianeh ve ark. (2024) boyaların elektrokimyasal giderimini araştırmışlar ve kopula fonksiyonu, makine öğrenimi, derin öğrenme ve çok amaçlı optimizasyonun uygulanmasını sağlayan yeni bir metodoloji önermişlerdir. Optimizasyon süreci, 4 farklı boyanın giderim verimliliği olmak üzere dört amaç fonksiyonuna dayanarak gerçekleştirildi. Araştırmacının sonuçları, boyaların giderim verimliliği arasında Pareto cephesinde doğrudan bir ilişki ve optimum koşullar altında karar değişkenleriyle (pH, NaCl konsantrasyonu, akım ve Zaman) oldukça salınımlı ve doğrusal olmayan bir ilişki olduğunu gösterdi. Araştırmacılar, önerdikleri metodoloji ile özellikle yeterli veri olmadığında, atıksudan çeşitli boyaların maksimum giderim verimliliğini elde etmek için optimum koşulları bulmak konusunda başarılı olduğunu belirttiler.

Ganthavee & Trzcinski, (2024) yine Reaktif Siyah 5'i (RB5) boyası ile kirlenmiş atıksuya grafit ara katman bileşiği adsorpsiyonu, doğrudan anodik oksidasyon ve $\cdot\text{OH}$ oksidasyonunu birleştiren üç boyutlu bir elektrokimyasal arıtma işlemi uyguladılar. Boya ve toplam organik

karbon (TOK) giderme verimliliklerini, akım verimliliğini, RB5 ve TOK giderimi için elektrik enerjisi tüketimini ve yıllık elektrik maliyetini tahmin etmek için bir matematiksel model oluşturmak üzere yüz merkezli merkezi kompozit tasarıma (CCD) sahip bir RSM geliştirildiler. Ayrıca, bu bağımlı değişkenlerin giriş parametreleriyle (akım yoğunluğu, elektroliz süresi ve başlangıç boya konsantrasyonu dahil) korelasyonunu ölçtüler. Tepki değişkenlerinin tahmin verimliliğini değerlendirmek için ise çeşitli yapay zeka ve makine öğrenme teknikleri kullandılar. Uyguladıkları algoritmalar arasında hibrit YSA-XGBoost'un tahmin verimliliğinin yüksek olduğunu belirttiler. Önerdikleri teknolojinin 3B elektrokimyasal prosesteki tekno-ekonomik uygulanabilirliğin, mühendislik uygulanabilirliğini ve çevresel uygunluğunu doğruladığını rapor ettiler.

Elver ve ark. (2024), Aktive edilmiş *Phragmites australis* atığı üzerindeki Cu(II) adsorpsiyonunu araştırmışlar ve araştırma bulgularını bulanık tabanlı ve sinir ağı tabanlı çıkarım sistemleri ile modellemişlerdir. Araştırmacılar en iyi Cu(II) giderimini elde etmek için genetik algoritma kullanmışlardır. Mamdani Bulanık Çıkarım Sistemi ve İleri Beslemeli Sinir Ağı girdilerini oluşturan adsorban parametrelerinin optimizasyonunda arzu edirlilik seviyelerinin %90'ın üzerinde olduğunu belirtmişlerdir. Her iki model ile yapılan, 6 deneysel tasarımdan 2'sinde %1'den az hata yüzdesi ile üstün tahmin performansı gösterdiği ve 2'sinde yaklaşık %2-3'lük hata yüzdesi ile başarılı olunduğu rapor edilmiştir. Diğer tasarımların ise , %6-8'lik hata yüzdesi ile kabul edilebilir bir seviyede olduğu belirtilmiştir. Atıksu arıtımında önemli bir yere sahip olan membrane teknolojilerine makine öğrenimi gibi yapay zeka uygulamalarının entegrasyonu, performans ve verimliliklerinde önemli iyileştirmeler sağlayarak membran tasarımı için devrim niteliğinde bir dönemi başlatmıştır. Güçlü algoritmalarla makine öğrenimi, seçicilik ve geçirgenlik gibi kritik membran özelliklerini tahmin etmek için kapsamlı veri kümelerini inceleyebilmekte ve böylece dikkate değer potansiyele sahip malzemeleri belirleyebilmektedir. Dahası, yapay zeka sistemleri yalnızca tahmin etmenin ötesine geçerek membran yapıları içindeki karmaşık ilişkileri araştırabilmektedir. Böylece uygulamalara özel uzmanlaşmış membranların geliştirilmesini kolaylaştırmaktadır.

Bu teknolojik yaklaşım, geleneksel emsallerinden daha iyi performans gösteren entegre membran sistemlerinin oluşturulmasıyla sonuçlanır ve membran teknolojisinde ciddi bir ilerlemeyi işaret eder (Osman vd., 2024). Araştırmacılar tarafından çok sayıda matematiksel model, membrane performansını ve membran kirlenmesini tahmin etmek için kullanılmıştır. Geleneksel matematiksel modellere kıyasla, makine öğrenme modeli matematiksel modelin dezavantajlarını gidererek, bir yandan kesin olmayan ve oldukça karmaşıklık içeren doğrusal olmayan verilerle başa çıkmada güçlü bir öğrenme yeteneğine sahiptir; diğer yandan, membran

kirliliğini veri setinin öğrenme mekanizmasına dayanarak tahmin edilebilme yeteneğine sahiptir (Zheng vd., 2024).

Singh ve ark. (2024) yaptıkları araştırmada sentezlenmiş poliamid bazlı membran ile ileri ozmoz performansının tahmininde tahmini modeller geliştirmek için entegre bir makine öğrenimi (YSA) kullanmışlardır. Özellikle, van't Hoff denkleminin doğrusal varsayımının doğruluğu, dış ve iç konsantrasyon polarizasyonunun nüanslı etkileri dikkate alınarak, su aktivitesine dayalı bir ozmotik basınç hesaplamasının tanıtılmasıyla önemli ölçüde artırıldığı vurgulanmıştır. Çalışma kapsamında kullanılan yazılım, çeşitli membran parametrelerini ve bunların performans üzerindeki etkilerini sistematik olarak analiz ederek membranlardaki akışı tahmin etme konusunda içgörüler sunarak kapsamlı bir teorik modelin oluşturulmasını kolaylaştırmıştır. Eş zamanlı olarak, YSA modeli, ağır eğitim aralığındaki ($R^2>0,91$) giriş parametrelerini kullanarak laboratuvar ölçekli membran sistemi için geçirgen akısını tahmin etmek için başarılı bir şekilde kullanılmıştır.

SONUÇ

Şu anda yapay zeka teknolojilerinin gelişimiyle dijital bir dönüşüm yaşanıyor. Yapay zeka sistemlerinin hassasiyeti ve en az hata ile çalışma yeteneği onları pek çok alanda popüler hale getirmiştir. Atıksu arıtımında YZ teknolojisi genel olarak veri toplama, kirleticilerin tanımlanması ve su kalitesi izleme ile ilgili alanlar başta olmak üzere proses tasarımı ve optimizasyonunda da başarıyla kullanılmıştır. Bu teknoloji hala araştırılmaya ve geliştirilmeye açıktır ve yeni ivme kazanmış bir alan olarak araştırmacılar için ilgi çekici olmaya devam edecektir. Bu içerikte yer alan araştırmaların dışında yapay zeka tekniklerinin kullanıldığı birçok araştırmanın da literatürde mevcut olduğunu belirtmek gerekir. Yapay zeka teknolojisinde atıksu arıtımıyla ilgili doğru tahminleri ve faydaları elde etmek için, uygun modelleme aracını seçmek ve algoritmaların çeşitli olasılıklarını dikkate alarak doğru bilgiyi uygun metodolojilere entegre etmek önemlidir. Su ve atıksu arıtma mühendislerinin model geliştiricilerle ve konunun uzmanlarıyla işbirliğini geliştirmesi ve araştırmalarını derinleştirmesi verimli ve ekonomik arıtma sistemlerini tasarlamaları açısından önemlidir. Akıllı teknolojilerin su üzerindeki potansiyelini etkin bir şekilde değerlendirmek su kaynaklarımızın korunması açısından faydalı olacaktır.

KAYNAKÇA

- Aghdam, E., Mohandes, S. R., Manu, P., Cheung, C., Yunusa-Kaltungo, A., & Zayed, T. (2023). Predicting quality parameters of wastewater treatment plants using artificial intelligence techniques. *Journal of Cleaner Production*, 405, 137019.
- Ahmad, Z. U., Yao, L., Lian, Q., Islam, F., Zappi, M. E., & Gang, D. D. (2020). The use of artificial neural network (ANN) for modeling adsorption of sunset yellow onto neodymium modified ordered mesoporous carbon. *Chemosphere*, 256, 127081.
- Al Kuwaiti, A., Nazer, K., Al-Reedy, A., Al-Shehri, S., Al-Muhanna, A., Subbarayalu, AV, ... & Al-Muhanna, FA (2023). Yapay zekanın sağlık hizmetlerindeki rolüne ilişkin bir inceleme. *Kişiselleştirilmiş tıp dergisi*, 13 (6), 951.
- Alam, G., Ihsanullah, I., Naushad, M., & Sillanpää, M. (2022). Applications of artificial intelligence in water treatment for optimization and automation of adsorption processes: Recent advances and prospects. *Chemical Engineering Journal*, 427, 130011.
- Allam, Z., & Dhunny, Z. A. (2019). On big data, artificial intelligence and smart cities. *Cities*, 89, 80-91.
- Altowayti, W. A. H., Allozy, H. G. A., Shahir, S., Goh, P. S., & Yunus, M. A. M. (2019). A novel nanocomposite of aminated silica nanotube (MWCNT/Si/NH₂) and its potential on adsorption of nitrite. *Environmental Science and Pollution Research*, 26, 28737-28748.
- Altowayti, W. A. H., Shahir, S., Othman, N., Eisa, T. A. E., Yafooz, W. M., Al-Dhaqm, A., ... & Ali, A. (2022). The role of conventional methods and artificial intelligence in the wastewater treatment: a comprehensive review. *Processes*, 10(9), 1832.
- Bera, S. P., Godhaniya, M., & Kothari, C. (2022). Emerging and advanced membrane technology for wastewater treatment: A review. *Journal of Basic Microbiology*, 62(3-4), 245-259.
- Bhagat, S. K., Pyrgaki, K., Salih, S. Q., Tiyyasha, T., Beyaztas, U., Shahid, S., & Yaseen, Z. M. (2021). Prediction of copper ions adsorption by attapulgite adsorbent using tuned-artificial intelligence model. *Chemosphere*, 276, 130162.
- Bharadiya, J. P., Thomas, R. K., & Ahmed, F. (2023). Rise of Artificial Intelligence in Business and Industry. *Journal of Engineering Research and Reports*, 25(3), 85-103.
- Bonavigo, L.; Zucchetti, M.; Mankolli, H. Water Radioactive Pollution and Related Environmental Aspects. *J. Int. Environ. Appl. Sci.* 2009, 4, 357–363.
- Chianeh, FN, Anaraki, MV, Mahmoudian, F. ve Farzin, S. (2024). Boyaların elektrokimyasal giderimi için optimum koşulların tahmini için yeni bir metodoloji; Kopula fonksiyonunun, makine öğreniminin, derin öğrenmenin ve çok amaçlı optimizasyonun uygulanması. *Proses Güvenliği ve Çevre Koruması*, 182, 298-313.
- Cohen, Y., & Kirchmann, H. (2004). Increasing the pH of wastewater to high levels with different gases—CO₂ stripping. *Water, Air, and Soil Pollution*, 159, 265-275.
- Çavuş, V., Sarıkaya, M (2021). Yapay Sinir Ağları ve Güneş Enerji Sistemlerinde Uygulamaları. Volkan ÇAVUŞ (Ed.), *Yapay Zeka Uygulamalarında Güncel Konular ve Araştırmalar içinde* (ss. 7-22). Konya, Çizgi Kitabevi Yayınları.
- Dereli, RK, Clifford, E. ve Casey, E. (2021). Belediye atık su arıtma tesislerinde sızıntı suyunun eş zamanlı arıtımı: Kritik sorunlar ve ortaya çıkan teknolojiler. *Çevre Bilimi ve Teknolojisinde Kritik İncelemeler*, 51 (11), 1079-1128.
- Dey, A. (2016). ML algorithms: a review. *Int J Comput Sci Inform Technol*, 7(3), 1174-1179.
- Ejraei, A., Aroon, M. A., & Saravani, A. Z. (2019). Wastewater treatment using a hybrid system combining adsorption, photocatalytic degradation and membrane filtration processes. *Journal of Water Process Engineering*, 28, 45-53.
- El-Shafeiy, E., Alsabaan, M., Ibrahim, MI, & Elwahsh, H. (2023). Çok değişkenli derin öğrenme tekniğine dayalı su kalitesi sensörü izleme için gerçek zamanlı anormallik tespiti. *Sensörler*, 23 (20), 8613.
- Elver, O., Temel, F. A., Yolcu, O. C., Akbal, F., & Kuleyin, A. (2024). Modeling of Cu (II) adsorption on the activated Phragmites australis waste by fuzzy-based and neural network-based inference systems. *Journal of Industrial and Engineering Chemistry*, 129, 180-192.

- Ganthavee, V., & Trzcinski, A. P. (2024). Superior decomposition of xenobiotic RB5 dye using three-dimensional electrochemical treatment: Response surface methodology modelling, artificial intelligence, and machine learning-based optimisation approaches. *Water Science and Engineering*.
- Ghahramani, M., Qiao, Y., Zhou, M. C., O'Hagan, A., & Sweeney, J. (2020). AI-based modeling and data-driven evaluation for smart manufacturing processes. *IEEE/CAA Journal of Automatica Sinica*, 7(4), 1026-1037.
- Kim, S., Nam, S. N., Jang, A., Jang, M., Park, C. M., Son, A., ... & Yoon, Y. (2022). Review of adsorption-membrane hybrid systems for water and wastewater treatment. *Chemosphere*, 286, 131916.
- Kinidi, L., Tan, I. A. W., Abdul Wahab, N. B., Tamrin, K. F. B., Hipolito, C. N., & Salleh, S. F. (2018). Recent development in ammonia stripping process for industrial wastewater treatment. *International Journal of Chemical Engineering*, 2018(1), 3181087.
- Kooh, M. R. R., Thotagamuge, R., Chau, Y. F. C., Mahadi, A. H., & Lim, C. M. (2022). Machine learning approaches to predict adsorption capacity of *Azolla pinnata* in the removal of methylene blue. *Journal of the Taiwan Institute of Chemical Engineers*, 132, 104134.
- Largitte, L., & Pasquier, R. J. C. E. R. (2016). A review of the kinetics adsorption models and their application to the adsorption of lead by an activated carbon. *Chemical engineering research and design*, 109, 495-504.
- Lim, S., Shi, J. L., von Gunten, U., & McCurry, D. L. (2022). Ozonation of organic compounds in water and wastewater: A critical review. *Water Research*, 213, 118053.
- Loloei, M., Nekoum, G., Alidadi, H., and Kor, Y. (2014). Study of the coagulation process in wastewater treatment of dairy industries. *International Journal of Environmental Health Engineering*, 3(1): 12.
- Lowe, M.; Qin, R.; Mao, X. A review on machine learning, artificial intelligence, and smart technology in water treatment and monitoring. *Water* 2022, 14, 1384.
- Malviya, A.; Jaspal, D. Artificial intelligence as an upcoming technology in wastewater treatment: A comprehensive review. *Environ. Technol. Rev.* 2021, 10, 177–187.
- Martínez-Huitle, C. A., & Panizza, M. (2018). Electrochemical oxidation of organic pollutants for wastewater treatment. *Current Opinion in Electrochemistry*, 11, 62-71.
- Matheri, A. N., Ntuli, F., Ngila, J. C., Seodigeng, T., & Zvinowanda, C. (2021). Performance prediction of trace metals and cod in wastewater treatment using artificial neural network. *Computers & Chemical Engineering*, 149, 107308.
- Meena, R. A. A., Kannah, R. Y., Sindhu, J., Ragavi, J., Kumar, G., Gunasekaran, M., & Banu, J. R. (2019). Trends and resource recovery in biological wastewater treatment system. *Bioresource Technology Reports*, 7, 100235.
- Mendoza-Castillo, D. I., Reynel-Ávila, H. E., Sánchez-Ruiz, F. J., Trejo-Valencia, R., Jaime-Leal, J. E., & Bonilla-Petriciolet, A. (2018). Insights and pitfalls of artificial neural network modeling of competitive multi-metallic adsorption data. *Journal of molecular liquids*, 251, 15-27.
- Mroue, A.M.; Obkirchner, G.; Dargin, J.; Muell, J. *Water-Energy Nexus: The Role of Hydraulic Fracturing. In Regulating Water Security in Unconventional Oil and Gas; Springer: Berlin/Heidelberg, Germany, 2020; pp. 21–38.*
- Nadiri, A. A., Shokri, S., Tsai, F. T. C., & Moghaddam, A. A. (2018). Prediction of effluent quality parameters of a wastewater treatment plant using a supervised committee fuzzy logic model. *Journal of cleaner production*, 180, 539-549.
- Narayanan, C. M., & Narayan, V. (2019). Biological wastewater treatment and bioreactor design: a review. *Sustainable environment research*, 29(1), 1-17.
- Narayana, P. L., Maurya, A. K., Wang, X. S., Harsha, M. R., Srikanth, O., Alnuaim, A. A., ... & Reddy, N. S. (2021). Artificial neural networks modeling for lead removal from aqueous solutions using iron oxide nanocomposites from bio-waste mass. *Environmental Research*, 199, 111370.
- Osman, A. I., Nasr, M., Farghali, M., Bakr, S. S., Eltaweil, A. S., Rashwan, A. K., & Abd El-Monaem, E. M. (2024). Machine learning for membrane design in energy production, gas separation, and water treatment: a review. *Environmental Chemistry Letters*, 22(2), 505-560.

- Praveen, S., Jegan, J., Pushpa, T. B., & Gokulan, R. (2021). Artificial neural network modelling for biodecolorization of Basic Violet 03 from aqueous solution by biochar derived from agro-bio waste of groundnut hull: kinetics and thermodynamics. *Chemosphere*, 276, 130191.
- Qin, H., Hu, T., Zhai, Y., Lu, N., & Aliyeva, J. (2020). The improved methods of heavy metals removal by biosorbents: A review. *Environmental pollution*, 258, 113777.
- Qin, X., Gao, F. ve Chen, G. (2012). Sensör füzyonu ve makine öğrenme tekniklerini kullanan atık su kalitesi izleme sistemi. *Su araştırması* , 46 (4), 1133-1144.
- Rad, S. M., Ray, A. K., & Barghi, S. (2022). Water pollution and agriculture pesticide. *Clean Technologies*, 4(4), 1088-1102.
- Saboe D., Ghasemi H., Gao M. M., Samardzic M., Hristovski K. D., Boscovic D., Burge S. R., Burge R. G. & Hoffman D. A. 2021 Real-time monitoring and prediction of water quality parameters and algae concentrations using microbial potentiometric sensor signals and machine learning tools. *Science of the Total Environment* 764, 142876.
- Safeer S., Pandey R. P., Rehman B., Safdar T., Ahmad I., Hasan S. W. & Ullah A. 2022 A review of artificial intelligence in water purification and wastewater treatment: Recent advancements. *Journal of Water Process Engineering* 49, 102974.
- Saleh, T. A., Mustaqeem, M., & Khaled, M. (2022). Water treatment technologies in removing heavy metal ions from wastewater: A review. *Environmental Nanotechnology, Monitoring & Management*, 17, 100617.
- Saravanan, A., Kumar, P. S., Jeevanantham, S., Karishma, S., Tajsabreen, B., Yaashikaa, P. R., & Reshma, B. (2021). Effective water/wastewater treatment methodologies for toxic pollutants removal: Processes and applications towards sustainable development. *Chemosphere*, 280, 130595.
- Shah, A. I., Dar, M. U. D., Bhat, R. A., Singh, J. P., Singh, K., & Bhat, S. A. (2020). Prospectives and challenges of wastewater treatment technologies to combat contaminants of emerging concerns. *Ecological Engineering*, 152, 105882.
- Shyu, HY, Castro, CJ, Bair, RA, Lu, Q. ve Yeh, DH (2023). Bir Yerde Atıksu Arıtma Sisteminin Su Kalitesini Tahmin Etmek İçin Makine Öğrenme Algoritmalarını Kullanan Yumuşak Bir Sensörün Geliştirilmesi. *ACS Environmental Au* , 3 (5), 308-318.
- Sheik, AG, Malla, MA, Srungavarapu, CS, Patan, AK, Kumari, S. ve Bux, F. (2024). Uyarlanabilir ve makine öğrenimi modelleri kullanılarak atık su kalite parametrelerinin tahmini: Güney Afrika vaka çalışması. *Su Süreci Mühendisliği Dergisi* , 67 , 106185.
- Singh, S. K., Sharma, C., Mahadeva, R., Patole, S. P., & Maiti, A. (2024). Predicting forward osmosis performance with synthesized polyamide-based membrane: An integrated machine learning (MATLAB and ANN) and economic analysis framework. *Journal of Cleaner Production*, 444, 141285.
- Tariq, A.; Mushtaq, A. Untreated wastewater reasons and causes: A review of most affected areas and cities. *Int. J. Chem. Biochem. Sci.* 2023, 23, 121–143.
- Teodosiu, C., Gilca, A. F., Barjoveanu, G., & Fiore, S. (2018). Emerging pollutants removal through advanced drinking water treatment: A review on processes and environmental performances assessment. *Journal of cleaner production*, 197, 1210-1221.
- Wang, Y., Cheng, Y., Liu, H., Guo, Q., Dai, C., Zhao, M., & Liu, D. (2023). A review on applications of artificial intelligence in wastewater treatment. *Sustainability*, 15(18), 13557.
- Wong, E. W. C. (2018). A simplified method to predict fatigue damage of TTR subjected to short-term VIV using artificial neural network. *Advances in Engineering Software*, 126, 100-109.
- Zhang, T., Payne, K., Zhang, J., Purswani, P., Karpyn, Z., & Wang, M. (2024). Hybrid ion exchange and biological processes for water and wastewater treatment: a comprehensive review of process applications and mathematical modeling. *Reviews in Environmental Science and Bio/Technology*.
- Zhang, W., Chen, R., Li, J., Huang, T., Wu, B., Ma, J., ... & Huang, W. (2023). Synthesis optimization and adsorption modeling of biochar for pollutant removal via machine learning. *Biochar*, 5(1), 25.

- Zhang*, W., Huang, W., Tan, J., Huang, D., Ma, J., & Wu, B. (2023). Modeling, optimization and understanding of adsorption process for pollutant removal via machine learning: Recent progress and future perspectives. *Chemosphere*, 311, 137044.
- Zheng, W., Chen, Y., Xu, X., Peng, X., Niu, Y., Xu, P., & Li, T. (2024). Research on the factors influencing nanofiltration membrane fouling and the prediction of membrane fouling. *Journal of Water Process Engineering*, 59, 104876.

BÖLÜM 2

İLETİM HATTI KORUMADA BULANIK MANTIK UYGULAMALARI

Hasan DİRİK
Dr. Öğr. Üyesi, Sinop Üniversitesi, hasan_dirik@hotmail.com
 0000-0003-0625-7213

İletim hatları elektrik güç sistemlerinin üretim birimleri ile yükler arasında köprü görevi gören hayati kısımlarından biridir. Çeşitli ekonomik ve teknik nedenlerden dolayı iletim hatları genellikle maksimum kapasitelerine yakın değerlerde yüklenerek kullanılırlar. Dolayısıyla iletim hatlarının arızalara karşı korunması güç sistemlerinin güvenilirliği bakımından hayati öneme sahiptir. Yıldırımlar, fırtınalar, ağaçların devrilmesi, bulut ve tozun izolatörleri kirletmesi iletim hatlarında meydana gelen arızaların başlıca nedenlerinden sayılabilir (Babu vd., 2011).

İletim hatlarında ortaya çıkabilecek herhangi bir arıza, hızlı bir şekilde tespit edilemez ve izole edilmezse, kapasitelerine yakın çalışan sıkı bir şekilde birbirine bağlı bir sistem için yaygın kesintilere neden olan bir sistem arızasına dönüşecektir. Bu yüzden iletim hattı koruma sistemleri hatayı veya arızayı olabildiğince kısa bir sürede tespit ederek arızalı kısmı sistemden izole etmek amacıyla kullanılırlar (www.GEMultilin.com, 2024). İyi bir koruma sisteminin hızlı olmasının yanında yalnızca arızalarda koruma yapacak şekilde seçici olması istenir.

İlk kullanılan koruma röleleri girişine verilen akım ve gerilim işaretlerine bağlı olarak manyetik kuvvetler üreten elektromekanik cihazlardı. Bu röleler yalnızca bir tane işaretin (akımın veya gerilimin) ürettiği mıknatıslanma kuvvetinin harekete geçirdiği bir mekanik düzenek ile çalışmaktaydı. Bu rölelerin geçici olaylara karşı hassas olmaları önemli bir dezavantajdı. Yani bu rölelerin koruma bölgelerinin dışındaki durumlara karşı yeterince seçici olmaması önemli bir dezavantaj olarak durmaktaydı. İlerleyen zamanlarda, iki değişken girişli (akım ve gerilim) rölelerin daha seçici ve güvenilir oldukları fark edildi. İki değişkene bağlı olarak çalışan indüksiyon tipi koruma röleleri ilk olarak 1920'li yıllarda geliştirilmiştir (Norouzi, 2021).

1960'lı yıllardan itibaren yarıiletken tabanlı dijital devrelerin gelişmesi ile beraber iletim hattı koruma teknikleri oldukça derinden bir değişime başlamıştır. Bu yıllardan itibaren iletim hattı korumada kullanılan elektromekanik koruma röleleri yerini yüksek matematiksel hesaplama gücüne sahip dijital rölelere bırakmaya başlamıştır. Buna paralel olarak daha hassas, seçici, hızlı ve gelişmiş koruma yöntemleri geliştirilmeye başlanmıştır.

Dijital korumalı röle fikri ilk olarak 1969 yılında George D. Rockefeller tarafından ortaya atılmış ve güç sistemi korumanın sayısal bir bilgisayarda yapılmasının temel ilkeleri detaylı bir şekilde ortaya konulmuştur (Rockefeller, 1969). Öyle ki, Rockefeller güç dağıtım istasyonlarının kontrol odalarının fiziksel ve kavramsal olarak birer bilgisayar ve hesaplama odalarına dönüşeceğini öngörmüştür. Kısa bir süre sonra, 1970'li yılların başlarında ilk ticari sayısal koruma röleleri pratik uygulamalarda yerini almıştır. Kullanılan ilk sayısal koruma röleleri analog rölelerden farklı olarak genellikle arıza empedansının gerçek zamanlı olarak hesaplanması yaklaşımını kullanıyordu (Norouzi, 2021).

1980'li yıllardan itibaren ortaya çıkan yapay zeka yöntemleri çeşitli alanlara (Balki vd., 2018) uygulanmış olup aynı zamanda sayısal röle tekniğinde kullanılan algoritmalarda da önemli bir dönüşüme neden olmuştur. Yapay sinir ağları, bulanık mantık ve diğer bazı yapay zeka yöntemleri bu alanda oldukça fazla uygulama alanı bulmaya başlamıştır.

Genel olarak, iletim hatlarında meydana gelen arızalar genel olarak iletkenler arasındaki veya iletkenler ile toprak arasındaki yalıtkanlığın kaybolması ile ortaya çıkar. Havai hatlar için yalıtkanlık iletkeni çevreleyen havanın dielektrik değeri ile iletkenler arasındaki mesafeye bağlıdır. Havai hatlarda yalıtkanlığın kaybolmasına neden olan olaylar dört gruba ayrılabilir.

1. Yalıtkanlık görevi gören havanın yabancı parçacıklar etkisi ile özelliğini kaybetmesi. Yangın veya endüstriyel bacalardan atılan uçucu atıklar buna neden olabilmektedir.
2. İletkenler arasındaki boşluğun (mesafenin) azalması. Bu durum rüzgar etkisiyle iletkenlerin sallanması, aşırı sıcaklıklara bağlı olarak iletken sehiminin artması veya buz yükünün artması nedeniyle ortaya çıkabilmektedir.

3. İletkenleri taşıyan izolatörlerin yüzeyinin yabancı maddeler ile kirlenmesi. Bu durum iletken ile toprak arasındaki yalıtkanlığın azalmasına ve atlamaların oluşmasına neden olur.

4. İletkenler arasındaki mesafe taşıdıkları gerilime göre belirlenir. Gerilimin anma değerinin çok üstüne çıkması durumunda iletkenler arasındaki yalıtkan özelliğini kaybeder ve atlamalar meydana gelir (www.GEMultilin.com, 2024).

İletim hatlarında ortaya çıkabilecek arızalar genel olarak,


1. Üç-faz arızaları
2. Üç-faz-toprak arızaları
3. Açık devre arızaları
4. Faz-faz arızaları
5. Faz-toprak arızaları
6. İki-faz-toprak arızaları

biçiminde sınıflandırılabilir. İlk üç arıza dengeli arıza akımlarının akmasına neden olurken diğerleri dengesiz arıza akımlarının akmasına neden olur. Bu arızaların hızlı ve doğru bir şekilde tespiti, sınıflandırılması ve gerekli aksiyonların alınması iletim hattı koruma tekniğinin esas amaçlarıdır.

İLETİM HATTI KORUMA TEKNİĞİ

Güç sistemlerinde yer alan generatörler, baralar, transformatörler ve iletim hatları sistemde oluşabilecek anormal çalışma koşullarına karşı koruma gerektirir. İletim hatlarının korunmasını gerektiren anormal çalışma koşulları genellikle faz iletkenlerinin kendi aralarında ve/veya toprak ile teması sonucunda ortaya çıkar. Temas sonucunda iletim hattından kapasitenin üzerinde aşırı akımlar veya kısa devre akımları akar. Zararlı olabilecek bu akımların uygun bir şekilde tespiti ve gerekli aksiyonların alınması amacıyla çeşitli iletim hattı koruma donanımları kullanılır. (Şekil 1) Röleler bu donanımların merkezinde yer alan ve arızanın tespitinde kilit rol oynayan donanımlardır. Röleler, arıza adı verilen bu anormal çalışma durumunun tespiti için gerilimin ve/veya akımın ölçümüne ihtiyaç duyarlar. Bu ihtiyaç genellikle iletim hattı gerilimlerini ve/veya akımlarını kullanılabilir/örneklenebilir değerlere düşüren ölçüm trafoları yardımıyla karşılanır. Ölçüm trafoları üzerinden örneklenen iletim hattı gerilim ve akım değerleri

koruma rölelerinin mikroişlemci ortamında işlenerek koruma durumuna (kesici konumuna) karar verilir. Röleler, arızalı durumda koruma fonksiyonunu hattın üzerinde kapalı konumda olan kesicilere açma komutu göndererek yerine getirirler.



Şekil 1. İletim hattı koruma donanımları

Genel olarak iletim hattı korumada kullanılan koruma röleleri kullandıkları koruma tekniği bakımından 5 ana gruba ayrılabilir. Bunlar,

- 1-Aşırı akım koruma röleleri
- 2-Yönlü aşırı akım koruma röleleri
- 3-Mesafe koruma röleleri
- 4-Pilot koruma (diferansiyel) röleleri (Phadke ve Thorp, 2009)
- 5-Yürüyen dalga röleler.


Aşırı Akım Röleleri

Güç sistemlerinde bir arıza meydana geldiğinde arıza akımı arıza öncesi yük akımından yüksek bir değere çıkar. Bu akım ile güç sisteminde yer alan her hangi bir bileşeni basit ve etkili bir şekilde korumak mümkündür. İletim hattını korumak için kullanılacak bir aşırı akım rölesinde hattın sonunda meydana gelecek arıza sonucunda akacak olan akım minimum açma akımı olarak ve hattın başında (kesicinin olduğu noktada) meydana gelecek arızada akacak olan akım da maksimum akım olarak ayarlanır. Bu koruma tekniğinin kullanılabilmesi için hattın tek taraflı beslenen bir hat olması gerekir. Rölenin ölçtüğü yük akımı hattan akacak olan maksimum yük akımından büyük olursa açma işareti üretilerek kesicinin açma yapması sağlanır. Yani I ölçülen akımı ve I_p ayarlanan akımı göstermek şartıyla,

eğer $|I| > I_p$ ise arıza var ve

eğer $|I| < I_p$ ise arıza yok demektir.

Arızanın tespiti durumunda rölenin açma sinyali üretmesi iki farklı biçimde olabilir. Eğer arıza tespit edildiği andan kesicinin açması arasında geçen süre bir sabit T_{min} süresi olarak ayarlanırsa bu tip aşırı akım röleleri ani açmalı aşırı akım rölesi adını alır. Fakat, açma süresinin arıza akımının genliğine bağlı olarak belirlenmesi arzu edilen durumdur. Öyle ki, arıza akımı genliği arttıkça açma süresinin kısalması istenir. Açma karakteristiği bu tip olan aşırı akım rölelerine ise ters zaman karakteristikli aşırı akım röleleri adı verilir. Ters zaman karakteristikli aşırı akım röleleri açma süresi-akım karakteristiklerine bağlı olarak ters, aşırı ters ve çok aşırı ters karakteristikli aşırı akım röleleri olarak sınıflandırılabilir. Söz konusu aşırı akım rölelerinin akım-açma zamanı karakteristikleri genel olarak Şekil 2’de verilmiştir. Ters zaman karakteristikli aşırı akım rölelerinin açma süreleri zaman ayarları yapılarak kullanılır.




Şekil 2. Aşırı akım röle karakteristikleri a) ani açmalı aşırı akım rölesi karakteristiği b) ters zaman karakteristikli aşırı akım röle karakteristiği (Phadke ve Thorp, 2009)

Yönlü Aşırı Akım Koruma Röleleri

Çift taraflı beslenen bir iletim hattında aşırı akım rölesi ile yapılacak koruma yeterli korumayı sağlamayabilir. Bu durumu açıklayabilmek için Şekil 3’ü göz önüne alalım. F1 noktasında meydana gelebilecek bir arızanın B noktasındaki röleden akıttığı akım F2 noktasında akıttığı akımdan daha küçük olabilir. Halbuki, F1 arızası A ve B rölelerinin koruma bölgesi içinde iken F2 arızası dışındadır. Dolayısıyla kesici açma işaretinin yalnızca akım genliğine bağlı olarak üretilmesi yeterli olmamaktadır. Bu sorun A ve B noktalarında yer alan koruma rölelerine arıza yönü tespit edebilen bir özellik kazandırılarak aşılabilir. Yönlü aşırı akım röleleri arızanın yönünü tespit ederek ters yönde açmaya izin vermezken ileri yönde meydana gelecek arızalarda açmanın yapılmasını mümkün kılar. Yön tespiti için genellikle arıza akımı ile gerilim arasındaki açı (θ) kullanılır. Yönlü aşırı akım rölesinin açması için kullanılan yön tayini açığına bağlı olarak

$-\pi < \theta < 0 \rightarrow$ açmaya izin verir,

$0 < \theta < \pi \rightarrow$ açmaya izin vermez.




Şekil 3. Çift taraftan beslenen iletim hattında a) olası arıza oluşum noktaları b) yönlü aşırı akım röle çalışma bölgesi (Phadke ve Thorp, 2009)

Mesafe Koruma Röleleri

Yalnızca aşırı akıma dayanan koruma tekniği çift taraflı beslenen iletim hatlarını korumak için yeterli değildir. Ayrıca, arıza akımının normal yük akımına yakın olması durumunda aşırı akım korumasının hassasiyeti kaybolur. Bu yüzden iletim hattı korumasında daha gelişkin bir koruma tekniği olarak mesafe koruma tekniği kullanılır. İki girişli (akım ve gerilim) koruma rölelerinden olan mesafe koruma röleleri yalnızca akım yerine gerilim ile akımın oranını kullanmakta olup oldukça işe yarayan koruma rölelerindendir. Bu oran empedansın bir ölçüsü olup iletim hattının arıza mesafesi ile orantılıdır. Bu röleler bulunduğu nokta ile arıza noktası arasındaki iletim hattının hesaplanan arıza empedansı üzerinden koruma fonksiyonunu yerine getirir.

Mesafe koruma röleleri, arıza yönünü de tespit edebilen bir yapıya sahip olup oldukça hızlı ve doğru bir çalışma biçimine sahiptir. Ayrıca ardışık bağlı iletim hatlarını koruyan diğer röleler için yedek koruma özelliğine de sahiptir. Şekil 4'te verilen radyal beslemeli iletim sistemini göz önüne alalım.



Şekil 4. Mesafe koruma rölelerinde koruma bölgeleri ve açma süreleri

Burada 1 nolu barada yer alan koruma rölesi esas olarak 1 ve 2 nolu baralar arasındaki hattı korumak için bulunduğu noktadaki akım ve gerilim değişkenlerini izler. Bu hatta meydana gelebilecek bir kısa devre arızası durumunda aynı noktadan ölçülen gerilim ve akım genliklerinin oranından arıza empedansı hesaplanır. I ölçülen akım akımının genliği ve U ölçülen gerilimin genliği olmak üzere ölçülen arıza empedansı Z_f ,


$$Z_f = \frac{U}{I} \quad (1)$$

ile hesaplanır. Z_L iletim hattının empedansı olmak üzere empedansların oranı

$$m = \frac{Z_f}{Z_L} \quad (2)$$


arıza noktası hakkında bilgi verir. Arıza noktası koruma bölgesi içinde ise röle tarafından kesiciye açma komutu gönderilerek arızalı bölge izole edilir. Bu oran röle üzerinden ayarlanarak 2 ile 3 nolu arasındaki ve 3 nolu bara sonrasındaki hatlar için de yedek koruma fonksiyonu çalıştırılmış olur. Bu değer genellikle 1. bölge için ilk hattın %80'ini, 2. bölge için birinci hattın tamamını ve ikinci hattın %50'sini ve 3. bölge için ilk iki hattın tamamını ve %10-20 fazlasını kapsayacak şekilde set edilir. Açma süresi arızanın gerçekleşme bölgesine bağlı olarak 1. bölgede hemen, 2. Ve 3. bölgelerde ise ayarlanan belli gecikmelere set edilir. Genel olarak mesafe koruma röleleri empedans röleleri, reaktans röleleri ve admitans (mho) röleleri olmak üzere üç alt sınıfa sahiptir.

Empedans röleleri hesaplanan empedans değeri üzerinden arıza noktasının röleye olan mesafesini hesaplayarak koruma bölgesi içinde olan arızalara tepki verir. Empedans röleleri orta uzunluktaki iletim hatlarının korunmasına daha uygun olan rölelerdir. Genel karakteristik Şekil 5'te verildiği gibidir.




Şekil 5. Empedans rölesinin çalışma karakteristiği

Reaktans röleleri yönlü röleler olup arıza empedansının yalnızca reaktif kısmının dikkate alındığı koruma röleleridir. Böylece arıza anında oluşan ark direncinin hatalı hesaplama yapılmasına etkisi göz ardı edilmiş olur. Reaktans röleleri kısa iletim hatları için kullanılmaya daha uygundur. Bu tip rölelerin genel karakteristiği Şekil 6’da verildiği gibidir.



Şekil 6. Reaktans rölesinin çalışma karakteristiği


Mho röleleri yönlü empedans röleleri olarak düşünülebilir. Bu rölelerde çalışma karakteristiği Şekil 7’den de görülebileceği üzere R-X düzleminde orjinden geçer. Mho rölelerde ark direncinin etkisi empedans rölelerine oranla daha az görülür. Bu tip röleler genellikle uzun iletim hatlarının korunmasına uygun rölelerdir.



Şekil 7. Mho (admitans) rölesinin çalışma karakteristiği

Pilot Koruma (Diferansiyel) Röleleri

Pilot koruma tekniği transformatörlerde kullanılan diferansiyel koruma tekniğinin iletim hatlarına uygulanan biçimidir. Genel yapı Şekil 8’de verildiği gibidir. Bu koruma tekniğinin bir iletim hattına uygulanabilmesi için hattın iki ucunda yer alan röleler arasında veri alışverişini sağlayacak bir haberleşme kanalının kullanılması gerekir. Koruma için öncelikle hattın her iki ucundan senkronize bir biçimde akım değerlerinin ölçümü yapılır. Senkronizasyon için ya veri iletişimindeki gecikme dikkate alınır ya da GPS gibi harici zaman referansları kullanılır (Prado vd., 2020). Haberleşme ile aktarılan akım verileri röle tarafından değerlendirilerek kesici konumuna karar verilir.



Şekil 8. İletim hattı pilot koruma tekniğinin şematik yapısı

Diferansiyel koruma tekniğinde hat başı ve sonundaki akımlar arasındaki vektöryel farkın sıfır olacağı varsayımı kullanılır. Fakat bu fark hattın şönt kapasitansı dikkate alındığında tam olarak sıfır değildir. Ayrıca akım trafolarının ölçüm hataları nedeniyle bu fark daha da büyük olabilir. Bu hata akan akımın artışıyla beraber daha da artar. İşte beklenen bu farktan daha büyük bir fark akımı koruma yapılan hatta bir arızanın olduğunu gösterir. Hattın başında ölçülen akım $\bar{I}_L$, hattın sonunda ölçülen akım $\bar{I}_R$ olmak üzere akımların vektöryel farkı ile vektöryel toplamının genlikleri aşağıdaki gibi tanımlanabilir.

$$I_F = |\bar{I}_L - \bar{I}_R| \quad (3)$$


$$I_T = |\bar{I}_L + \bar{I}_R| \quad (4)$$

Bu durumda diferansiyel koruma karakteristiği:

$$I_F > kI_T \text{ ise arıza var,}$$

$$I_F > kI_T \text{ ise arıza yok}$$

biçimindedir. Burada k karakteristiğinin eğimi olarak tanımlanır. Genel olarak diferansiyel koruma tekniğinin karakteristiği Şekil 9'da verildiği biçimdedir (Mogaru, 2020).



Şekil 9. Pilot (diferansiyel) koruma rölesinin çalışma karakteristiği

Yürüyen Dalga Röleleri

Yürüyen dalgalara dayalı ultra hızlı koruma tekniği 1970'li yıllarda ortaya çıkmıştır. Meydana gelen bir arıza sonrasındaki bir veya iki periyot boyunca arıza tarafından yüksek frekanslı geçici dalgalar oluşturulur. Bu geçici durum sinyallerinin analizine dayanarak, arıza yeri arızanın başlamasından itibaren birkaç milisaniye içinde hesaplanabilir. Yürüyen dalga prensibine dayanarak literatürde çok sayıda algoritma geliştirilmiştir. Bu algoritmalar arızaların oluşturduğu yüksek frekanslı dalgaların hareket süresini kullanarak arıza yerini tespit edebilmektedir. Çoğu araştırmacı, yürüyen dalga tabanlı yöntemlerin röle noktasına yakın arızalar ve küçük arıza başlangıç açılı arızalar için iyi performans göstermediğini, ayrıca çok yüksek bir örnekleme oranı gerektirdiğini ve uygulamalarının empedans tekniklerinin uygulanmasından daha maliyetli olduğunu belirtmiştir (Babu vd., 2011).

BULANIK MANTIK SİSTEMLERİNİN GENEL YAPISI

Klasik olarak bir önerme Aristo mantığına göre ya doğru ya da yanlıştır. Hâlbuki insanın düşünce yapısı bazı önermelerin kısmi olarak doğru veya yanlış olabileceğini söyler. Ayrıca, doğadaki büyüklükler belirsizlik ortamında tamamen doğru veya tamamen yanlış olarak düşünülemeyecek kadar geniş bir çeşitliliğe sahip olabilmektedir. Çok kabaca söylemek gerekirse, bulanık mantık doğada var olan önermelerin tamamen doğru

veya yanlış olacağı fikrinin aksine bir önermenin belirli oranlarda doğruluk derecesine sahip olacağı fikrine dayanır.

Bulanık mantığın dayandığı bulanık kümeler fikri ilk kez California Üniversitesinden Prof. Dr. Lütfi Zadeh tarafından klasik kümeler teorisinin genelleştirilmiş bir biçimi olarak ortaya atılmıştır (Zadeh, 1965). Bulanık kümeler ve bulanık mantık endüstride, doğada ve insan düşünce sisteminde yer alan ve belirsizlik içeren sistemleri modellemek için kullanılabilecek oldukça güçlü bir matematiksel araçtır. Tanımlanması klasik matematik ile kolay olmayan karmaşık sistemlerden yaklaşık iyi bir çözüm bulma konusunda bulanık mantık oldukça işe yarayan bir düşünme biçimidir. Japon bilim adamları bulanık mantığın endüstriye uygulanma potansiyelini ilk fark eden grup olarak bulanık mantık sistemlerini elektrikli süpürge, bulaşık makinası, kamera, yemek pişirme cihazları gibi çok sayıda ticari üründe başarılı bir şekilde kullanarak enerji verimli ve tüketici odaklı cihazlar geliştirmişlerdir (Bojadziev ve Bojadziev, 1995). Günümüzde bulanık mantığın sosyal ve teknik bilimlerin hemen hemen bütün kollarında uygulama alanı bulduğunu söyleyebiliriz. Sonuç olarak, bulanık mantık, pratik uygulamalardaki başarısından dolayı günümüzde oldukça popüler bir alandır.


Bulanık mantığın temelde sağladığı avantajlar aşağıda sıralanmıştır:

1. İnsan düşünce sistemine ve tarzına yakındır.
2. Uygulamasında mutlaka matematiksel bir modele gereksinim duymaz.
3. Yazılımın basit olması nedeniyle, sistem daha ekonomik olarak kurulabilir.
4. Bulanık Mantık kavramını anlamak kolaydır.
5. Üyelik değerlerinin kullanımı sayesinde, diğer kontrol tekniklerine göre daha esnektir.
6. Kesinlik arz etmeyen bilgilerin kullanılması söz konusudur.
7. Doğrusal olmayan fonksiyonların modellenmesine izin verebilir.
8. Sadece uzman kişilerin tecrübelerinden faydalanılarak, kolaylıkla bulanık mantığa dayalı bir modelleme ya da sistem tasarlanabilir.
9. Geleneksel kontrol teknikleriyle uyum halindedir.

10. İnsanların iletişimde kullandıkları sözel ifadelerin bulanık mantıkta kullanımı ile daha olumlu sonuçlar çıkmaktadır (Kıyak ve Kahvecioğlu, 2003;Şen, 2001;Çiftçi, 2002).


Bulanık mantık tabanlı sistemlerde belirsizlik içeren değişkenler dilsel olarak ifade edilen büyüklüklerle tanımlanır. Örneğin bir insanın çocuk, genç ve yaşlı olup olmadığını yaşına bağlı olarak ifade edebilecek bir kesin ölçek yoktur. 17 yaşında olan birisini genç veya çocuk kategorisine sokmak mümkündür. Fakat bu önermelerin belirsizlik içerdiği açıktır. Yaklaşık yüz kişi ile yapılacak bir anketin sonucunda %40 oranında çocuk ve %60 oranında genç cevabı alındığını farz edelim. Bu durumda 17 yaşındaki bir insanı tamamen çocuk veya tamamen genç olarak tanımlamaktansa %40 oranında çocuk %60 oranında genç olarak tanımlamak daha mantıklıdır. Yaş arttıkça ilk oranın düşeceği ikinci oranın da artacağını öngörmek zor değildir. Hatta daha ileri yaşlar için genç yerine yaşlı tanımı da yapılabilir. Aslında burada klasik küme mantığından farklı olarak bir insanın yaşına bağlı olarak belli oranlarda çocuk, genç ve yaşlı kümelerinin üyesi olduğu kabul edilmiş olur. Sonuç olarak bir insanı yaşına bağlı olarak 3 farklı kümeye (çocuk, genç ve yaşlı) belli oranlarda üye kabul edebiliriz. Bu üyelik için hangi fonksiyonların kullanılacağı ayrı bir konudur.

Örnek olarak, Şekil 10'da bahsedilen bu durum için üyelik fonksiyonlarının değişimi verilmiştir. Bu üyelik fonksiyonlarına göre bir insan 0 yaşında iken %100 oranında çocuk kabul edilirken yaş ilerledikçe bu oran düşmektedir. 20'li yaşlardan sonra bu oran neredeyse %0 olmaktadır. Genç olmayı tanımlayan üyelik fonksiyonuna göre ise yaklaşık olarak 25 – 55 yaşları arasında insanın neredeyse %100 oranında genç olduğu kabul edilmiş olur. Fakat yaş 25'ten geriye doğru azaldıkça veya 55'ten ileriye doğru arttıkça bu oran %100 değerinden %0'a doğru azalır.



Şekil 10. Yaşa bağlı olarak çocuk, genç ve yaşlı üyelik fonksiyonları

Yukarıdaki örnekte de ima edildiği gibi dilsel olarak ifade edilen değişkenleri nicelik olarak tanımlayan ve üyelik fonksiyonları adı verilen fonksiyonlar yardımıyla matematiksel olarak göstermiş oluruz. Kullanılan çeşitli üyelik fonksiyonlarının grafiksel gösterimleri Şekil 11’de verilmiştir (The MathWorks Inc., 2022).



Şekil 11. Başlıca bulanık mantık üyelik fonksiyon tipleri

Burada;

linzmf: linear Z-biçimli üyelik fonksiyonunu,

trimf: üçgen üyelik fonksiyonunu,

trapmf: trapez üyelik fonksiyonunu,

linsmf: linear S-biçimli üyelik fonksiyonunu

smf: S-biçimli üyelik fonksiyonunu,

gaussmf: basit gaussian üyelik fonksiyonunu,

gauss2mf: çift yanlı gaussian üyelik fonksiyonunu,

gbellmf: genelleştirilmiş çan üyelik fonksiyonunu,

zmf: Z-biçimli üyelik fonksiyonunu,

pimf: pi-biçimli üyelik fonksiyonunu,

sigmf: sigmoid üyelik fonksiyonunu,

dsigmf: d-sigmoid üyelik fonksiyonunu ve

psigmf: p-sigmoid üyelik fonksiyonunu

göstermektedir. Üyelik fonksiyonları 0 ile 1 arasında değer alabilen fonksiyonlardır. Her bir üyelik fonksiyonu belirli matematiksel ifadelere sahiptir. Örneğin gauss, genelleştirilmiş çan, sigmoid, trapez ve üçgen üyelik fonksiyonları sırasıyla aşağıdaki eşitlikler ile tanımlanır. Burada x üyelik fonksiyonunun giriş değişkenini, a, b, c, d ve σ ise bu fonksiyonların sabit değerlere sahip parametrelerini ifade eder.

$$\text{gaussmf}(x, \sigma, c) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (5)$$


$$\text{gbellmf}(x, a, b, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}} \quad (6)$$

$$\text{smf}() = \frac{1}{1 + ae^{-(x-c)}} \quad (7)$$

$$\text{trapmf}(x, a, b, c, d) = \max\left(\min\left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}, 0\right)\right) \quad (8)$$

$$\text{trimf}(x, a, b, c) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}, 0\right)\right) \quad (9)$$

Bulanık mantık sistemlerin genel yapısı Şekil 12’de verilmiştir. Giriş 1 veya 1’den fazla değişkenin sayısal değerlerinden oluşurken çıkış genellikle 1 tane sayısal değerdir.




Şekil 12. Bulanık mantık sistemlerin genel yapısı

Bulanıklaştırma birimi, giriş değişkenlerinden gelen değerleri ilgili üyelik fonksiyonları yardımıyla 0 ile 1 arasındaki değerlere dönüştürür.

Örnek bir sistem olarak, bir bulaşık makinesinin yıkama süresini bulaşık miktarına ve kirlilik derecesine göre hesaplayan bulanık mantık hesaplama sistemini göz önüne alalım. Burada iki giriş değişkeni ve bir çıkış değişkeni mevcuttur. Her bir değişken çok sayıda üyelik fonksiyonuna sahip olabilir. Bulaşık miktarı (bm) için az bulaşık (AB), orta bulaşık (OB) ve çok bulaşık (ÇB) biçiminde 3 tane üyelik fonksiyonu tanımlayabiliriz. Kirlilik derecesi (kd) için yine az kirli (AK), orta kirli (OK) ve çok kirli (ÇK) biçiminde 3 tane üyelik fonksiyonu tanımlayabiliriz. Çıkış değişkeni olan yıkama süresi (ys) için ise

benzer şekilde düşük (D), az düşük (AD), az yüksek (AY) ve yüksek (Y) biçiminde 4 tane üyelik fonksiyonu tanımlayabiliriz. Her bir üyelik fonksiyonu belirli tip fonksiyonlar kullanılarak giriş değerlerini 0 ile 1 arasında değişen değerlere dönüştüren fonksiyonlardır. Bu değişkenlerin her bir üyelik fonksiyonlarını Şekil 13'te gösterilen biçimde değişen fonksiyonlar olarak tanımlayalım.



Şekil 13. Bulaşık miktarı, kirlilik oranı ve yıkama süresi için tanımlanan üyelik fonksiyonlarının değişimi

Bulanık mantık sisteminde, öncelikle giriş değişkenlerinin her bir üyelik fonksiyonunda aldığı değerler hesaplanır. Böylece bulanıklaştırma işlemi tamamlanmış olur. Bulaşık makinesi örneğinde bulaşık miktarı %30 ve bulaşıkların kirlilik oranı %75 olarak verilmiş olsun. Bu durumda her bir giriş üyelik fonksiyonunun aldığı değer sırasıyla $\mu_{AB}(0.3)=0.5$, $\mu_{OB}(0.3)=0.5$, $\mu_{ÇB}(0.3)=0$, $\mu_{AK}(0.3)=0$, $\mu_{OK}(0.3)=0.5$ ve $\mu_{ÇK}(0.3)=0.5$ olarak hesaplanır.


Ara yüz motoru, kayıtlı kural tabanındaki bilgileri kullanarak her bir kuralın sonuç değerini hesaplar. Çamaşır makinesi örneği için örnek bir kural tabanı tablo olarak Tablo I'de verilmiştir.

TABLO I. Çamaşır makinesi örneği için örnek bir kural tabanı

Eğer	AB	ve	AK	ise	D
	OB		AK		AD
	ÇB		AK		AD
	AB		OK		AD
	OB		OK		AY
	ÇB		OK		AY
	AB		ÇK		AY
	OB		ÇK		AY
	ÇB		ÇK		Y

Burada giriş üyelik fonksiyonları “ve” operatörü ile birbirlerine bağlanmıştır. Bu operatör bazı durumlarda “veya” olabilmektedir. Ara yüz motoru her bir kural için bir değer hesaplar. Operatörün “ve” olması durumunda çıkış üyelik fonksiyonunun değeri giriş üyelik fonksiyonlarının çarpımı veya maksimum değeri alınarak elde edilir. Operatörün “veya” olması durumunda çıkış üyelik fonksiyonunun değeri giriş üyelik fonksiyonlarının ortalaması veya minimum değeri alınarak elde edilir. Örnek olarak 4. Kural için AB ve OK üyelik fonksiyonlarının bulanıklaştırılmış değerleri sırasıyla 0.5 olduğu göz önüne alınarak “Eğer AB ve AK ise D” kuralı çarpım kullanılarak işletildiğinde $\mu_D(K4) = \mu_{AB}(0.3) \times \mu_{AK}(0.7) = 0.25$ bulunur. Arayüz motoru tarafından her bir kuralın işletilmesi sonucunda kural sayısı kadar çıkış değişkeni değeri elde edilir.

Durulaştırma biriminde, ara yüz motorundan gelen değerler birleştirilerek tek bir sayısal sonuç elde edilir. Çok sayıda değerden bir sonuç elde etmek için ağırlık merkezi yöntemi, ağırlıklı ortalama yöntemi, maksimum yöntemi, maksimumların ortalaması yöntemi gibi pek çok yöntem kullanılır. Şekil 14’te ağırlık merkezi yöntemi kullanılarak çıkış değerinin hesaplanmasına ait örnek bir görsel verilmiştir. Burada çıkış değişkenine ait her bir üyelik fonksiyonunun hesaplanan aktivasyon seviyesine göre üyelik fonksiyonlarının ağırlık değerleri hesaplanarak ağırlık merkezi bulunmaktadır.



Şekil 14. Ağırlık merkezi yöntemi kullanılarak bulanık mantık çıkış değerinin hesaplanması

BULANIK MANTIK TABANLI İLETİM HATTI KORUMA YÖNTEMLERİ

İletim hatlarında ortaya çıkabilecek arızalar çok sayıda belirsizlik içerir. Bulanık mantık, bu belirsizliklerin üstesinden gelebilmek için uygun bir araç olarak öne çıkar.

İletim hattı korumada kullanılan röleler genel olarak 4 ana birimden oluşur. İlk birimde hatta arızanın olup olmadığı tespit edilir. Arızanın varlığı tespit edildiğinde arızanın sınıflandırılmasını yapan ikinci birim aktive edilir. Arızanın ne tip bir arıza olduğu (faz-toprak, faz-faz, faz-faz-toprak, 3 faz, 3 faz toprak) rölenin ölçtüğü akım ve/veya gerilim değerleri üzerinden bulunur. Üçüncü bir birim ise arızanın konumunu tespit etmek için yine akım ve/veya gerilim bilgilerini kullanır. Dördüncü birim ise arızalı kısmın devre dışı bırakılması amacıyla ilgili kesiciye açma komutu gönderir (Hessine, 2017).

Arızanın tespiti ve sınıflandırılmasında kullanılan gerilim ve akım değerleri öncelikle bir ön işleme tabi tutulur. Ön işlem gerilim ve akım işaretlerinin gürültüden arındırılması, temel frekans bileşenlerinin hesaplanması ve simetrik bileşenlerinin bulunması amacıyla yapılır (Raju ve Koley, 2016). Simetrik bileşenlerin hesabı için kullanılan eşitlik

$$\begin{bmatrix} I_{a0} \\ I_{a1} \\ I_{a2} \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & 1 & 1 \\ 1 & a & a^2 \\ 1 & a^2 & a \end{bmatrix} \begin{bmatrix} I_a \\ I_b \\ I_c \end{bmatrix} \quad (10)$$


biçimindedir. Burada I_a , I_b ve I_c sırasıyla a, b ve c fazının akımlarını, I_{a0} , I_{a1} ve I_{a2} ise sırasıyla a fazı akımının sıfır, pozitif ve negatif akım bileşenlerini göstermektedir. a ise

$$a = e^{-j2\pi/3} \quad (11)$$


olarak tanımlanan bir karmaşık sayı sabitini gösterir. Benzer dönüşüm gerilimler için de kullanılarak gerilimin simetrik bileşenleri kolaylıkla bulunabilir.

Üç fazlı arızalarda bileşen akımlarının genliği yaklaşık olarak sıfırdır. Negatif bileşendeki artış faz-faz arızalarının oluştuğunun bir işaretidir. Faz-toprak arızalarında ise sıfır bileşen genliği artış gösterecektir. Bulanık mantık tabanlı iletim hattı koruma sistemlerinde genellikle bileşen akımlarının genliği ve/veya açıları kullanılarak arızanın tespiti yapılır. İletim hatlarının bulanık mantık teknikleri kullanılarak korunmasını öneren oldukça geniş bir literatür mevcuttur. Konuyla alakalı olarak yapılmış bazı çalışmalara (Ferreira vd., 2016; Samantaray, 2013; Rebizant ve Solak, 2011; Reddy ve Mohanta, 2007; Dash vd., 2000; Kasztenny vd., 1997; Youssef, 2004a; Youssef, 2004b; Sa'ad Ahmed vd., 2020; Chin, 2003; Das ve Reddy, 2005; Wang ve Keerthipala, 1998; Yadav ve Swetapadma, 2015; Maamoon, 2004) referanslarından ulaşılabilir. Aşağıda konu ile ilgili literatürde yer alan bazı çalışmalar özet olarak verilmiştir.

(Solak vd., 2012) ve (Abasi vd., 2019)'da verilen iki benzer çalışmada iletim hatları için bir bulanık mantık tabanlı adaptif diferansiyel koruma tekniği sunulmuştur. Önerilen uyarlamalı bulanık şema, akım ve faz karşılaştırmalı koruma kriterlerinin güçlü yönlerini birleştirmektedir. Önerilen yapıda, bir bulanık mantık yapısı yardımıyla diferansiyel rölenin açma karakteristiği (Şekil 15) adaptif olarak güncellenmektedir. Yöntemin hesaplama blok şeması Şekil 16'da verilmiştir. Burada, bileşen akımları ve faz farkları bulanık mantık hesaplama biriminin girişine verilmekte ve bulanık mantık hesaplama birimi tarafından rölenin karakteristiğini belirleyen k_1 ve k_2 değişkenleri hesaplanmaktadır. Ayrıca diferansiyel ve bias akımları (I_d ve I_{bias}) da hesaplanarak güncellenen çalışma karakteristiğine göre kesici konumuna karar verilmektedir. Böylece akım trafosu doymasına daha dayanıklı bir koruma yöntemi ortaya konulmuştur.



Şekil 15. İletim hattı koruması için kullanılan diferansiyel rölenin çalışma karakteristiği




Şekil 16. (Solak vd., 2012)'de önerilen iletim hattı diferansiyel koruma rölesinin hesaplama şeması

(Katyara vd., 2018)'de bulanık mantık tabanlı bir arıza tespit ve sınıflandırma yöntemi verilmiştir. Yöntem, ayrıca, arızalı bölgenin izole edilmesi için gerekli sürenin hesaplanmasını da sağlamaktadır. Sınıflandırma için akımın sıfır ve pozitif bileşenlerinin genlikleri kullanılmıştır. Düşük akım D ve yüksek akım Y olmak üzere önerilen bulanık mantık kuralları sırasıyla aşağıda verilmiştir.

- Eğer $I_a \rightarrow D$ ve $I_b \rightarrow D$ ve $I_c \rightarrow D$ ve $I_n \rightarrow D$ ise arıza yok,*
- Eğer $I_a \rightarrow Y$ ve $I_b \rightarrow Y$ ve $I_c \rightarrow Y$ ve $I_n \rightarrow D$ ise 3 faz arızası,*
- Eğer $I_a \rightarrow Y$ ve $I_b \rightarrow Y$ ve $I_c \rightarrow Y$ ve $I_n \rightarrow Y$ ise 3 faz-toprak arızası,*
- Eğer $I_a \rightarrow Y$ ve $I_b \rightarrow D$ ve $I_c \rightarrow D$ ve $I_n \rightarrow Y$ ise 1 faz-toprak arızası,*
- Eğer $I_a \rightarrow D$ ve $I_b \rightarrow Y$ ve $I_c \rightarrow D$ ve $I_n \rightarrow Y$ ise 1 faz-toprak arızası,*
- Eğer $I_a \rightarrow D$ ve $I_b \rightarrow D$ ve $I_c \rightarrow Y$ ve $I_n \rightarrow Y$ ise 1 faz-toprak arızası,*
- Eğer $I_a \rightarrow Y$ ve $I_b \rightarrow Y$ ve $I_c \rightarrow D$ ve $I_n \rightarrow D$ ise faz-faz arızası,*
- Eğer $I_a \rightarrow Y$ ve $I_b \rightarrow D$ ve $I_c \rightarrow Y$ ve $I_n \rightarrow D$ ise faz-faz arızası,*
- Eğer $I_a \rightarrow D$ ve $I_b \rightarrow Y$ ve $I_c \rightarrow Y$ ve $I_n \rightarrow D$ ise faz-faz arızası,*
- Eğer $I_a \rightarrow Y$ ve $I_b \rightarrow Y$ ve $I_c \rightarrow D$ ve $I_n \rightarrow Y$ ise faz-faz-toprak arızası,*
- Eğer $I_a \rightarrow Y$ ve $I_b \rightarrow D$ ve $I_c \rightarrow Y$ ve $I_n \rightarrow Y$ ise faz-faz-toprak arızası,*
- Eğer $I_a \rightarrow D$ ve $I_b \rightarrow Y$ ve $I_c \rightarrow Y$ ve $I_n \rightarrow Y$ ise faz-faz-toprak arızası var.*

Benzer bir çalışma (Sahu ve Yadav, 2018)'de verilmiştir. Bu çalışmada önerilen hesaplama yöntemi ile arızaların tespiti ve sınıflandırılması yapılmaktadır. Bunun için ölçülen hat gerilim ve akım değerleri öncelikle bir alçak geçiren süzgeç yardımıyla gürültüden arındırılarak örneklenmekte ve sonrasında Ayırık Fourier Dönüşümü yardımıyla temel bileşenlerin hesabında kullanılmaktadır. Temel bileşenler bulanık

hesaplama birimine verilerek arızanın tespiti ve sınıflandırılması gerçekleştirilmektedir. Önerilen yöntemin blok hesaplama şeması Şekil 17’de verilmiştir.



Şekil 17. (Sahu ve Yadav, 2018)’de verilen arıza tespit ve sınıflandırma yönteminin blok şeması

İletim hattında meydana gelebilecek arızanın tespiti ve sınıflandırılması için önerilen bir başka yöntem ise (Verma vd., 2017)’de verilmiştir. Bu çalışmada 6-fazlı sistemlerde meydana gelebilecek 120 farklı arıza ihtimali görece basit bir yapı kullanılarak sınıflandırılmaktadır. Bunun için rölenin bulunduğu konumdan ölçülen gerilim ve akım değerleri ölçülerek bir alçak geçiren filtreye verilerek gürültüden arındırılmaktadır. Daha sonra bu işaretler Ayırık Fourier Dönüşümü’ne tabi tutularak temel frekans bileşenlerinin elde edilmesi sağlanmaktadır. Bir sonraki aşamada ise arızanın var olup olmadığı gerilimlerin genliğindeki değişime bakılarak karar verilmektedir. Bunun için önce gerilimlerin genliklerinin toplamı hesaplanmakta ve bir eşik değeri ile karşılaştırılarak arızanın varlığının tespiti yapılmaktadır:

$$V_{sum} = |V_a| + |V_b| + |V_c| + |V_d| + |V_e| + |V_f| \quad (12)$$

eğer $|V_{sum}| < V_{thrs}$ ise arıza var,

eğer $|V_{sum}| > V_{thrs}$ ise arıza yok.

Eğer arıza varsa bulanık mantık tabanlı arıza sınıflandırma devreye alınarak arıza tipi belirlenmektedir. Bulanık mantık girişleri olarak gerilim ve akımların faz açılarında

meydana gelen değişim kullanılmıştır. Arızanın toprak temasını da içerip içermediğinin tespiti için akımın sıfır bileşeni hesaplanarak bir eşik değerle karşılaştırılmaktadır. Yani,

Eğer $|I_0| < I_{thrs}$ ise toprak arızası var,

Eğer $|I_0| > I_{thrs}$ ise toprak arızası yok.

(Ali vd., 2013)'te çift beslemeli bir iletim hattı için tasarlanan bulanık mantık tabanlı bir otomatik tekrar kapamalı koruma yöntemi verilmiştir. Otomatik tekrar kapamalı koruma sistemleri kısa süreli geçici arıza sonrası güç sistemi kararlılığını sağlamada kullanılan koruma biçimidir. Geçici arızalar, iletim hatlarında oluşan arızaların yaklaşık %80-90'ını oluşturmakta olup bu arızalar genellikle yıldırım etkisi ile hatta oluşan kısa süreli arızalardan ve şiddetli rüzgar nedeniyle oluşan kısa süreli temaslardan dolayı ortaya çıkar. Otomatik tekrar kapamalı koruma sistemlerinde öncelikle oluşan arızanın geçici mi yoksa sürekli olduğu belirlenir. Geçici arıza durumunda ise belirli bir gecikme süresi sonrasında kesiciye tekrar kapama komutu gönderilir (Ali vd., 2013).

(Ali vd., 2013)'te verilen yöntemde arızaların izlenmesi için hat akımlarının genlikleri yerine faz açıları kullanılmaktadır. Arızanın cinsini belirlemek için hat akımlarının pozitif ve negatif bileşenlerinin faz açıları arasındaki fark kullanılmaktadır. Her bir faz için hesaplanan bu açı farkları arızanın cinsini belirlemek üzere bulanık mantık tabanlı sınıflayıcıya verilmektedir.

Arıza tipinin bulanık mantık birimleri kullanılarak elde edildiği bir başka çalışma (Razi vd., 2007)'de verilmiştir. Bu çalışmada yalnızca 3-faz akımları kullanılarak arızanın sınıflandırılması yapılmaktadır. Ölçülen akımların öncelikle temel frekanstaki simetrik bileşenleri Ayırık Fourier Dönüşümü kullanılarak elde edilmektedir. Sonrasında, sırasıyla a, b ve c fazlarının temel frekanstaki simetrik bileşenleri $I_{a0}, I_{a1}, I_{a2}, I_{b0}, I_{b1}, I_{b2}, I_{c0}, I_{c1}, I_{c2}$ olmak üzere bu bileşenlerin arıza sonrası değerlerinden sırasıyla aşağıdaki açı ve oranlar hesaplanmaktadır.

$$A_{çl_A} = |A_{çl}(I_{a1f}) - A_{çl}(I_{a2f})| \quad (13)$$

$$A_{çl_B} = |A_{çl}(I_{b1f}) - A_{çl}(I_{b2f})| \quad (14)$$

$$A_{çl_C} = |A_{çl}(I_{c1f}) - A_{çl}(I_{c2f})| \quad (15)$$

$$R_{0f} = \frac{I_{a0f}}{I_{a1f}} \quad (16)$$

$$R_{2f} = \frac{I_{a2f}}{I_{a1f}} \quad (17)$$


Ayrıca arıza öncesi ile sonrası arasında pozitif bileşenin açı değişimi hesaplanır.

$$\Delta A = |A_{\text{Çİ}}(I_{a1f}) - A_{\text{Çİ}}(I_{a1pf})| \quad (18)$$


$$\Delta B = |A_{\text{Çİ}}(I_{b1f}) - A_{\text{Çİ}}(I_{b1pf})| \quad (19)$$

$$\Delta C = |A_{\text{Çİ}}(I_{c1f}) - A_{\text{Çİ}}(I_{c1pf})| \quad (20)$$


Hesaplanan toplamda 8 değer tasarlanan bulanık mantık sisteminin giriş değişkenleridir. Çıkış değişkeni ise arıza tipi adı verilen bir değişkendir. Açıl_A, Açıl_B ve Açıl_C için üyelik fonksiyonları Şekil 18’de, R_{0f} için üyelik fonksiyonları Şekil 19’da, R_{2f} için üyelik fonksiyonları Şekil 20’de ve Delta_A, Delta_B, Delta_C için üyelik fonksiyonları Şekil 21’de verilmiştir. Ayrıca Arıza tipi için üyelik fonksiyonları Şekil 22’de verilmiştir.




Şekil 18. Açıl_A, Açıl_B ve Açıl_C için üyelik fonksiyonları




Şekil 19. R_{0f} için üyelik fonksiyonları



Şekil 20. R_{2f} için üyelik fonksiyonları



Şekil 21. Delta_A, Delta_B, Delta_C için üyelik fonksiyonları



Şekil 22. Çıkış değişkeni “arıza tipi” için üyelik fonksiyonları

Bu çalışmada bulanık mantık sisteminde kullanılan kural tabanı TABLO II’de verilen bilgiler yardımıyla oluşturulmuştur. Örneğin bu tablodan “Açı_A=30 ve Açı_B=150 ve Açı_C=90 ve $R_{of}=1$ ve $R_{2f}=1$ ve Delta_A=Negative_high ve Delta_B=Small ve Delta_C=Small ise arıza tipi=a-g” biçiminde bir kural yazılabilir.

TABLO II. (Razi vd., 2007)’de verilen bulanık mantık sınıflayıcı için kullanılan bilgi tabanı

Type of fault	ang_A	ang_B	ang_C	R_{of}	R_{2f}	delta_A	delta_B	delta_C
a-g	30°	150°	90°	1.0	1.0	Negative high	Small	Small
b-g	90°	30°	150°	1.0	1.0	Small	Negative high	Small
c-g	150°	90°	30°	1.0	1.0	Small	Small	Negative high
a-b	30°	90°	150°	0.05	1.0	Negative high	Negative high	Small
b-c	150°	30°	90°	0.05	1.0	Small	Negative high	Negative high
c-a	90°	150°	30°	0.05	1.0	Negative high	Small	Negative high
a-b-g	30°	90°	150°	0.5	0.5	Negative high	Negative high	Small
b-c-g	150°	30°	90°	0.5	0.5	Small	Negative high	Negative high
c-a-g	90°	150°	30°	0.5	0.5	Negative high	Small	Negative high
Symmetric	-	-	-	0.05	0.05	Negative high	Negative high	Negative high

(Dawood vd., 2018)’de verilen bir başka çalışmada, iletim hattında meydana gelebilecek toprak temaslı arızaların tespiti ve sınıflandırılması için bir bulanık mantık tabanlı yöntem sunulmuştur. Yöntem arızanın röle noktasından ileri veya geri noktada olup olmadığını da tespit edebilmektedir. Arızaların sınıflandırılması için referans gerilimi ile sıfır bileşen akımı arasındaki açı (D), sıfır bileşen akımı (I_n) ve faz gerilimlerinin etkin

değerleri (V_a , V_b ve V_c) kullanılan değişkenlerdir. Referans gerilim olarak 3-fazlı gerilimlerin sıfır bileşeni (V_0) kullanılmaktadır. D açısının aldığı değer aslında arızanın oluşum noktası hakkında bilgi vermektedir. Öyle ki

eğer $0 < D < \pi$ ise arıza ileri yöndedir ve

eğer $\pi < D < 2\pi$ ise arıza geri yöndedir.

Öte yandan arızanın olduğu fazdaki gerilim önemli derecede düşerken akım dramatik bir biçimde yükselecektir. Bu bilgiler bulanık mantık giriş değişkenlerinin ve kural tabanının oluşturulmasında kullanılmıştır. Önerilen yapıda kullanılan giriş ve çıkış değişkenlerine ait üyelik fonksiyonları Şekil 23'te verilmiştir. Yöntemin kullandığı kural tabanı ise aşağıdaki gibidir;

Eğer $D \rightarrow FR$ ve $I_n \rightarrow IH$ ve $V_a \rightarrow VH$ ise ileri yönde A fazı-toprak arızası var,


Eğer $D \rightarrow FR$ ve $I_n \rightarrow IH$ ve $V_b \rightarrow VH$ ise ileri yönde B fazı-toprak arızası var,

Eğer $D \rightarrow FR$ ve $I_n \rightarrow IH$ ve $V_c \rightarrow VH$ ise ileri yönde C fazı-toprak arızası var,

Eğer $D \rightarrow R$ ve $I_n \rightarrow IH$ ve $V_a \rightarrow VH$ ise geri yönde A fazı-toprak arızası var,

Eğer $D \rightarrow R$ ve $I_n \rightarrow IH$ ve $V_b \rightarrow VH$ ise geri yönde B fazı-toprak arızası var,


Eğer $D \rightarrow R$ ve $I_n \rightarrow IH$ ve $V_c \rightarrow VH$ ise geri yönde C fazı-toprak arızası var.



Şekil 23. (Dawood vd., 2018)'de kullanılan giriş ve çıkış değişkenlerine ait üyelik fonksiyonları

(Dawood vd., 2021)'de verilen bir başka çalışma ise (Dawood vd., 2018)'deki ile benzerlik göstermekte olup bu çalışmada faz-faz arızalarının yönünü ve hangi fazlar arasında oluştuğunu bulmak için önerilmiştir. Arızaların yönüne faz akımları ile faz-faz

gerilimleri arasındaki açı kullanılarak karar verilmektedir. Bu açılar sırasıyla D_1 açısı (I_a ile V_{cb} arasındaki açı), D_2 açısı (I_b ile V_{ac} arasındaki açı) ve D_3 açısı (I_c ile V_{ab} arasındaki açı)'dır. Açıların $0-\pi$ aralığında olması arızanın ileri yönde olduğunu ve $\pi-2\pi$ aralığında olması arızanın geri yönde olduğunu gösterir. Arıza sınıflandırma için bu açılar dışında ayrıca gerilimlerin etkin değerleri (V_a , V_b ve V_c) de kullanılır. Öyle ki arızanın olduğu fazlarda gerilim genliği azalacaktır. Açılar ve gerilimler için kullanılan bulanık mantık üyelik fonksiyonları ile arıza tipine ait üyelik fonksiyonları Şekil 24'te verilmiştir. Kullanılan bulanık mantık kuralları ise aynı anda genliği küçük olan fazlar arasında bir arıza olduğu ve yönünün de açının aralığına göre belirlendiği durumlara uygun olarak belirlenmiştir. Örneğin ileri yönde a ve b fazları arasında arıza oluşumu kuralı "Eğer $V_a \rightarrow VL$ ve $V_b \rightarrow VL$ ve $D_1 \rightarrow FR$ ise a-b fazları arasında ileri yönde arıza var" biçiminde olacaktır.




Şekil 24. (Dawood vd., 2021)'de önerilen yapıda kullanılan bulanık mantık üyelik fonksiyonları

(Touati vd., 2024)'te verilen bir başka çalışmada ise arıza sonrası yalnızca hat gerilimlerinin THD değerleri kullanılarak iletim hattında arızanın olup olmadığı, arızalı hattın tespiti, arıza tipinin tespiti ve arıza noktasının tespiti yapılmaktadır. Çalışmada kullanılan bulanık mantık biriminin giriş değişkenleri fazların THD değerleri iken çıkış değişkenleri arıza bölgesi, arızalı fazlar ve toprak arızasının olup olmamasıdır. Kullanılan kural sayısı ise 41 olarak verilmiştir. Önerilen yapının performansı simülasyon çalışmaları yapılarak akım ve gerilim genliği kullanan 6 girişli bulanık mantık biriminin performansı ile karşılaştırılmış ve bu yöntemle olan üstünlüğü ortaya konulmuştur. Öyle ki önerilen yapının daha az sayıda ölçüm gerektirmesi, düşük cevap süresi ve arızalarla bozunumları ayırt edebilme gücü bakımından daha iyi olduğu gösterilmiştir.

(Rajeswary vd., 2016)'da verilen bir çalışmada üzerinde bir TCSC cihazı bulunan iletim hattında meydana gelen arızaların tespiti ve sınıflandırılması için hattın iki ucundan

ölçülen akımların Wavelet Dönüşümü sonucunda elde edilen detay katsayıları kullanılmıştır. Bunun için önce hattın iki ucundan ölçülen akımlardan elde edilen detay katsayıları arasındaki fark alınmakta ve her üç faz için elde edilen fark değerleri toplanarak bir eşik değeri ile karşılaştırılmaktadır. Karşılaştırma sonucunda arızanın olup olmadığı ve varsa arızanın tipi elde edilmektedir. Arıza konumunun belirlenmesi ise hattın bir tarafından ölçülen akımların Wavelet Dönüşümü sonucunda elde edilen MRA değerlerinin bir bulanık mantık birimine verilmesiyle yapılmaktadır. Değeri 0 ile 1 arasında değişen bu giriş değişkeni için ve arıza bölgesini gösteren çıkış değişkeni için tanımlanan üyelik fonksiyonları ise Şekil 25'te verilmiştir.




Şekil 25. (Rajeswary vd., 2016)'de arıza mesafesini belirlemek için kullanılan giriş ve çıkış değişkeni üyelik fonksiyonları


Farklı arıza oluşum açıları kullanılarak yapılan simülasyon çalışmaları önerilen yöntemin çeşitli iletim hattı arızalarını farklı arıza bölgeleri için iyi bir şekilde tespit edebildiğini göstermiştir.

(Kumar vd., 1999)'de iletim hatlarında oluşan arızalar sonrasında ortaya çıkan yürüyen dalgalara dayalı bir bulanık mantık tabanlı koruma rölesi algoritması tanıtılmıştır. Algoritma, faz-toprak ve faz-faz arızalarının tespitine yönelik geliştirilmiştir. Yürüyen dalganın oluşumu anı ile yansıması arasında geçen süre arıza noktasının tespitinde kullanılmıştır. Bir iletim hattında bir faz-toprak arızası oluştuğunda gerilimde ve akımda yüksek frekanslı bileşenler oluşur. Bu bileşenler arıza noktasında iki tarafa doğru hareket ederek zamanla kaybolur. Oluşan bu bileşenlerin değeri arıza noktasındaki gerilime, arızanın oluştuğu faz açısına, arıza akımının aktığı arıza direncine bağlıdır. Bu


bilgiler arızanın türü ve konumu hakkında önemli bilgiler verir. Çalışmada önerilen yöntemde, öncelikle arızanın karakteristik empedansının modal bileşenleri ve yürüyen dalğanın yansıma süresi hesaplanmaktadır. Bu iki değişken bir bulanık mantık birimine verilerek çıkış değişkenleri olan arıza mesafesi ve arıza tipi elde edilmektedir. Giriş değişkenlerine ait üyelik fonksiyonları Şekil 26 ve 27’de verilmiştir. Arıza mesafesi değişkeni için üyelik fonksiyonları ise Şekil 28’de verilmiştir.



Şekil 26. yürüyen dalğanın yansıma süresi için üyelik fonksiyonları



Şekil 27. Karakteristik empedansının modal bileşeni için üyeli fonksiyonları



Şekil 28. Arıza mesafesi için üyelik fonksiyonları

TABLO III. (Kumar vd., 1999)'de önerilen algoritmanın kural tabanı tablosu

IF		THEN	
Time	Modal characteristic impedance	Distance	Type of Fault
VS	LOW	VC	PP
S	LOW	C	PP
M	LOW	F	PP
L	LOW	MF	PP
VL	LOW	VF	PP
VS	MEDIUM	VC	PPP
S	MEDIUM	C	PPP
M	MEDIUM	F	PPP
L	MEDIUM	MF	PPP
VL	MEDIUM	VF	PPP
VS	HIGH	VC	PG
S	HIGH	C	PG
M	HIGH	F	PG
L	HIGH	MF	PG
VL	HIGH	VF	PG

(Youssef, 2004c)'de güç sisteminde yer alan iletim hattının fazlarının birbirinden bağımsız olarak açma/kapama işleminin yapıldığı ve otomatik geri kapamanın kullanıldığı koruma biçimi için bulanık mantık tabanlı bir koruma algoritması sunulmuştur. Önerilen yöntem hat akımlarını kullanmaktadır. Yöntemde öncelikle ölçülen hat akımlarının dc bileşenlerinden arındırılmaktadır. Bunun için ardışık iki örnek aşağıdaki eşitlikte verildiği biçimde kullanılır.

$$i(k)_{no-offset} = i(k) - \frac{i(k-1)}{e^{\frac{h}{\tau}}} = i(k) - 1.003i(k-1) \quad (21)$$

Burada h örnekleme aralığını ve τ zaman sabitini göstermekte olup çalışmadaki örnekte bu sabitler için sırasıyla 1/4500 s ve 0.08 s değerleri kullanılmıştır. Doğru bileşenden arındırılan akım işareti bir sonraki aşamada harmonik bileşenlerinden arındırılmaktadır. Bunun için Wavelet tabanlı bir yöntem kullanılmakta olup kullanılan pencere 10 örnekle genişliğe sahiptir. Sonraki aşamada ise akımların simetrik bileşenleri hesaplanmaktadır. Toprak arızasının olup olmadığı sıfır bileşenin tepe değerinin pozitif bileşen tepe değerine olan oranının karesi üzerinden belirlenmektedir. Bu oran için kullanılan eşitlik aşağıdaki gibi verilmiştir.

$$\frac{\hat{i}_0(k)^2}{\hat{i}_1(k)^2} = \frac{i_0(k)^2 + C_3^2(i_0(k+1) - i_0(k-1))^2}{i_1(k)^2 + C_3^2(i_1(k+1) - i_1(k-1))^2} \quad (22)$$

Burada kullanılan sabit

$$C_3 = \frac{1}{2\pi f h} \quad (23)$$

olarak tanımlanmıştır. Faz akımlarının faz açıları ise aşağıdaki eşitlikle hesaplanmaktadır.

$$\varphi_{ia,b,c}(k) = C_1 \frac{i_{a,b,c}(k+1) - i_{a,b,c}(k-1)}{C_2(i_{a,b,c}(k+1) - i_{a,b,c}(k-1)) + i_{a,b,c}(k)} \quad (24)$$

Son eşitlikteki sabitler ise θ_s örnekleme açısı olmak üzere aşağıdaki biçimde tanımlanmıştır.

$$C_1 = 1 + \cos\theta_s^2 / \sin\theta_s \quad (25)$$

$$C_2 = \cos\theta_s \quad (26)$$

Sonrasında açılar arasındaki farklar hesaplanmaktadır.

$$Ci_{ab}(k) = \varphi_{ia}(k) - \varphi_{ib}(k) \quad (27)$$

$$Ci_{bc}(k) = \varphi_{ib}(k) - \varphi_{ic}(k) \quad (28)$$

$$Ci_{ca}(k) = \varphi_{ic}(k) - \varphi_{ia}(k) \quad (29)$$

Daha sonra bulanık mantık girişleri olarak kullanılacak olan açı farklarının oranları elde edilir.

$$IP_1 = \frac{Ci_{ab}(k)}{Ci_{bc}(k)} \quad (30)$$


$$IP_2 = \frac{Ci_{bc}(k)}{Ci_{ca}(k)} \quad (31)$$

$$IP_3 = \frac{Ci_{ca}(k)}{Ci_{ab}(k)} \quad (32)$$


Diğer bulanık mantık giriş değişkeni ise aşağıdaki gibi tanımlanmıştır.

$$IP_4 = \frac{\hat{I}_0(k)^2}{\hat{I}_1(k)^2} \quad (33)$$

Çıkış değişkeni ise arızalı fazı temsi edecek şekilde 1, 2 ve 3 sayılarından oluşmaktadır. Kullanılan üyelik fonksiyonları Şekil 29'da verilmiştir. Kullanılan kural tabanı ise genel yapı ile beraber Şekil 30'da verilmiştir.



Şekil 29. (Youssef, 2004c)'de kullanılan üyelik fonksiyonları



Şekil 30. (Youssef, 2004c)'de kullanılan genel yapı ve kural tabanı

KAYNAKÇA

- Abasi, M., Farsani, A. T., Rohani, A., & Shiran, M. A. (2019, February). Improving differential relay performance during cross-country fault using a fuzzy logic-based control algorithm. In *2019 5th Conference on Knowledge Based Engineering and Innovation (KBEI)* (pp. 193-199). IEEE.
- Ali, A. J., Allu, A. A., & Antar, R. K. (2013, December). Fuzzy logic technique based single phase auto-reclosing protection system of a double circuit transmission line. In *2013 International Conference on Electrical Communication, Computer, Power, and Control Engineering (ICECCPCE)* (pp. 31-36). IEEE.
- Babu, K. V., Tripathy, M., & Singh, A. K. (2011). Recent techniques used in transmission line protection: a review. *International Journal of Engineering, Science and Technology*, 3(3).
- Balki, M. K., Çavuş, V., Duran, İ. U., Tuna, R., & Sayin, C. (2018). Experimental study and prediction of performance and emission in an SI engine using alternative fuel with artificial neural network. *International Journal of Automotive Engineering and Technologies*, 7(1), 58-64.
- Bojadziev, G., & Bojadziev, M. (1995). *Fuzzy sets, fuzzy logic, applications* (Vol. 5). World scientific.
- Chin, H. C. (2003). Fault section diagnosis of power system using fuzzy logic. *IEEE Transactions on Power Systems*, 18(1), 245-250.
- Çiftçi, H. (2002). Fuzzy logic approximation for some mathematical functions. *OGÜ Lisans Tezi, Eskişehir*.
- Dash, P. K., Pradhan, A. K., & Panda, G. (2000). A novel fuzzy neural network based distance relaying scheme. *IEEE Transactions on Power Delivery*, 15(3), 902-907.
- Das, B., & Reddy, J. V. (2005). Fuzzy-logic-based fault classification scheme for digital distance protection. *IEEE transactions on power delivery*, 20(2), 609-616.
- Dawood, R. M. S., Al-Greer, M., & Pillai, G. (2021, August). Fuzzy Logic Based Scheme for Directional Overcurrent Detection and Classification for Transmission Line. In *2021 56th International Universities Power Engineering Conference (UPEC)* (pp. 1-6). IEEE.
- Dawood, R. M. S., Pillai, G., & Al-Greer, M. (2018, September). Fuzzy logic based scheme for directional earth fault detection and classification. In *2018 53rd International Universities Power Engineering Conference (UPEC)* (pp. 1-6). IEEE.
- Ferreira, V. H., Zanghi, R., Fortes, M. Z., Sotelo, G. G., Silva, R. D. B. M., Souza, J. C. S., ... & Gomes Jr, S. (2016). A survey on intelligent system application to fault diagnosis in electric power system transmission lines. *Electric Power Systems Research*, 136, 135-153.
- Hessine, M. B., Marrouchi, S., & Chebbi, S. (2017, January). A fault classification scheme with high robustness for transmission lines using fuzzy-logic system. In *2017 International Conference on Advanced Systems and Electric Technologies (IC_ASET)* (pp. 256-261). IEEE.
- Kasztenny, B., Rosolowski, E., Saha, M. M., & Hillstrom, B. (1997). A self-organizing fuzzy logic based protective relay-an application to power transformer protection. *IEEE Transactions on Power Delivery*, 12(3), 1119-1127.
- Katyara, S., Akhtar, F., Solanki, S., Leonowicz, Z., & Staszewski, L. (2018, June). Adaptive fault classification approach using digitized fuzzy logic (dfl) based on sequence components. In *2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)* (pp. 1-7). IEEE.

- Kıyak, E., & Kahvecioğlu, A. (2003). Bulanık Mantık ve Uçuş Kontrol Problemine Uygulanması. *Journal of Aeronautics and Space Technologies*, 1(2), 63-72.
- Kumar, P., Jamil, M., & Thomas, M. S. (1999, September). Fuzzy approach to fault classification for transmission line protection. In *Proceedings of IEEE. IEEE Region 10 Conference. TENCN 99. Multimedia Technology for Asia-Pacific Information Infrastructure* (Cat. No. 99CH37030) (Vol. 2, pp. 1046-1050). IEEE.
- Maamoon, F. A. (2004). A Fuzzy Logic Distance Relay. *American Journal of Electrical Power and Energy Systems*, 3(5), 95-100.
- Mogaru, N. O. (2020, August). The basics of transmission line protection. In *2020 IEEE PES/IAS PowerAfrica* (pp. 1-5). IEEE.
- Norouzi, A. (2021). The Shape of a Zone: Distance Relaying Technology From Electromechanical to Digital. *IEEE Industry Applications Magazine*, 28(2), 78-88.
- Phadke, A. G., & Thorp, J. S. (2009). *Computer relaying for power systems*. John Wiley & Sons.
- Prado, I. F., Medeiros, R. P., Costa, F. B., & Silva, K. M. (2020). A Performance Analysis of Transmission Line Differential Protection. *Simpósio Brasileiro de Sistemas Elétricos-SBSE*, 1(1).
- Rajeswary, G. R., Kumar, G. R., Lakshmi, G. J. S., & Anusha, G. (2016, March). Fuzzy-wavelet based transmission line protection scheme in the presence of tcsc. In *2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)* (pp. 4086-4091). IEEE.
- Raju, G. V., & Koley, E. (2016, December). Fuzzy logic based fault detector and classifier for three phase transmission lines with STATCOM. In *2016 international conference on electrical power and energy systems (ICEPES)* (pp. 469-474). IEEE.
- Razi, K., Hagh, M. T., & Ahrabian, G. (2007, December). High accurate fault classification of power transmission lines using fuzzy logic. In *2007 International Power Engineering Conference (IPEC 2007)* (pp. 42-46). IEEE.
- Rebizant, W., & Solak, K. (2011, December). Transmission line differential protection with fuzzy signal processing support. In *2011 7th International Conference on Electrical and Electronics Engineering (ELECO)* (pp. I-162). IEEE.
- Reddy, M. J., & Mohanta, D. K. (2007). A wavelet-neuro-fuzzy combined approach for digital relaying of transmission line faults. *Electric Power Components and Systems*, 35(12), 1385-1407.
- Rockefeller, G. D. (1969). Fault protection with a digital computer. *IEEE Transactions on Power Apparatus and Systems*, (4), 438-464.
- Sahu, S. K., & Yadav, A. (2018, June). Fuzzy logic based protective relaying scheme for IEEE-39 bus transmission system. In *2018 2nd International Conference on Power, Energy and Environment: Towards Smart Technology (ICEPE)* (pp. 1-6). IEEE.
- Samantaray, S. R. (2013). A systematic fuzzy rule based approach for fault classification in transmission lines. *Applied soft computing*, 13(2), 928-938.
- Sa'ad Ahmed, S., Ismaeel, I., & Karam, K. M. (2020). Fault detection and location of power transmission lines using intelligent distance relay. *International Journal of Power Electronics and Drive Systems*, 11(2), 726.
- Şen, Z. (2001). Bulanık (fuzzy) mantık ve modelleme ilkeleri. *Bilge Kültür Sanat Yayınları, İstanbul*.
- Solak, K., Rebizant, W., & Klimek, A. (2012). Fuzzy adaptive transmission-line differential relay immune to CT saturation. *IEEE transactions on power delivery*, 27(2), 766-772.
- The MathWorks Inc. (2022). MATLAB version: (R2024b), Natick, Massachusetts: The MathWorks Inc. <https://www.mathworks.com>

- Touati, K. O. M., Boudiaf, M., Mazouz, L., & Cherroun, L. (2024). Efficient hybrid strategy based on FFT and fuzzy logic techniques applied to fault diagnosis in power transmission line. *Soft Computing*, 28(15), 8911-8930.
- Verma, M., Koley, E., & Ghosh, S. (2017, December). Application of fuzzy logic for fault detection and classification in six phase transmission line. In 2017 IEEE international conference on computational intelligence and computing research (ICCIC) (pp. 1-5). IEEE.
- Yadav, A., & Swetapadma, A. (2015). Enhancing the performance of transmission line directional relaying, fault classification and fault location schemes using fuzzy inference system. *IET Generation, Transmission & Distribution*, 9(6), 580-591.
- Wang, H., & Keerthipala, W. W. L. (1998). Fuzzy-neuro approach to fault classification for transmission line protection. *IEEE Transactions on Power Delivery*, 13(4), 1093-1104.
- www.GEMultilin.com, (2024) "Transmission Line Principles", GE Vernova
- Youssef, O. A. (2004a, October). Applications of fuzzy inference mechanisms to power system relaying. In *IEEE PES Power Systems Conference and Exposition, 2004*. (pp. 560-567). IEEE.
- Youssef, O. A. (2004b). Combined fuzzy-logic wavelet-based fault classification technique for power system relaying. *IEEE transactions on power delivery*, 19(2), 582-589.
- Youssef, O. A. (2004c). A novel fuzzy-logic-based phase selection technique for power system relaying. *Electric Power Systems Research*, 68(3), 175-184.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*.


BÖLÜM 3

KALİTE KONTROL PROSESLERİNDE YAPAY ZEKA UYGULAMALARI

Yakup İRİM
Öğretim Görevlisi, Sinop Üniversitesi, yirim@sinop.edu.tr
ID 0000-0002-1267-7153

Salih DAĞLI
Dr. Öğretim Üyesi, Sinop Üniversitesi, sdagli@sinop.edu.tr
ID 0000-0003-3805-5130

Çoğu endüstrinin ana hedefi müşterilerine yüksek kaliteli ürünler sunmak olduğundan, ürün kalite kontrolü üretimde önemli bir rol oynamaktadır. Üretim süreçleri tamamlanmış ve nihai ürün kontrolünde hatalı olduğu tespit edilen ürünler müşteri satışına sunulamaz ve üreticiyi firmanın maddi kayba uğramasına sebebiyet vermektedir. Üretim esnasında oluşacak deformasyonlara ait belirtilerin üretim hatlarında ortaya çıkar çıkmaz tespit edilmesi, önemli kayıpların önlenmesinde çok büyük bir önem arz etmektedir (Sini vd. 2020). Bu yüzden imalat sanayinde ürün kalite kontrolü, şirketlerin başarısının ve mali kazançlarının sürdürülebilirliği kısmında en önemli etkenlerden birisi olarak kabul edilmektedir. Teknolojinin gelişmesi ve endüstride üretim süreçlerinin iyileşmesine katkı sağlaması, deformasyona sahip ürünlerin erken teşhis edilmesi ve kalite kontrolünün insan gücünden daha hızlı ve yaklaşık güvenilirlik altında gerçekleştirilmesine olanak sağlamaktadır (Kim, Lin, ve Tseng 2018). Endüstride üretim yapılan ürünler farklılık gösterdiğinden ve deformasyonları çeşitli şekillerde ortaya çıkabildiğinden, farklı kalite kontrol yöntemleri uygulanmaktadır. Kalite kontrol sistemleri tasarlanırken ürünün üretim süreçlerinde karşılaşılabilecek olgulara özgün olarak tasarlanması gerekmektedir (Prezas vd. 2022). Kalite yönetim sistemine ait alt başlıklar ve alt başlıkların sağlamış oldukları avantajlar Şekil 1’de gösterilmiştir.



Şekil 1: Kalite yönetim sisteminin kapsadığı endüstriyel süreç başlıkları

Kalite kontrol süreçleri ham madde formundan müşteri memnuniyetine kadar olan sürecin her aşamasında yer almaktadır. Ürünlerin müşteri taleplerini yerine getirdiğinden ve ürünün planlanan işlevselliğe sahip olduğundan emin olmak için farklı kalite kontrol süreçlerinde çeşitli testler gerçekleştirilmektedir. Faaliyetleri tamamen otomatik, tamamen manuel veya her ikisinin kombinasyonu olarak tasarımlar gerçekleştirilmektedir.

Kalite kontrol teknikleri, üretim sürecinde oluşabilecek kusurların etkin bir şekilde tespit edilmesi, mümkünse düzeltilmesi ve kusurların daha da minimize edilmesinde hayati bir rol oynamaktadır. Ancak düzeltme mekanizmasını uygulamadan önce kusurları önlemek esas amaç olmalıdır. Bu nedenle, kusurlarla daha etkin bir şekilde başa çıkabilmek için iyi tanımlanmış bir Kalite Yönetimi Süreci tasarıma ihtiyaç duyulmaktadır. Bu süreç kusur önleme, kusur tespit etme ve kusur giderme süreçlerini içermektedir. Hataların zaman ve maliyet üzerindeki etkisinden şirketlerin kaçınması için hataların ilk aşamalarda yazılıma entegre edilmesi ile engellenebilmektedir. Hatalı ürünlerin üretim süreçlerinde devam etmesi ve bunun geç fark edilmesi halinde hatayı düzeltmek için ihtiyaç duyulan zaman ve maliyet artmaktadır (Pacana ve Ulewicz 2020).

Kalite kontrol, ürünlerin veya hizmetlerin kalite standartlarına uygunluğunu sağlamak amacıyla belirli yöntemler kullanarak denetlenen ve sürekli geliştirilen bir süreç olarak tanımlanmaktadır. Müşteri memnuniyetini artırmak, verimliliği sağlamak ve

üretim süreçlerindeki hataları minimize etmek için oldukça önemli bir süreçtir (Chen vd. 2023). Günümüzde kalite kontrol süreçlerinde yapay zeka ve otomasyon sistemlerinin kullanımı hızla artmaktadır. Bu süreç, tasarımcı tarafından ürüne uygulanan işlemlere bağlı olarak belirlenen aşamalar doğrultusunda yürütülmektedir.

Kalite kontrol sistemlerinin genel olarak yerine getirmesi gereken **temel işlevleri** şu şekilde sıralanabilir;

1. *Planlama ve Standart Belirleme:* Kalite kontrol sürecinde, belirlenen kalite standartlarının tanımlanmasının gerektiği aşamadır. Bu standartlar ulusal ve uluslararası kalite normlarını içermektedir ve ürünlerin müşteri beklentilerini karşılayabilmesi için gerekliliklerini göstermektedir (Chisty ve Adusumalli 2022).
2. *Ölçme ve Veri Toplama:* Üretim süreçlerinden elde edilen veriler toplanıp ve analiz edilmektedir. Bu aşama, üretim esnasındaki kalite sapmalarının (hataların) erken tespiti için önemlidir ve ölçüm cihazları ile otomasyon sistemleri desteklenmektedir (Castaño vd. 2020).
3. *Analiz ve Değerlendirme:* Toplanan veriler, kalite standartları ile karşılaştırılmaktadır. Bu aşamada ileri veri analiz yöntemleri kullanılarak kalite sapmalarının kaynakları tespit edilmektedir (Tambare vd. 2021).
4. *Düzeltilici Faaliyetler ve İyileştirme:* Kalite problemleri tespit edildikten sonra düzeltici faaliyetler uygulanmaktadır. Kalite süreçlerinde sürdürülebilir iyileştirme sağlanmasına olanak tanımaktadır. Düzeltici faaliyetler ve iyileştirme aşamasında ürünün üretim süreçlerine bağlı olarak göstermemesi gereken nitelikler ortadan kaldırılmaktadır.
5. *İzleme ve Geri Bildirim:* Kalite kontrol süreçleri, sürekli izlenerek geribildirimler doğrultusunda iyileştirilmektedir. Bu aşama, kalite kontrolün sürdürülebilirliğini sağlamak için önem arz etmektedir. Otomasyon sistemi tarafından üründe deformasyon tespit edildiği zaman ikaz vermesi ve ürünün sonraki işlem aşamasına geçmesine engel olunacak aşamadır. Otomasyon sistemine bağlı olarak bu aşamada deformasyonun sebebi de tanımlanabilmektedir.

Kalite kontrol sistemleri, üretim süreçlerinde kalitenin sağlanması ve sürdürülmesi için çeşitli **denetim ve izleme yöntemlerini** içermektedir. Bu sistemler,

gelişen endüstriyel ihtiyaçlara ve teknolojilere uyum sağlamak için farklı türlerde uygulanmaktadır:

1. *Statik Kalite Kontrol*: Ürün ya da süreç üzerinde kalite kontrolleri, üretim başlamadan önce tasarım ve planlama aşamasında yapılmaktadır. Statik kalite kontrol, kaliteyi baştan sağlama ve süreçleri optimize etmeyi amaçlamaktadır. Bu tür kontrol sistemler, ürün kalitesinin korunmasını sağlayan önemli ön adımlardan birisi olarak kabul edilmektedir.

2. *Dinamik Kalite Kontrol*: Üretim veya hizmet sunumu sırasında anlık olarak yapılan kontrolleri içermektedir. Süreç esnasında yapılan bu kontroller, hata tespitinin hızlıca yapılmasını ve düzeltici önlemlerin uygulanmasını sağlamaktadır. Kalite kontrolü kapsamında, yapay zeka ve makine öğrenimi ile donatılan sistemler sayesinde süreçler daha hızlı analiz edilmekte ve anında geri bildirim sağlanmaktadır (Fonseca, Amaral, ve Oliveira 2021).

3. *Son Ürün Kontrolü*: Üretim süreci tamamlandıktan sonra ürünün nihai kontrolünün gerçekleştirildiği kalite kontrol yöntemidir. Kalite yönetim sistemlerinde, ürünlerin belirlenen kalite standartlarını karşılayıp karşılamadığı bu aşamada doğrulanmaktadır. (J. Minglana, R. R. Tobias, ve R. E. Roxas 2021).

4. *Gerçek Zamanlı Serbest Bırakma Testleri (RTRT)*: Bu gelişmiş kalite kontrol yöntemi, ürünlerin üretim sürecinde izlenmesi ve gerekli kalite gereksinimlerini gerçek zamanlı karşılayıp karşılamadığını belirlemektedir. RTRT, endüstrilerde yapay zeka ve süreç analizleriyle desteklenip süreçleri optimize etmektedir (Hinckley 1997).

Kalite kontrol sistemlerinin bu çeşitliliği, kalite yönetimini daha kapsamlı ve etkili hale getiren endüstri 4.0 ve dijitalleşme ile artmıştır. Özellikle gerçek zamanlı ve süreç içi kalite kontrol türleri, hız ve doğruluğu artırarak operasyonel verimliliği sağlamaktadır. Bu tür gelişmeler, kalite yönetim süreçlerini daha öngörülebilir ve müşteri odaklı bir yaklaşıma dönüştürmektedir.

Kalite kontrol **yöntemleri ve araçları**, üretim süreçlerinde kaliteyi güvence altına almak amacıyla kullanılan çeşitli teknikleri kapsamaktadır. Bu yöntemler, özellikle Endüstri 4.0 ile gelişerek "Kalite 4.0" konseptiyle daha dijital ve otomatik hale gelmiştir.

1. *İstatistiksel Proses Kontrol (SPC)*: Üretim süreçlerinin kalite düzeylerini izlemek ve iyileştirmek için istatistiksel araçları kullanmaktadır. SPC'nin temel amacı, süreci sürekli izleyerek üretimdeki varyasyonları en aza indirmek ve ürün kalitesini garanti altına almaktır. Bu sistem, genellikle kontrol grafiklerini kullanır; grafiklerde belirli bir ölçüm sürekli olarak gözlemlenir ve sürecin "kontrol altında" olup olmadığına karar verilmektedir. *SPC'nin ana bileşenleri; kontrol grafikleri, pareto analizi ve neden-sonuç diyagramlarından oluşmaktadır.* Üretim sürecinde meydana gelen hataların hızlıca tespit edilerek düzeltici işlemler yapılmasına olanak sağlamaktadır (Sanchez-Marquez ve Jabaloyes Vivas 2020).

2. *Toplam Kalite Yönetimi (TQM)*: Kaliteyi tüm işletme süreçlerine entegre ederek müşteri memnuniyetini sağlamaya odaklanan bir yönetim anlayışıdır. TQM, organizasyon genelinde sürekli iyileştirme ve tüm çalışanların kalite süreçlerine katılımını teşvik etmektedir. Bu yaklaşım, müşteri ihtiyaçlarının belirlenmesi, süreçlerin optimize edilmesi ve çalışanların yetkinliklerinin artırılması gibi ilkelere dayanmaktadır. Organizasyon yapı olarak müşteri odaklılık, sürekli iyileştirme, çalışan katılımı, veriye dayalı karar verme ve süreç odaklılığı gibi temel ilkeleri benimsemektedir (Nainggolan ve Rezeki 2024).

3. *Six Sigma*: Kalite kontrol süreçlerinde hataları minimize etmek için kullanılan, istatistiksel ve metodolojik bir yönetim sistemidir. Başlangıçta Motorola tarafından geliştirilen bu yöntem, süreçlerdeki sapmaları ölçmek ve azaltmak amacıyla her milyonda yalnızca 3, 4 hata hedefiyle çalışmaktadır. *Six sigma yönetimi, belirle, ölç, analiz et, iyileştir ve kontrol et prensipleri ile çalışmaktadır* (Sordan vd. 2020).

4. *Hata Türü ve Etkileri Analizi (FMEA)*: Bir sistem veya süreçte oluşabilecek olası hataları tanımlamak, bu hataların olası etkilerini analiz etmek ve riskleri azaltmak amacıyla kullanılan bir yöntemdir. 1960'larda otomotiv ve havacılık sektörlerinde güvenliği artırmak amacıyla geliştirilmiştir. Günümüzde ise çeşitli sektörlerde kaliteyi güvence altına almak için geniş bir uygulama alanı bulunmaktadır. FMEA, hata türlerini belirleme, etki analizi, risk öncelik sayısı hesaplama ve önleyici eylemler aşamalarından oluşan bir uygulama akışı bulunmaktadır (Lo vd. 2020).


Son yıllarda, özellikle yapay zeka ve makine öğrenimi gibi teknolojilerin kalite kontrol araçlarına entegre edilmesi, süreçlerin daha öngörülebilir ve verimli hale gelmesini sağlamıştır. Bu teknolojiler, örneğin otomatik veri analizleri ile kalite sorunlarını gerçek zamanlı tespit edebilmekte, ürün kalitesini anlık olarak izleyebilmektedir. Yapay zeka, özellikle büyük veri analizinde hızlı ve doğru sonuçlar sağlayarak kalite kontrol süreçlerine önemli bir katkı sunmaktadır. Görüntü işleme algoritmaları, makine öğrenimi, robotik sistemler ve prediktif analizler, kaliteyi ölçme ve denetleme sürecinde insan hatalarını azaltırken olası kalite deformasyonlarının önüne geçilmesini mümkün kılmaktadır. Kalite kontrol sistemleri ve yöntemleri, toplam kalite yönetiminden süreç analizlerine kadar çeşitli tekniklerle müşteri memnuniyetini artırmayı ve ürünlerin daha güvenilir olmasını sağlamayı hedeflemektedir.

YAPAY ZEKA MODELLERİ

Yapay zeka (YZ), bilgisayar bilimi ve fizyolojinin bir entegrasyonudur. Zeka, ezberleme ve anlama, kalıpları tanıma, değişime uyum sağlayan seçimler yapma ve deneyimlerden öğrenme yaratmayı hayal etmek için düşünme yeteneğidir. Yapay zeka, bilgisayarların insanlar gibi ve bir insandan çok daha kısa sürede olguların ortaya konulmasını sağlamakla ilgilenmektedir (Poole, Goebel, ve Mackworth 1998). Yapay zeka algoritmalarının temelini oluşturan yapay sinir ağları insan beynini ve nöronlarla sinaps bağlantıları taklit edilerek elde edilen bir yöntemdir. YSA'da girdi, gizli ve çıkış katmanındaki nöronlar algoritmanın yapıtaşlarıdır.

Yapay zeka insan zekâsını taklit ederek ortaya çıkmış, insan hayatını kolaylaştıran ve geliştiren teknolojiler geliştirmeyi amaçlayan geniş bir teknik ve yaklaşım yelpazesini kapsayan bir alandır (L. Chen, Chen, ve Lin 2020). İlk başlarda YZ programları çoğunlukla “uzman sistemler” olarak tanımlanmışlardır. Bu programların amaçları, belirli bir görev için uzman insanın kararlarını taklit ederek ilgili görevlerini gerçekleştirmektir. YZ programı tarafından gerçekleştirilmesi istenilen eylemler akış diyagramına göre sırasıyla bilgisayara bir dizi kural olarak tanıtılmaktadır. Programın temel olarak, hedeflenen eylemin bir insan tarafından gerçekleştirilmesi ile elde edilecek çıktıyı üretecek şekilde çalışması amaçlanmaktadır. YZ tabanlı programların çıktılarının hedeflenen çıktılar ile arasında değerlendirme yapılarak programın performans ölçütü hesaplanmaktadır. Bu temel YZ programları gelişen bilgisayar teknolojisi ile yerini çözümleri programlayıcıya

gerek kalmadan üretebilen evrimsel algoritmalar gibi sezgisel yöntemlere dayalı yaklaşımlar geliştirilmiştir. Bu sistemlerin tek bir eylem algoritması ya da tek yöntemle eğitilmesine gerek kalmadan birkaç farklı yöntemden oluşabilmektedir. Yapay zeka, makine öğrenmesi (ML) ve derin öğrenme (DL) arasındaki ilişki Şekil 2’de gösterilmiştir.




Şekil 2: Yapay zeka, makine öğrenmesi ve derin öğrenmenin birbirleri arasındaki ilişki

Makine Öğrenmesi Modelleri

Makine öğrenimi, girdi verilerinden çıktı verilerine ulaşılabilmesi için algoritma akışını tanımlamayı gerçekleştirebilen, ilgili görevlerin çözümlenmesi için kararlar verebilen bir dizi algoritma ve model olarak tanımlanmaktadır (Luan ve Tsai 2021). Makine öğrenimine dayalı yazılım, görevle ilgili veri kümelerinin hazırlanması, uygun bir makine öğrenimi yaklaşımının seçilmesi ve makine öğrenimi modelinin görevi tamamlamak üzere eğitilmesi yoluyla geliştirilmektedir. Makine öğrenimi genel olarak üç ana öğrenme algoritması altında sınıflandırılabilir: denetimli öğrenme (supervised), denetimsiz öğrenme (unsupervised) ve pekiştirmeli öğrenme (reinforcement) (Saravanan ve Sujatha 2018). Makine öğreniminde kullanılan öğrenme algoritmaları Şekil 3’te gösterilmiştir. Makine öğrenimi algoritmaları spesifik bir öğrenme görevi için yukarıda tanımlanan öğrenme algoritmalarından bir veya birkaçını bir arada kullanabilirler. Birçok farklı görevi yerine getirmek için tasarlanan uygulamaların geliştirilmesi için genellikle öğrenme algoritmalarının birkaçı kombine edilerek modeller

geliştirilmektedir. ML yaklaşımlarını ve tekniklerini kategorize etmek için tek bir standart yaklaşım bulunmamaktadır farklı özniteliklere bağlı olarak kategorizasyon da mümkündür.



Şekil 3: Makine öğrenimi yaklaşımları ve kullanım amaçları

Denetimli Öğrenme: Denetimli öğrenmede, girdi kümesi (özellikler) ve bunlara karşılık gelen etiketlere (etiketli veri kümesi) sahip veriler kullanılarak eğitim gerçekleştirilmektedir. Model tasarımı gerçekleştirildikten sonra eğitim aşamasında algoritma, giriş verilerinin ilgili etiket değeri ile eşleştirme yapabilmesi için doğru şekilde tahmin işlemi yapmayı öğrenmektedir. Eğitim aşaması tamamlanmış modele etiket değeri bilinmeyen giriş verileri için etiket değeri tahmin ederek sınıflandırma işlemi gerçekleştirilmektedir. Denetimli öğrenme özellikle görüntü, ses ve nesne tanıma gibi etiketli veri kümelerinin kolayca elde edilebildiği uygulamalar için kullanışlıdır (Sen, Hajra, ve Ghosh 2020).

Denetimsiz Öğrenme: Denetimsiz öğrenmede, makine öğrenimi modeli yalnızca ilgili etiketler olmadan giriş özellikleri kullanılarak eğitilmektedir. Denetimsiz öğrenmede eğitimin amacı giriş özelliklerinin boyutluluğunu azaltmak, benzer veri noktalarını kümelemek (k-ortalamalar kümeleme) ve eğitim veri kümesini taklit etmektir. Eğitim sırasında, denetimsiz öğrenme için makine öğrenimi modelleri, gözle fark edilemeyen farklılıkları (anormallik) veya farklı bilgileri tespit edebilmektedir (Khanum vd. 2015).

Pekiştirmeli Öğrenme: Pekiştirmeli öğrenme, bir yapay zeka modelinin, belirli bir ortamda deneme-yanılma yoluyla öğrenerek en iyi hareket stratejisini geliştirmesini

sağlayan bir makine öğrenimi dalı olarak tanımlanmaktadır. Bu yöntemde model, bir hedefe ulaşmak için adımlar atar ve her adımda aldığı ödül veya cezalarla doğru davranışı öğrenmektedir. Pekiştirmeli öğrenmede, ajan olarak adlandırılan yapay zeka modeli, aldığı kararlar sonucunda ortamdan sürekli bir geri bildirim almaktadır. Bu geri bildirim, modelin hangi kararların başarıya veya başarısızlığa götürdüğünü anlamasına yardımcı olur ve bu sayede gelecekteki seçimlerini iyileştirmektedir. Ajanlar ortamı keşfetmek için harekete geçer ve her eylemden sonra yeni bir duruma geçmektedir. Her durum için, ajan, eyleminin verilen durum için arzu edilip edilmediğine bağlı olarak pozitif veya negatif bir değer almaktadır. Bu süreç tekrarlandıkça, ajan yavaş yavaş olumlu eylemleri aramayı ve olumsuz olanlardan kaçınmayı öğrenir ve sonucunda hedefine giden en uygun yolu belirlemektedir (AlMahamid ve Grolinger 2021). Pekiştirmeli öğrenme belirli bir problemi çözmek için doğru cevapların veya hedeflerin varlığına gerek kalmadan, yalnızca ajandan gelen bir cevabın doğru yönde olup olmadığına dair bilgiye ihtiyaç duymaktadır. Pekiştirmeli öğrenme, optimizasyon uygulamalarının yanı sıra robotik uygulamalarında da faydalı kullanımları bulunmaktadır (Singh, Kumar, ve Singh 2022). Makine öğrenimi için bazı öğrenme algoritmaları, öğrenme modelleri, görevleri ve üretim endüstrisindeki kullanım amaçları Şekil 4’te gösterilmiştir.

ÖĞRENME YAKLAŞIMLARI	ÖĞRENME MODELLERİ	ÖĞRENME GÖREVLERİ	ENDÜSTRİYEL UYGULAMALAR
DENETİMLİ ÖĞRENME	SINIFLANDIRMA ALGORİTMALARI	KONTROL SİSTEMLERİ	BAKIM TAHMİNİ
	SİNİR AĞLARI	BİLGİSAYARLI GÖRME	ENERJİ TÜKETİM DÜZENLEMESİ
	DESTEK VEKTÖR MAKİNELERİ	SINIFLANDIRMA	KALİTE KONTROL
DENETİMSİZ ÖĞRENME	KARA AĞAÇLARI	REGRESYON	SİBERGÜVENLİK
	KODLAYICILAR	HATA TESPİTİ	SÜREÇ OPTİMİZASYONU
PEKİŞTİRMELİ ÖĞRENME	DÖNÜŞTÜRÜCÜLER	DOĞAL DİL İŞLEME	ENDÜSTRİYEL OTOMASYON

Şekil 4: Makine öğrenimi genel kategorileri, kullandıkları yöntemler, görevler ve üretim endüstrisindeki uygulamaları

Makine Öğrenim Algoritmaları ve Endüstride Kullanım Alanları

Destek vektör makinesi (DVM): DVM, sınıflandırma ve regresyon görevleri için yaygın olarak kullanılan bir makine öğrenimi algoritmasıdır. DVM, sınıflandırma işlemi için destek vektörleri ile tanımlanan sınıfların ayrıştırılmasını sağlayan hiper düzlemler tanımlamaktadır. Regresyon işlemi sırasında girdi verilerinden oluşan evrensel küme içerisinde noktaları en kısa mesafede eşleştiren bir amaç fonksiyonu tanımlanmaktadır (Pisner ve Schnyer 2020). DVM, (Silva, Sousa, ve Alenya 2021) plastik enjeksiyonda parça kalitesinin tahmin edilmesi, (T. Liu, Huang, ve Chen 2019) lazer katkılı üretimde kusurların belirlenmesi, (Lee vd. 2019) frezeleme işlemleri sırasında takım aşınmasının önceden tahmin edilmesi, (Huang vd. 2015) makine bileşenlerinin kalan kullanılabilir ömürlerinin (RUL) tahmin edilmesi gibi çeşitli çalışmalarda kullanılmıştır.

K-en yakın komşular (KNN): KNN, denetimli öğrenme yöntemlerinden biri olup hem sınıflandırma hem de regresyon problemlerinde kullanılan, basit fakat etkili bir makine öğrenmesi algoritmasıdır. KNN algoritması, bir veri noktasını sınıflandırma işlemi için o noktanın en yakın K adet komşusuna bakarak karar vermektedir. Regresyon işlemi için, K adet en yakın veri noktası değerlerinin ortalamasına dayanarak çıktı katmanında değer tahmini gerçekleştirmektedir (Uddin vd. 2022). (Yıldız, Buldu, ve Demetgul 2016) çalışmalarında, KNN algoritması kullanılarak üretim aşamasında kumaşların termal görüntüleri üzerinden yapılan analiz sonucunda kumaşlarda hata tespiti yapılabileceğini ortaya koymuşlardır. Katmanlı üretim kalite kontrolü bağlamında KNN, (Khanzadeh vd. 2018)'da sunulduğu gibi etkili gözeneklilik tahmini göstermiştir. (Ouadah, Zemmouchi-Ghomari, ve Salhi 2022) çalışmalarında, kestirimci bakım analizi için farklı algoritmalarının kullanımları üzerine araştırma gerçekleştirmişlerdir ve çalışmalarında ilgili görev için KNN algoritmasının kabul edilebilir etkinliği ortaya konulmuştur.

Naive Bayes: Naive Bayes, olasılık teorisine dayalı, genellikle sınıflandırma problemlerinde kullanılan basit ama güçlü bir makine öğrenmesi algoritmasıdır. Bu algoritma, adını Bayes teoreminden ve özellikler arasındaki bağımsızlık varsayımından almaktadır. Naive Bayes, özellikle metin sınıflandırma ve tavsiye sistemlerinde yaygın olarak kullanılmaktadır. Sınıflara ait veri kümelerinden oluşan evrensel küme içerisinde her noktanın tüm olasılık parametreleri hesaplanır ve olasılık değeri en yüksek olan sınıf veri noktasının etiketi olarak tahmin edilmektedir. Naive Bayes regresyon görevleri için de kullanılabilir (H. Chen vd. 2021). Naive Bayes algoritması, parçacık sürüsü optimizasyonu (PSO) (Shami vd. 2022) ile birlikte (Romli vd. 2021) ürün kusurlarını etkili bir şekilde tespit etmek için kullanılmıştır. (Zhang vd. 2018) çalışmalarında, Naive Bayes algoritması kullanılarak üretim esnasından oluşan titreşim sinyalleri analiz edilerek rulman hatalarının etkili şekilde tespit edildiğini ortaya koymuşlardır.

Regresyon (doğrusal ve lojistik): Doğrusal regresyon evrensel kümede yer alan verilerin düz bir çizgi kullanılarak giriş verileri ile hedef çıktılar arasında doğrusal olarak bir bağlantı sağlayan makine öğrenimi algoritmasıdır (Maulud ve Abdulazeez 2020). Evrensel kümedeki verilerin doğrusal bağlantı için tasarlanan düz çizgilerle ilişkileri değerlendirilerek algoritmanın başarı kriteri belirlenmektedir. Lojistik regresyon ise, 0 ile 1 arasında değerler üreten lojistik bir fonksiyon kullanarak bir sınıfa ait olma olasılığını hesaplayarak sınıflandırma için kullanılmaktadır (Sufriyana vd. 2020). (Jin, Li, ve Shi

2007)'da, haddeleme sürecinde ürün kalitesini tahmin etmek için bir lojistik regresyon modeli önerilmiştir. (Akhir ve Ayuni 2021) çalışmalarında doğrusal regresyon algoritmasını kullanarak türbin jeneratörlerinde makine arızası tahminindeki etkinliği ortaya konulmuştur. (Zhao, Tang, ve Tan 2016) titreşim verilerine dayalı olarak rulmanların RUL süresini tahmin etmek için çoklu doğrusal regresyon (MLR) (Uyanık ve Güler 2013) kullanılmıştır.


Karar ağaçları: Karar ağaçları hem sınıflandırma hem de regresyon görevleri için kullanılan bir makine öğrenme modelidir. Her bir iç düğümün bir özelliği ve her bir yaprak düğümünün bir sınıfı veya tahmin edilen bir değeri temsil ettiği bir ağaç şeklinde bir yapı oluşturmaktadır. Algoritmada evrensel kümede yer alan veriler, eğitim öncesinde sınır olarak belirlenen iterasyon, hata değeri veya sapma değeri gibi parametrelere göre her düğüm noktasında en iyi ayrıştırma eylemini gerçekleştiren özelliğe bağlı olarak bölütlenmektedir (Kaparthi ve Bumblauskas 2020). (Ogorodnyk vd. 2019) çalışmalarında, kara ağaçları kullanılarak enjeksiyon kalıplama üretiminde üretilen parçaların kalite parametrelerinin tahmin edilebileceğini ortaya koymuşlardır. (Gerdes, Galar, ve Scholz 2017)'te sunulan çalışmada, bir uçak klima sisteminin RUL süresini tahmin etmek için bir genetik algoritma ile birlikte karar ağaçları kullanılmıştır.

Topluluk yaklaşımı: Topluluk yaklaşımları, istenilen çıktı değerinin elde edilmesi için birden çok ve farklı model çıktılarını birleştirerek nihai çıktı üreten bir makine öğrenimi yöntemidir. Tahminler genellikle sınıflandırma görevleri için oylama ve sayısal değer tahmini için ortalama kullanılarak birleştirilmektedir (Talukder vd. 2022). Topluluk yaklaşımları arasında, XGBoost (Jeong 2022), rastgele orman (Liu vd. 2021) ve gradyan artırma makineleri (Kiangala ve Wang 2021) gibi farklı topluluk yöntemleri bulunmaktadır. XGBoost, (Obregon, Hong, ve Jung 2021)'da üretim hatalarını başarılı bir şekilde tahmin etmektedir. Kestirimci bakımda, (Ayvaz ve Alpay 2021)'de makinelerin RUL süresini tahmin etmek için rastgele orman modelleri kullanılmıştır.

Derin Öğrenme Modelleri

Derin öğrenme, birbirine bağlı birden fazla nöron katmanına sahip yapay sinir ağlarını kullanan gelişmiş bir yaklaşımdır. Özellikle büyük miktarda veriyi işlemek için etkilidir ve hem işlenmiş hem de işlenmemiş verileri kullanabilmektedir. Her biri belirli

veri türlerine uyarlanmış farklı sinir ağları mimarileri önerilmiştir. Derin öğrenme modellerinin öğrenme yaklaşımlarına göre sınıflandırılması Şekil 5'te gösterilmiştir.



Şekil 5: Derin öğrenme modellerinin öğrenme yaklaşımlarına göre sınıflandırılmaları

Çok katmanlı algılayıcı (MLP): MLP modelleri en yaygın olarak kullanılan derin öğrenme modelleridir. MLP, sırasıyla girdi katmanı, gizli katman ve çıktı katmanı olmak üzere birden fazla nöron katmanının birbirini takip etmesinden oluşmaktadır. Girdi katmanı bilgilere herhangi bir işlem uygulamadan direkt olarak bilgiyi gizli katman nöronlarına iletmektedir. Gizli katman nöronları girdi katmandaki her nörondan gelen bilgi ile ilgili yolun katsayısının çarpımından değer almaktadır. Gizli katmandaki nöronlar gelen bilgilerin toplamını bir aktivasyon fonksiyonundan geçirerek nöronlara ait çıktılar elde edilmektedir. Çıktı katmanı gizli katman aynı işlemi yapar ve aktivasyon işlemi sonucunda tasarıma bağlı olarak ya sınıflandırma için etiket değeri hesaplar ya da regresyon işlemi için bir değer üretmektedir (Liao ve Chen 1998). (J. C. Chen, Guo, ve Wang 2020) çalışmalarında MLP algoritmasını enjeksiyon kalıplama işlemi için çevrimiçi bir kusur tespit sistemine uygulanmıştır. (Kang, Catal, ve Tekinerdogan 2021)'de MLP, uçak turbofan motorlarının RUL süresini tahmin etmek için kullanılmıştır. (Cardoso ve Ferreira

2020) çalışmalarında, MLP modelinin makine bileşeni arızalarını tahmin etme işleminde yeteneğini araştırmış ve çalışma sonucunda elde edilen sonuçların umut vaat edici olduğunu ortaya koymuşlardır.

Evrişimsel sinir ağı (CNN): Evrişimsel sinir ağları (CNN'ler), görüntü sınıflandırma, nesne algılama ve görüntü segmentasyonu gibi görüntü işleme alanlarında sıkça tercih edilen bir derin öğrenme yöntemidir. Bu ağların temel yapı taşını oluşturan konvolüsyonel katman, giriş görüntülerindeki desenleri algılamak için filtreler kullanır. CNN'ler, özellik çıkarma sürecini manuel olarak gerçekleştirmeye gerek kalmadan, bu özellikleri otomatik olarak öğrenme yeteneğine sahiptir (Chien, Hung, ve Liao 2022). Literatürde, bir görev üzerinde önceden eğitilmiş bir CNN modelinin alınması ve yeni, benzer bir göreve uyarlanmasını içeren transfer öğrenmenin kullanılması yaygındır. Birçok ön eğitilmiş model mimarisi açık kaynaklı olarak literatüre sunulmuştur (Krause, Politis, ve Kowalczyk 2021). (Wang vd. 2018) çalışmalarında arka plan-doku tabanlı kusur tespiti için bir CNN modeli kullanımı önermişlerdir ve çalışma sonucundan CNN modelinin başarılı bir performans gösterdiğini ortaya koymuşlardır. Modifiye edilmiş You Only Look Once (YOLO) yaklaşımı (Shafiee vd. 2017) tam evrişimli bir modele dönüştürülmüş ve çelik şeritlerde gerçek zamanlı yüzey hatası tespiti için kullanılmıştır.

Tekrarlayan sinir ağı (RNN): RNN, ardışık verileri işlemek ve analiz etmek için tasarlanmış bir yapay sinir ağı türüdür. RNN'ler, özellikle zaman serisi analizi, metin işleme, konuşma tanıma ve dil modeli gibi sıralı bilgi gerektiren görevlerde kullanılmaktadır. Bu ağlar, sıradan yapay sinir ağlarından farklı olarak önceki adımların bilgilerini hatırlayabilme yeteneğine sahiptir, bu da onları sıralı veri ile çalışma açısından oldukça güçlü kılmaktadır (Abdelhameed ve Tolbah 2002). Vanilya RNN (Yi, Kim, ve Bu 2024), uzun kısa süreli bellek (LSTM) ağları ve kapılı tekrarlayan birimler (GRU'lar) dahil olmak üzere farklı RNN mimarileri bulunmaktadır (Katte 2018). (Wu vd. 2018) çalışmalarında, temel bir LSTM modeli kullanarak uçak motorlarının RUL süresini tahmin etmek için bir yaklaşım önermiştir.

Otomatik kodlayıcı: Otomatik kodlayıcılar, kodlayıcı ve kod çözücü olmak üzere iki temel yapıdan oluşturulan bir derin öğrenme modelidir. Kodlayıcının görevi girdi verisini daha az alan kaplayacak kodlama değerlerini üretmektir. Kod çözücü, gelen temsili kodlamayı kullanarak düşük boyutlu veriyi gerçek veriye yeniden dönüştürmektir. Otomatik kodlayıcıların temel amaçları bu dönüşüm sonucunda elde edilen veri ile orijinal

veri arasındaki farklılığın en düşük seviyelerde sağlanmasıdır (Alfeo vd. 2020). (Jung vd. 2021)'de enjeksiyon kalıplama sürecinde kalite tahmini için otoenkoder tabanlı bir model kullanılmıştır.

Dönüştürücü: Dönüştürücüler başlangıçta dil çevirisi ve metin özetleme gibi doğal dil işleme görevleri için oluşturulmuştur. Otomatik kodlayıcılara benzer şekilde, dönüştürücüler temel olarak iki bölümden oluşur: bir kodlayıcı ve bir kod çözücü. Kodlayıcı ve kod çözücü yapı olarak ileri beslemeli sinir ağlarından oluşmaktadır. Dönüştürücü, dikkat mekanizmasını kullanarak yalnızca giriş verilerinden çıkarılan ilgili bilgilere odaklanarak çıktılar üretmeyi öğrenecek şekilde tasarlanmıştır (Orabi vd. 2024). Dönüştürücüler, RNN'lerin sıralı işleme sınırlamalarının üstesinden gelerek verilerin paralel işlenmesini sağlamaktadır (Zaheer vd. 2020). (Wang vd. 2023) çalışmalarında yüzey kusurlarını tespit etmek için dönüştürücüleri kullanmıştır.

ENDÜSTRİ ALANLARINDA YAPAY ZEKA İLE KALİTE KONTROL UYGULAMALARI

Endüstri alanlarında yapay zeka ile kalite kontrol uygulamaları, üretim süreçlerinin hızlandırılması, doğruluğun artırılması ve maliyetlerin düşürülmesi gibi avantajlar sağlamaktadır. Yapay zeka uygulamaları, kalite kontrol için kullanıldığı temel endüstri alanları ve bu alanlardaki spesifik uygulamalar için tasarlanmaktadır. Otomotiv endüstrisinde yapay zeka destekli kusur tespiti ve performans takibi gerçekleştirilmektedir. Gıda sektöründe bilgisayarlı görme ve makine öğrenimi kullanılarak görsel kalite, tazelik kontrolü ve kimyasal analizler gerçekleştirilmektedir. Havacılık ve savunma sanayi de uçak ve savunma araçlarının malzemelerindeki yapısal çatlakların, deformasyonların ve yapısal zayıflıkların tespitinde derin öğrenme algoritmaları kullanılmaktadır. Farklı endüstri alanına bağlı olarak yapay zeka tabanlı birçok uygulama üretimin iyileşmesini ve üretilen malzemelerin kalite kontrolünü sağlayacak şekilde uygulamalara başvurulmaktadır. Bu bölümde bazı üretim alanındaki yapay zeka tabanlı olarak kalite kontrol uygulamalarına dair çalışmalar özetlenmiştir.

Gıda Endüstrisi

(García-Esteban vd. 2018), çalışmalarında gıda ürünlerinin kalite kontrolüne odaklanan, sürece dahil olan ana aktörler (kalite yöneticileri, profesyonel tadımcılar, üretim yöneticileri, denetim yetkilileri, vb.) arasında iş birliği ve veri alışverişine dayanan

bir sanallaştırma stratejisi ve bilgisayar modeli önermişlerdir. Çalışmada, girdi veri seti olarak üretilen gıda ürünlerine ait Yakın Kızılötesi Spektroskopi verileri kullanılarak araştırma yapılmıştır. Sanallaştırma yaklaşımlarını olgunlaşan peynir hazırlama işlemin üzerinde test edilmiştir. Gelişmiş görselleştirme teknikleri sayesinde kalite yöneticisi, bir ürünün duyu kalitesiyle ilgili değer ölçüsünü anında ve sistematik olarak öğrenebilmektedir. Önerilen uygulamanın, makine öğrenimi algoritmalarını belirli bir sürece göre sürekli olarak yeniden ayarlayabilecek ve rekabet gücünü artırmak için faydalı olacağını ortaya koymuştur.

(Palakurti 2022), gıda endüstrisi, müşterilerin güvenli ve kaliteli gıda beklentilerini karşılamakta hiç bitmeyen zorluklarla karşılaşır ve kalite standartlarının sağlanması için tespit, izleme ve yönetimde gıda güvenliği ve kalite kontrolündeki zorluklara çözümler sunan yapay zeka tabanlı yeni çözümler gerektirdiğini düşünmüşlerdir. Yapay zeka tabanlı uygulamalar sayesinde gıda ürünlerinin güvenliğini ve kalitesini geliştirebilir veriler toplanarak kullanılabilir. Yapay zekanın getirmiş olduğu bu avantajların yanı sıra üretim verimliliği de sağlayacağını düşünmüşlerdir. Çalışmada, gıda güvenliği ve kalite kontrolünde YZ'nin mevcut araştırma başarılarını, yöntemlerini ve uygulamalarını sistematik olarak özetlemişlerdir. Literatürdeki uygulamaları değerlendirdikleri zaman gıda güvenliği ve kalite kontrolü için YZ uygulaması alanlarındaki araştırmacılar ve uzmanlar için net ve ileriye dönük bir rota oluşturmaya yönelik katkı sağlayacağını ortaya koymuştur.

(Mavani vd. 2022), çalışmada, gelecekteki yapay zeka ve gıda endüstrisi ile ilgili gelişmeler için bir ön görüş belirtmişlerdir. Gıda sektöründe uygulanacak gelişmelerin en uygun yöntemlerin seçilmesi için bir kılavuz olarak avantajlarını, sınırlamalarını ve formülasyonlarını gözden geçirmişlerdir. Bu akıllı değerlendirme sistemlerinin elektronik burun, elektronik dil, bilgisayar görüş sistemi ve yakın kızılötesi spektroskopi (NIR) gibi diğer cihazlarla entegrasyonu da vurgulanmakta olup, bunların tümü hem sektör üreticilerine hem de tüketicilere fayda sağlayacağı ortaya konulmuştur.

(Chhetri 2024), gıda kalite yönetimi ve güvenlik değerlendirmesinde yapay zeka ve makine öğreniminin çeşitli kullanımlarını analiz ederek akademisyenler, iş adamları ve yasa koyucular için aydınlatıcı bilgileri araştıran bir inceleme çalışması yapmıştır. Yapay zeka ve makine öğreniminin güçlü yetenekleri, gıda kalite yönetimi ve güvenlik değerlendirmesinde prosedürlerde devrim yaratma potansiyeline sahip olmalarından

kaynaklı, bu teknolojilerin derinlemesine incelenmesi yoluyla gıda kalitesi yönetiminde yapay zeka ve makine öğreniminin sayısız kullanımı gösterilmiştir. Derin öğrenme teknikleri de örüntü tanıma ve anormallik tespiti için güvenilir yaklaşımlar sunmakta ve böylece üretim partileri arasında kalite tutarlılığını korumaktadır. Gıda güvenliği değerlendirmesi açısından tehlikeli mikroorganizmaların, alerjilerin ve kimyasal kirleticilerin tespit edilmesinde yapay zeka ve makine öğreniminin katkısı değerlendirilmiştir. Gerçekleştirilen inceleme sonucunda yapay zeka ve makine öğrenimi teknolojilerinin gıda kalite kontrolü ve güvenliğine entegrasyonunun yalnızca verimliliği artırmak, riskleri en aza indirmek ve mevzuata uygunluğu sağlamakla kalmayıp, aynı zamanda gıda endüstrisinde dönüştürücü bir paradigmaya işaret eden yeni bir kişiselleştirilmiş beslenme, otonom izleme ve küresel iş birliği çağının habercisi olduğunu ortaya koymaktadır.

Otomotiv Endüstrisi

(Chouchene vd. 2020), denetim süreci özellikle bitmiş ürünlerin kalitesini kontrol etmek için çok önemi göz önüne alınarak çalışmalarında, araçlardaki uygunsuzlukları (deformasyon) kontrol etmek için otomatik bir yapay zeka tabanlı görme sistemi önerilmişlerdir. Önerilen sistemin ana fikri, üretime dayalı hataları otomatik olarak tanımlamak ve aynı zamanda akıllı endüstri 4.0 kavramını desteklemek için yapay zekanın tabanlı bir yöntem geliştirilmesidir. Akıllı endüstrilerde kalite kontrol denetimi için yapay zekaya dayanan bazı çalışmalar, görsel denetim konularını vurgulamak ve yapay zekanın özellikle araç üretimi ile ilgili endüstrilerdeki etkinliğini ortaya koymuşlardır.

Kalite kontrol, otomotiv şirketleri için vazgeçilmez bir işlemdir. Çok sayıda referans üretilir ve birçok ilgi alanının kontrol edilmesi gerekmektedir. Görsel kontrol, her parçayı manuel olarak kontrol eden operatör tarafından gerçekleştirilmektedir. Günde birkaç kontrolden sonra operatör yorulur ve bu nedenle bir kaynak dikişini veya bir bileşen kontrolünü yanlış nitelendirebilir. Bu probleminin araştırılması amacıyla (El Hachem vd. 2021) çalışmasında bir sinir ağının nesnenin varlığını veya yokluğunu tespit etmede yüksek hassasiyete ulaşma yeteneğini göstermişlerdir. ResNet-50 ile %99'luk bir doğruluk oranına ulaşmayı başarmışlardır. Çalışma sonucunda, otomotiv endüstrisinde başka yenilikçi projelere yol açacak otomatik bir görsel denetim sunarak mevcut üretim durumuna yardımcı olacağı ortaya konulmuştur.

Ürün boyutsal değişkenliği, tespit edilmeyen kusurların kolayca aşağı yönde yayılabildiği karmaşık çok aşamalı üretim süreçlerinin kalite kontrolünde çok önemli bir faktör olarak otomotiv endüstrisinde önemli bir problem arz etmektedir. (Peres vd. 2019), çalışmasında gerçek bir otomotiv üretim şirketinde çok aşamalı montaj hattındaki boyutsal kusurları tahmin etmek için çeşitli makine öğrenimi sınıflandırıcıları eğitmiş ve çeşitli metrikler üzerinde değerlendirmede bulunmuşlardır. Hat, iki otomatik denetim aşaması ile bunların arasında insan tarafından işletilen birkaç montaj ve ön hizalama aşamasını kapsamaktadır. Sonuçlar, XGBoost ve Random Forests gibi doğrusal olmayan modellerin böyle bir ortamın karmaşıklığını modelleyebildiğini, yüksek bir doğru pozitif orana ulaştığını ve mevcut kalite kontrol yaklaşımlarının iyileştirilmesi için umut vaat ettiğini, kusurların ve sapmaların daha erken ele alınmasını sağladığını ve böylece hurda ve onarım maliyetlerinin azaltılmasına yardımcı olduğunu ortaya koymuştur.

(Msakni, Risan, ve Schütz 2023), çalışmalarında otomotiv endüstrisindeki tampon kirişlerinin kalite kontrolü ile ilgili olarak zaman serisi verileri ve makine öğrenmesi algoritmalarını kullanarak bir tahmin problemi incelenmiştir. Tampon kirişlerinin üretim sürecinde frezelenir ve frezelenen deliklerin konumları katı tolerans sınırlarında olması gerekmektedir. Standart bir sinir ağı, uzun kısa süreli bellek ağı (LSTM) ve rastgele orman algoritmaları uygulanmış ve önceki ürün ölçümlerinin bir zaman serisi de dahil olmak üzere geçmiş verilerle eğitmişlerdir. Deneyler, LSTM ve rastgele orman için hafif bir baskınlıkla birlikte tüm modellerin benzer tahmin yeteneklerine sahip olduğunu göstermiştir. Sonuçlar, bazı deliklerin iyi kalitede tahmin edilebileceğini ve tahminlerin kalite kontrol sürecini iyileştirmek için kullanılabileceğini ortaya koymuşlardır.

Eklemeli İmalat

(Kim vd. 2018), eklemeli imalat ürünlerinin doğrudan nihai ürün olarak kullanılabilmesi için, eklemeli imalat ürününün istenen tekrarlanabilirlik, tekrar üretilebilirlik, güvenilirlik ve kesinliği kanıtlayabilecek ve bunlara ulaşabilecek kapasiteye sahip gelişmiş kalite kontrol (Quality Control) süreci ile üretilmesi gerektiğini söylemişlerdir. Çalışmada, eklemeli imalat teknolojisindeki Fotopolimer Vat İşlemleri (PVP), Malzeme Jetleme İşlemleri (MJP), Bağlayıcı Jetleme İşlemleri (BJP), Ekstrüzyon Tabanlı İşlemler (EBP), Toz Yatağı Füzyon İşlemleri (PBF), Yönlendirilmiş Enerji Biriktirme İşlemleri (DED) ve Tabaka Laminasyon İşlemlerini (SLP) yedi tekniğin değerlendirilmesi bulunmaktadır. Bu eklemeli imalat teknolojilerindeki farklı tekniklerin

kalite kontrolü üzerine bir inceleme sunmuş olup her bir kalite süreci aşamasında ayrıntılı tartışma sağlamaktadırlar. İnceleme çalışmalarında ilgili 7 eklemeli imalat yönteminin kalite kontrolünde kullanılan yapay zeka tabanlı uygulamaların endüstriyel, otomotiv, medikal, havacılık ve askeri üretim gibi eklemeli imalat endüstrisinde kalite kontrolün iyileştirilmesini etkileyeceğini düşünmektedirler.

(Yan vd. 2024), kontaminasyon nihai ürünlerde çatlaklara ve arızalara yol açan önemli bir problem olmasını ele almışlardır. Burada geleneksel değerlendirme yöntemleri malzeme bileşiminden ziyade fiziksel bütünlüğe odaklanıyor olmasının zaman kaybına yol açacağını belirtmişlerdir. Geleneksel değerlendirme yöntemleri yerine hiperspektral görüntüleme (HSI), uzamsal bilgilerle birlikte geniş bir frekans aralığından spektral verileri yakalayarak bu zorluğun üstesinden gelmek için sıcaklık, nem ve kimyasal bileşim açısından küçük farklılıkları tespit edebileceğini düşünmüşlerdir. Çalışmada, metal tozlarının tahribatsız muayenesi için makine öğrenimi ile HSI uygulamasını üzerine araştırma gerçekleştirmişlerdir. Deneysel sonuçlarına bağlı olarak özellikle endüstriyel üretim ortamlarının gereksinimlerini karşılamada, toz metalürjisinde tahribatsız test için HSI'nın muazzam potansiyelini ve makine öğrenimi ile sinerjisini olduğunu ortaya koymuşlardır.

(Nascimento vd. 2023), çalışmalarında yapay zeka tabanlı bilgisayarlı görü (computer vision) aracılığıyla malzeme ekstrüzyon parçalarının kalite değerlendirmesi için yeni bir yöntem ileri sürmüşlerdir. Bu amaçla, eklemeli üretim alanındaki diğer alanlara uygulanan denetim yöntemleri kullanılarak farklı teknikler incelenmiştir. Şekil analizi, Canny kenar bulma dedektörü kullanılarak görüntünün ikili (binary) formata dönüştürülmesi ile elde edilmiştir. Sonuçlar, önerilen sistemin eklemeli imalatla üretilen parçaları %86,5 genel doğrulukla sınıflandırabildiğini ve yüzeylerindeki kusurları daha etkili bir şekilde tespit edebildiğini ortaya koymuşlardır.

(Kumar vd. 2023), son teknoloji üretim yöntemleriyle dijitalleşme ve büyük veri kullanılabilirliği, ürün kalitesini artırmak için makine öğrenimi ve optimizasyon tekniklerini entegre etme ihtiyacını ve ilgisini daha da artırdığını düşünmektedirler. Çalışmalarında, modern üretim yöntemlerine, yani eklemeli üretime odaklanarak makine öğrenimi tekniğinin mevcut durumunu tartışmışlardır. Özellikle eklemeli üretimin tasarımı, süreçleri ve üretim kontrolüne odaklanan çeşitli kategoriler, son teknoloji incelemesi şeklinde açıklanmışlardır.

(Masinelli vd. 2021), lazer süreçlerinin kalitesini gerçek zamanlı olarak izlemek için sağlam ve düşük maliyetli yöntemlerin literatürde mevcut olmadığını ve bunun bir eksiklik olduğunu düşünmüşlerdir. Çalışmada, akustik emisyonları (AE) kullanarak eklemeli üretimin çevrimiçi kalite izlemesi için yenilikçi bir yaklaşım önermişlerdir. AE sinyalleri iş parçasının erimesi, resolidifikasyonu, delaminasyonu ve çatlaması gibi süreçler hakkında derinlemesine bilgi sağlayacağını düşünmüşlerdir. Önerilen yöntemle, akustik sinyallerin üretilen parçaların kalitesiyle korelasyonu yapay zeka yöntemleri ile incelenmiştir. Özellikle, makine öğrenimi, farklı sinterleme veya eritme olaylarından benzersiz akustik imzaların veri odaklı bir şekilde çıkarılması ve tanınması için kullanılmıştır. Yapay zekaya dayalı eklemeli imalat süreçlerinin kontrolü açısından gelecekte katkı sağlayacağını ortaya koymuşlardır.

(Pratap, Pandey, ve Sardana 2024), eklemeli üretim imalat sektöründe giderek yaygınlaştıkça, kalite kontrol ihtiyacı her zamankinden daha kritik hale geldiğini gözlemlemişlerdir. Derin öğrenme algoritmaları eklemeli üretim sürecini optimize etmeye yardımcı olabileceğini, böylece maliyet etkin ve verimli olduğunu kanıtlayabilir olduğunu düşünmüşlerdir. Derin öğrenme algoritmaları, baskı sürecini izleyen sensörlerden gelen verileri analiz ederek kalıpları belirleyebilir ve süreç parametrelerini optimize edebilir, böylece baskı kalitesi ve tutarlılığı artar, israf azalır ve kusur riski en aza indirilebileceğini gösteren çeşitli durumlarını inceleyen çalışmalardan bir derleme sunmuşlardır.

Tekstil Endüstrisi

(Yosephine vd. 2024), çalışmasında geleneksel tekstil endüstrisinde üretim kalite kontrolünü geliştirmek için makine öğrenimi ve bilgisayarla görme teknolojilerinin pratik uygulamasına incelemişlerdir. Bulgular, geleneksel tekstil üretiminde üretim kalite kontrolü için makine öğrenimi ve bilgisayarla görmenin kullanılmasının zorlukları ve fırsatları hakkında değerli bilgiler sağlamıştır. Çalışmadaki makine öğrenimi modelleri, gerçek dünyadaki tekstil üretim ortamlarında çeşitli aydınlatma koşulları altında %75 ila %100 arasında değişen iyi bir doğruluk göstererek pratik kalite kontrol uygulamaları için uygunluklarını ortaya koymuşlardır.

(Nair ve Trivedi 2024), derleme araştırmasının amacı, tekstil ve hazır giyim endüstrisinin kalite kontrol departmanında yapay zeka ve makine öğreniminin rolünü araştırmışlardır. Yapay zeka ve makine öğrenimi üreticilerin kısa sürede maksimum verimlilik ve üretkenliğe ulaşmasını sağlarken, aynı zamanda daha düşük üretim

maliyetiyle yüksek kaliteli ürünler üretmelerini sağlamaktadır. Bununla birlikte, yapay zeka ve makine öğreniminin önemli etkisi öncelikle tekstil ve hazır giyim endüstrisinin bazı alanlarında fark edilirken, kalite kontrolde nadiren keşfedilmiştir. Yapay zeka ve makine öğrenimi kusurları ve hataları tespit etmek için kullanıldığında, süreç otomatik hale gelir, işçilik süresini ve maliyetleri azaltır ve nihayetinde kaliteyi artırmaktadır.

(Hariharan ve Sivaraman 2024), çalışmalarında sektördeki kalite kontrol süreçlerini iyileştirmek için makine öğrenimi tekniklerini kullanan yeni bir çözüm tanımlamışlardır. Önerilen sistem, doğruluğu ve verimliliği artırarak ve insan etkileşimi ihtiyacını azaltarak kumaş kusurlarını otomatik olarak tanımlamak ve sınıflandırmak için bilgisayarla görmeyi kullanılmaktadır. Özel olarak eğitilen CNN modeli daha önceki yöntemlerle karşılaştırıldığında, geri çağırma, doğruluk, hassasiyet ve genel kusur tespitinin tümü %82'den %96'ya, doğruluk %80'den %95'e, hassasiyet %78'den %94'e, geri çağırma %82'den %96'ya ve genel kusur tespit oranı %85'ten %95'e yükselmiştir. Çalışma sonucunda, makine öğrenimi odaklı kalite kontrol sistemlerinin tekstil kumaşı üretim sektöründe devrim yaratma ve gelişmiş kalite ve operasyonel verimliliği garanti etme potansiyeli vurgulanmıştır.

Petrol ve Gaz Sektörü

(Heydari, Alinezhad, ve Vahdani 2024), çalışmalarında motor yağı üretimine odaklanarak imalat sanayilerinde Çok Değişkenli-Çok Aşamalı Kalite Kontrolünün önemini ve gerekliliğini araştırmışlardır. Motor yağı kalitesi, motor performansını önemli ölçüde etkilediği için çalışmanın temel amacı, klasik istatistiksel yöntemlerde genellikle göz ardı edilen bir yön olan verilerin görsel kalite kontrolü için derin öğrenme algoritmalarını kullanarak ve süreç kontrol süresini azaltarak kalite değişkenlerindeki hataları tespit etmede doğruluğu artırmaktır. Sayısal değişkenleri kontrol etmek için Uzun Kısa Süreli Bellek (LSTM) ve Evrişimsel Sinir Ağları (CNN) gibi derin öğrenme algoritmaları ile görüntü değişkenlerini kontrol etmek için Artık Ağlar (ResNet) ve Yoğun Evrişimsel Ağlar (DenseNet) kullanılmıştır. Önerilen LSTM-CNN hibrit algoritması, hata tespitinde bireysel CNN ve LSTM algoritmalarından daha iyi performans göstermekte ve performansı sırasıyla %15 ve %8 oranında artırmaktadır. Araştırma, derin öğrenme yöntemlerinden yararlanarak imalat endüstrilerinde çok değişkenli-çok aşamalı kalite kontrolünü önemli ölçüde geliştirmektedir. Büyük ölçekli verilerdeki karmaşık doğrusal

olmayan paternleri yüksek esneklik ve minimum zaman ile tespit edilebileceğini ortaya koymuşlardır.

(Ma 2023), çalışmasında petrol ve gaz yüzey inşaatında sık sık meydana gelen güvenlik kazalarına ve mevcut güvenlik gözetim sistemlerinin düşük zeka seviyesine yanıt olarak, petrol ve gaz yüzey inşaatı için yapay zeka tabanlı bir güvenlik gözetim sistemi geliştirmiştir. Bu sistemin en büyük özelliği, petrol ve gaz yüzey inşaatının güvenlik gözetimi süreci boyunca yapay zeka teknolojisini uygulamaktır. Manuel bağımlılığı azaltmak için sistem analizinin üç ana hedefi, petrol ve gaz yüzey tasarımının güvenli çalışması için önemli teknik destek sağlayacağı ortaya konulmuştur.

(Coveney, Fletcher, ve Hughes 1996), çalışmalarında petrol sahası çimentolarının değişkenliğinin tanımlanmasına, karakterize edilmesine ve tahmin edilmesine olanak tanıyan yöntemleri değerlendirmesini yapmışlardır. Önerilen yöntem, saf çimento tozlarının dağınık reflektans kızılötesi Fourier dönüşüm spektrumundan çimento bileşimlerinin, parçacık boyutu dağılımlarının ve kalınlaşma-zaman eğrilerinin tahmin edilmesini içermektedir. Tahminlerde yapay sinir ağları kullanılmıştır. Çalışma sonucunda, birçok temel çimento özelliğinin çimento tozlarının Fourier dönüşüm kızılötesi spektrumlarında yakalandığını ve uygun sinir ağı teknikleri kullanılarak bu spektrumlardan tahmin edilebileceğini ortaya koymuşlardır.

KAYNAKÇA

- Abdelhameed, Magdy M., ve Farid A. Tolbah. 2002. "A recurrent neural network-based sequential controller for manufacturing automated systems". *Mechatronics* 12(4):617-33.
- Akhir, Emelia Akashah P., ve Nasha Ayuni. 2021. "Predictive analytics of machine failure using linear regression on KNIME platform". Ss. 59-64 içinde.
- Alfeo, Antonio L., Mario GCA Cimino, Giuseppe Manco, Ettore Ritacco, ve Gigliola Vaglini. 2020. "Using an autoencoder in the design of an anomaly detector for smart manufacturing". *Pattern Recognition Letters* 136:272-78.
- AlMahamid, Fadi, ve Katarina Grolinger. 2021. "Reinforcement learning algorithms: An overview and classification". Ss. 1-7 içinde. IEEE.
- Ayvaz, Serkan, ve Koray Alpay. 2021. "Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time". *Expert Systems with Applications* 173:114598.
- Cardoso, Diogo, ve Luís Ferreira. 2020. "Application of predictive maintenance concepts using artificial intelligence tools". *Applied Sciences* 11(1):18.
- Castaño, Fernando, Rodolfo E. Haber, Wael M. Mohammed, Mirosław Nejman, Alberto Villalonga, ve Jose L. Martinez Lastra. 2020. "Quality monitoring of complex manufacturing systems on the basis of model driven approach". *Smart Structures and Systems* 26(4):495-506.
- Chen, Hong, Songhua Hu, Rui Hua, ve Xiuju Zhao. 2021. "Improved naive Bayes classification algorithm for traffic risk management". *EURASIP Journal on Advances in Signal Processing* 2021(1):30.
- Chen, Joseph C., Gangjian Guo, ve Wei-Nian Wang. 2020. "Artificial neural network-based online defect detection system with in-mold temperature and pressure sensors for high precision injection molding". *The International Journal of Advanced Manufacturing Technology* 110(7):2023-33.
- Chen, Lijia, Pingping Chen, ve Zhijian Lin. 2020. "Artificial intelligence in education: A review". *Ieee Access* 8:75264-78.
- Chen, Xing, Yonglei Wu, Xingyou He, ve Wuyi Ming. 2023. "A comprehensive review of deep learning-based PCB defect detection". *IEEE Access*.
- Chen, Yajun, Yuanyuan Ding, Fan Zhao, Erhu Zhang, Zhangnan Wu, ve Linhao Shao. 2021. "Surface defect detection methods for industrial products: A review". *Applied Sciences* 11(16):7657.
- Chhetri, Krishna Bahadur. 2024. "Applications of Artificial Intelligence and Machine Learning in Food Quality Control and Safety Assessment". *Food Engineering Reviews* 16(1):1-21.
- Chien, Chen-Fu, Wei-Tse Hung, ve Eddy Ting-Yi Liao. 2022. "Redefining monitoring rules for intelligent fault detection and classification via CNN transfer learning for smart manufacturing". *IEEE Transactions on Semiconductor Manufacturing* 35(2):158-65.
- Chisty, Nur Mohammad Ali, ve Harshini Priya Adusumalli. 2022. "Applications of artificial intelligence in quality assurance and assurance of productivity". *ABC Journal of Advanced Research* 11(1):23-32.
- Chouchene, Amal, Adriana Carvalho, Tânia M. Lima, Fernando Charrua-Santos, Gerardo J. Osório, ve Walid Barhoumi. 2020. "Artificial intelligence for product quality

- inspection toward smart industries: quality control of vehicle non-conformities". Ss. 127-31 içinde. IEEE.
- Coveney, Peter V., Philip Fletcher, ve Trevor L. Hughes. 1996. "Using artificial neural networks to predict the quality and performance of oil-field cements". *AI Magazine* 17(4):41-41.
- El Hachem, Charbel, Gilles Perrot, Loic Painvin, ve Raphaël Couturier. 2021. "Automation of quality control in the automotive industry using deep learning algorithms". Ss. 123-27 içinde. IEEE.
- Fonseca, Luis, António Amaral, ve José Oliveira. 2021. "Quality 4.0: The EFQM 2020 Model and Industry 4.0 Relationships and Implications". *Sustainability* 13(6). doi: 10.3390/su13063107.
- García-Esteban, Juan Alberto, Belén Curto, Vidal Moreno, I. González-Martín, Isabel Revilla, ve A. Vivar-Quintana. 2018. "A digitalization strategy for quality control in food industry based on Artificial Intelligence techniques". Ss. 221-26 içinde. IEEE.
- Gerdes, Mike, Diego Galar, ve Dieter Scholz. 2017. "Genetic algorithms and decision trees for condition monitoring and prognosis of A320 aircraft air conditioning". *Insight-Non-Destructive Testing and Condition Monitoring* 59(8):424-33.
- Hariharan, V., ve K. Sivaraman. 2024. "Machine Learning Techniques for Quality Control in Textile Fabric Manufacturing". Ss. 902-7 içinde. IEEE.
- Heydari, Mehdi, Alireza Alinezhad, ve Behnam Vahdani. 2024. "A deep learning framework for quality control process in the motor oil industry". *Engineering Applications of Artificial Intelligence* 133:108554.
- Hinckley, C. Martin. 1997. "Defining the best quality-control systems by design and inspection". *Clinical Chemistry* 43(5):873-79. doi: 10.1093/clinchem/43.5.873.
- Huang, Hong-Zhong, Hai-Kun Wang, Yan-Feng Li, Longlong Zhang, ve Zhiliang Liu. 2015. "Support vector machine based estimation of remaining useful life: current research status and future trends". *Journal of Mechanical Science and Technology* 29:151-63.
- Islam, Saidul, Hanae Elmekki, Ahmed Elsebai, Jamal Bentahar, Nagat Drawel, Gaith Rjoub, ve Witold Pedrycz. 2023. "A comprehensive survey on applications of transformers for deep learning tasks". *Expert Systems with Applications* 122666.
- J. Minglana, R. R. Tobias, ve R. E. Roxas. 2021. "Artificial Intelligence Applications in Quality Management System: A Bibliometric Study". Ss. 947-52 içinde *TENCON 2021 - 2021 IEEE Region 10 Conference (TENCON)*.
- Jeong, Jahoon. 2022. "Predicting defects of EBM-based additive manufacturing through XGBoost". *Journal of the Korea Institute of Information and Communication Engineering* 26(5):641-48.
- Jin, Ran, Jing Li, ve Jianjun Shi. 2007. "Quality prediction and control in rolling processes using logistic regression". *Transactions of NAMRI/SME* 35:113-20.
- Jung, Hail, Jinsu Jeon, Dahui Choi, ve Jung-Ywn Park. 2021. "Application of machine learning techniques in injection molding quality prediction: Implications on sustainable manufacturing industry". *Sustainability* 13(8):4120.
- Kang, Ziqiu, Cagatay Catal, ve Bedir Tekinerdogan. 2021. "Remaining useful life (RUL) prediction of equipment in production lines using artificial neural networks". *Sensors* 21(3):932.

- Kaparthi, Shashidhar, ve Daniel Bumblauskas. 2020. "Designing predictive maintenance systems using decision tree-based machine learning techniques". *International Journal of Quality & Reliability Management* 37(4):659-86.
- Katte, Trupti. 2018. "Recurrent neural network and its various architecture types". *International Journal of Research and Scientific Innovation (IJRSI)* 5(3):124-29.
- Khanum, Memoona, Tahira Mahboob, Warda Imtiaz, Humaraia Abdul Ghafoor, ve Rabeea Sehar. 2015. "A survey on unsupervised machine learning algorithms for automation, classification and maintenance". *International Journal of Computer Applications* 119(13).
- Khanzadeh, Mojtaba, Sudipta Chowdhury, Mohammad Marufuzzaman, Mark A. Tschopp, ve Linkan Bian. 2018. "Porosity prediction: Supervised-learning of thermal history for direct laser deposition". *Journal of manufacturing systems* 47:69-82.
- Kiangala, Sonia Kahimba, ve Zenghui Wang. 2021. "An effective adaptive customization framework for small manufacturing plants using extreme gradient boosting-XGBoost and random forest ensemble learning algorithms in an Industry 4.0 environment". *Machine Learning with Applications* 4:100024.
- Kim, Hoejin, Yirong Lin, ve Tzu-Liang Bill Tseng. 2018. "A review on quality control in additive manufacturing". *Rapid Prototyping Journal* 24(3):645-69.
- Krause, Daniel, Archontis Politis, ve Konrad Kowalczyk. 2021. "Comparison of convolution types in CNN-based feature extraction for sound source localization". Ss. 820-24 içinde. IEEE.
- Kumar, Sachin, T. Gopi, N. Harikeerthana, Munish Kumar Gupta, Vidit Gaur, Grzegorz M. Krolczyk, ve ChuanSong Wu. 2023. "Machine learning techniques in additive manufacturing: a state of the art review on design, processes and production control". *Journal of Intelligent Manufacturing* 34(1):21-55.
- Lee, Wo Jae, Haiyue Wu, Huitaek Yun, Hanjun Kim, Martin BG Jun, ve John W. Sutherland. 2019. "Predictive maintenance of machine tool systems using artificial intelligence techniques applied to machine condition data". *Procedia Cirp* 80:506-11.
- Liao, T. Warren, ve LJ Chen. 1998. "Manufacturing process modeling and optimization based on multi-layer perceptron network".
- Liu, Kailong, Xiaosong Hu, Huiyu Zhou, Lei Tong, W. Dhammika Widanage, ve James Marco. 2021. "Feature analyses and modeling of lithium-ion battery manufacturing based on random forest classification". *IEEE/ASME Transactions on Mechatronics* 26(6):2944-55.
- Liu, Kun, Aimei Li, Xi Wen, Haiyong Chen, ve Peng Yang. 2019. "Steel surface defect detection using GAN and one-class classifier". Ss. 1-6 içinde. IEEE.
- Liu, Tao, Lei Huang, ve Bo Chen. 2019. "Real-time defect detection of laser additive manufacturing based on support vector machine". S. 052043 içinde C. 1213. IOP Publishing.
- Lo, Huai-Wei, William Shiue, James JH Liou, ve Gwo-Hshiung Tzeng. 2020. "A hybrid MCDM-based FMEA model for identification of critical failure modes in manufacturing". *Soft Computing* 24:15733-45.
- Luan, Hui, ve Chin-Chung Tsai. 2021. "A review of using machine learning approaches for precision education". *Educational Technology & Society* 24(1):250-66.
- Ma, Jie. 2023. "The Application of Artificial Intelligence Technology in the Safety Monitoring System of Oil and Gas Ground". *Procedia Computer Science* 228:486-93.

- Masinelli, Giulio, Sergey A. Shevchik, Vigneashwara Pandiyan, Tri Quang-Le, ve Kilian Wasmer. 2021. "Artificial intelligence for monitoring and control of metal additive manufacturing". Ss. 205-20 içinde. Springer.
- Maulud, Dastan, ve Adnan M. Abdulazeez. 2020. "A review on linear regression comprehensive in machine learning". *Journal of Applied Science and Technology Trends* 1(2):140-47.
- Mavani, Nidhi Rajesh, Jarinah Mohd Ali, Suhaili Othman, MA Hussain, Haslaniza Hashim, ve Norliza Abd Rahman. 2022. "Application of artificial intelligence in food industry—a guideline". *Food Engineering Reviews* 14(1):134-75.
- Msakni, Mohamed Kais, Anders Risan, ve Peter Schütz. 2023. "Using machine learning prediction models for quality control: a case study from the automotive industry". *Computational Management Science* 20(1):14.
- Mumbelli, Joceleide DC, Giovanni A. Guarneri, Yuri K. Lopes, Dalcimar Casanova, ve Marcelo Teixeira. 2023. "An application of Generative Adversarial Networks to improve automatic inspection in automotive manufacturing". *Applied Soft Computing* 136:110105.
- Nainggolan, Elisabeth, ve Sri Rezeki. 2024. "Keys to Business Performance: Improving Product Quality and Implementing Total Quality Management in Manufacturing". *Jurnal Manajemen Bisnis Eka Prasetya Penelitian Ilmu Manajemen* 10(2):481-92.
- Nair, Gopika G., ve Vishal Trivedi. 2024. "Application of AI And ML in Quality Control Department of Textile and Apparel Industry".
- Nascimento, Rui, Isabel Martins, Thiago Assis Dutra, ve Luis Moreira. 2023. "Computer vision based quality control for additive manufacturing parts". *The International Journal of Advanced Manufacturing Technology* 124(10):3241-56.
- Obregon, Josue, Jihoon Hong, ve Jae-Yoon Jung. 2021. "Rule-based explanations based on ensemble machine learning for detecting sink mark defects in the injection moulding process". *Journal of Manufacturing Systems* 60:392-405.
- Ogorodnyk, Olga, Ole Vidar Lyngstad, Mats Larsen, Kesheng Wang, ve Kristian Martinsen. 2019. "Application of machine learning methods for prediction of parts quality in thermoplastics injection molding". Ss. 237-44 içinde. Springer.
- Orabi, Moussab, Kim Phuc Tran, Philipp Egger, ve Sébastien Thomassey. 2024. "Anomaly detection in smart manufacturing: An Adaptive Adversarial Transformer-based model". *Journal of Manufacturing Systems* 77:591-611.
- Ouadah, Abdelfettah, Leila Zemmouchi-Ghomari, ve Nedjma Salhi. 2022. "Selecting an appropriate supervised machine learning algorithm for predictive maintenance". *The International Journal of Advanced Manufacturing Technology* 119(7):4277-4301.
- Pacana, Andrzej, ve Robert Ulewicz. 2020. "Analysis of causes and effects of implementation of the quality management system compliant with ISO 9001". *Polish Journal of Management Studies* 21(1):283-96.
- Palakurti, Naga Ramesh. 2022. "AI Applications in Food Safety and Quality Control". *ESP Journal of Engineering & Technology Advancements* 2(3):48-61.
- Peres, Ricardo Silva, Jose Barata, Paulo Leitao, ve Gisela Garcia. 2019. "Multistage quality control using machine learning in the automotive industry". *IEEE Access* 7:79908-16.

- Pisner, Derek A., ve David M. Schnyer. 2020. "Support vector machine". Ss. 101-21 içinde *Machine learning*. Elsevier.
- Poole, David I., Randy G. Goebel, ve Alan K. Mackworth. 1998. *Computational intelligence*. C. 1. Oxford University Press Oxford.
- Pratap, Ayush, Atul Pandey, ve Neha Sardana. 2024. "Machine learning and additive manufacturing: A case study for quality control and monitoring". Ss. 211-34 içinde *Modern Materials and Manufacturing Techniques*. CRC Press.
- Prezas, Loukas, George Michalos, Zoi Arkouli, Antonis Katsikarelis, ve Sotiris Makris. 2022. "AI-enhanced vision system for dispensing process monitoring and quality control in manufacturing of large parts". *Procedia CIRP* 107:1275-80.
- Romli, Ikhsan, Toga Pardamean, Sufajar Butsianto, Tri Ngudi Wiyatno, ve Effendi bin Mohamad. 2021. "Naive bayes algorithm implementation based on particle swarm optimization in analyzing the defect product". S. 012020 içinde C. 1845. IOP Publishing.
- Sanchez-Marquez, Rafael, ve José Manuel Jabaloyes Vivas. 2020. "Multivariate SPC methods for controlling manufacturing processes using predictive models – A case study in the automotive sector". *Computers in Industry* 123:103307. doi: 10.1016/j.compind.2020.103307.
- Saravanan, Renuka, ve Pothula Sujatha. 2018. "A state of art techniques on machine learning algorithms: a perspective of supervised learning approaches in data classification". Ss. 945-49 içinde. IEEE.
- Sen, Pratap Chandra, Mahimarnab Hajra, ve Mitadru Ghosh. 2020. "Supervised classification algorithms in machine learning: A survey and review". Ss. 99-111 içinde. Springer.
- Shafiee, Mohammad Javad, Brendan Chywl, Francis Li, ve Alexander Wong. 2017. "Fast YOLO: A fast you only look once system for real-time embedded object detection in video". *arXiv preprint arXiv:1709.05943*.
- Shami, Tareq M., Ayman A. El-Saleh, Mohammed Alswaitti, Qasem Al-Tashi, Mhd Amen Summakieh, ve Seyedali Mirjalili. 2022. "Particle swarm optimization: A comprehensive survey". *Ieee Access* 10:10031-61.
- Silva, Bruno, Joao Sousa, ve Guillem Alenya. 2021. "Machine learning methods for quality prediction in thermoplastics injection molding". Ss. 1-6 içinde. IEEE.
- Singh, Bharat, Rajesh Kumar, ve Vinay Pratap Singh. 2022. "Reinforcement learning in robotic applications: a comprehensive survey". *Artificial Intelligence Review* 55(2):945-90.
- Sini, Francesca, Giulia Bruno, Paolo Chiabert, ve Frederic Segonds. 2020. "A lean quality control approach for additive manufacturing". Ss. 59-69 içinde. Springer.
- Sordan, Juliano Endrigo, Pedro Carlos Oprime, Márcio Lopes Pimenta, Paolo Chiabert, ve Franco Lombardi. 2020. "Lean Six Sigma in manufacturing process: a bibliometric study and research agenda". *The TQM Journal* 32(3):381-99.
- Su, Chun, Le Li, ve Zejun Wen. 2020. "Remaining useful life prediction via a variational autoencoder and a time-window-based sequence neural network". *Quality and Reliability Engineering International* 36(5):1639-56.
- Sufriyana, Herdiantri, Atina Husnayain, Ya-Lin Chen, Chao-Yang Kuo, Onkar Singh, Tso-Yang Yeh, Yu-Wei Wu, ve Emily Chia-Yu Su. 2020. "Comparison of multivariable logistic regression and other machine learning algorithms for prognostic

- prediction studies in pregnancy care: systematic review and meta-analysis". *JMIR medical informatics* 8(11):e16503.
- Talukder, Md Alamin, Md Manowarul Islam, Md Ashraf Uddin, Arnisha Akhter, Khondokar Fida Hasan, ve Mohammad Ali Moni. 2022. "Machine learning-based lung and colon cancer detection using deep feature extraction and ensemble learning". *Expert Systems with Applications* 205:117695.
- Tambare, Parkash, Chandrashekhhar Meshram, Cheng-Chi Lee, Rakesh Jagdish Ramteke, ve Agbotiname Lucky Imoize. 2021. "Performance measurement system and quality management in data-driven Industry 4.0: A review". *Sensors* 22(1):224.
- Uddin, Shahadat, Ibtisham Haque, Haohui Lu, Mohammad Ali Moni, ve Ergun Gide. 2022. "Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction". *Scientific Reports* 12(1):6256.
- Uyanık, Gülden Kaya, ve Neşe Güler. 2013. "A study on multiple linear regression analysis". *Procedia-Social and Behavioral Sciences* 106:234-40.
- Verstraete, David, Enrique Droguett, ve Mohammad Modarres. 2019. "A deep adversarial approach based on multi-sensor fusion for semi-supervised remaining useful life prognostics". *Sensors* 20(1):176.
- Wang, Junpu, Guili Xu, Fujun Yan, Jinjin Wang, ve Zhengsheng Wang. 2023. "Defect transformer: An efficient hybrid transformer architecture for surface defect detection". *Measurement* 211:112614.
- Wang, Tian, Yang Chen, Meina Qiao, ve Hichem Snoussi. 2018. "A fast and robust convolutional neural network-based defect detection model in product quality control". *The International Journal of Advanced Manufacturing Technology* 94:3465-71.
- Wu, Yuting, Mei Yuan, Shaopeng Dong, Li Lin, ve Yingqi Liu. 2018. "Remaining useful life estimation of engineered systems using vanilla LSTM neural networks". *Neurocomputing* 275:167-79.
- Yan, Yijun, Jinchang Ren, He Sun, ve Robert Williams. 2024. "Nondestructive quantitative measurement for precision quality control in additive manufacturing using hyperspectral imagery and machine learning". *IEEE transactions on industrial informatics*.
- Yıldız, Kazım, Ali Buldu, ve Mustafa Demetgul. 2016. "A thermal-based defect classification method in textile fabrics with K-nearest neighbor algorithm". *Journal of Industrial Textiles* 45(5):780-95.
- Yi, D., I. Kim, ve S. Bu. 2024. "VARIATIONS OF TRAINING PROCESS IN VANILLA RECURRENT NEURAL NETWORK FRAMEWORK." *Neural Network World* (2).
- Yosephine, Vina Sari, Tabitha Hanna, Marla Setiawati, ve Ari Setiawan. 2024. "Machine Learning for Quality Control in Traditional Textile Manufacturing". *Jurnal Rekayasa Sistem Industri* 13(1):165-74.
- Zaheer, Manzil, Guru Guruganesh, Kumar Avinava Dubey, Joshua Ainslie, Chris Alberti, Santiago Ontanon, Philip Pham, Anirudh Ravula, Qifan Wang, ve Li Yang. 2020. "Big bird: Transformers for longer sequences". *Advances in neural information processing systems* 33:17283-97.
- Zhang, Nannan, Lifeng Wu, Jing Yang, ve Yong Guan. 2018. "Naive bayes bearing fault diagnosis based on enhanced independence of data". *Sensors* 18(2):463.

- Zhao, Minghang, Baoping Tang, ve Qian Tan. 2016. "Bearing remaining useful life estimation based on time-frequency representation and supervised dimensionality reduction". *Measurement* 86:41-55.
- Zhao, Rui, Dongzhe Wang, Ruqiang Yan, Kezhi Mao, Fei Shen, ve Jinjiang Wang. 2017. "Machine health monitoring using local feature-based gated recurrent unit networks". *IEEE Transactions on Industrial Electronics* 65(2):1539-48.

BÖLÜM 4

BIYODİZEL KULLANILAN BİR DİZEL MOTORDA ÇOK KRİTERLİ KARAR VERME YÖNTEMİYLE OPTİMUM ÇALIŞMA KOŞULLARI VE YAKIT KARIŞIMININ BELİRLENMESİ

Cenk SAYIN

Prof. Dr., Marmara Üniversitesi, csayin@marmara.edu.tr

 0000-0001-7286-472X

Taşımacılık ve enerji üretiminde kullanılan içten yanmalı motorlarda enerji, petrol ürünlerinden karşılanmaktadır. Ancak günümüzde petrol fiyatlarındaki dalgalanmalar ve fosil yakıtların hızla tükenerek çevresel tehdit oluşturması nedeniyle petrolün yerini alabilecek alternatif yakıtlar üzerine araştırmalar yapılmaktadır. Biyodizel, bitkisel ve hayvansal ürünlerden elde edilen, dizel yakıtla benzer yanma özellikleri gösteren, yenilenebilir nitelikte bir yakıttır (Söyler et al. 2023). Bu yakıtlar belli oranda dizel yakıtıyla karıştırılarak içten yanmalı motorlarda kullanılabilir.

Motor performansını ve yanmayı etkileyen en önemli parametreler, özgül yakıt tüketimi, efektif verim, ortalama efektif basınç ve egzoz gazı sıcaklıklarıdır. İçten yanmalı motorların yaklaşık %30 termal verime sahip olduğu ve kalan enerjinin hem egzoz gazı hem de soğutma sıvısı yoluyla ısı olarak kaybolduğu bilinen bir gerçektir. Motorların ısı veriminin artırılması ile yakıt tüketiminin azaltılması yani performans ve yanma karakteristiklerindeki iyileşmeler egzoz emisyonlarını da azaltabilmektedir (Söyler et al. 2024). İçten yanmalı motorlarda egzoz emisyonları ise ağırlıklı olarak; azot oksitler (NO_x), karbon monoksit (CO) ve yanmamış hidrokarbonlar (HC), partikül madde (PM), kükürt oksitler (SO_x), kurşun (Pb) içermektedir. Bu kirletici emisyonlar insan sağlığı, hayvanlar ve çevre açısından zararlı ve tehlikeli etkilere sahiptirler.

Bu çalışmada ise içten yanmalı bir motorda biyodizel kullanılarak motor performansı, yanma ve emisyon kriterlerinin en ideal yakıt seçimine etkileri araştırılmıştır. Birden fazla kriterin optimize edilerek olası çözüm setleri arasından en iyi alternatifin seçildiği bu tür problemlerde Çok Kriterli Karar Verme Yöntemleri sıklıkla kullanılmaktadır. Karar verme sürecinde, karar vericiler, amaç, karar kriterleri, alternatif

seçenekler, kriter aralığı gibi kararı oluşturan temel elemanların önceden doğru belirlenmesi ise önemlidir (Söyler, 2023).

Literatürde çok sayıda biyodizel ile ilgili deneysel çalışma bulunmasına rağmen Çok Kriterli Karar Verme Yöntemleri kullanılarak yapılmış ve biyodizel yakıt karışımlarının seçimi, yakıt üretim yöntemi ya da alternatif yakıt türünün belirlenmesi ile ilgili uygulama sayısı çok azdır.

Okolie vd. (2023) en iyi sürdürülebilir havacılık yakıtı üretim yöntemini belirlemek adına çok kriterli karar verme yöntemlerini kullanmışlardır. Karar kriterleri satış fiyatı, sermaye artırım, işletim giderleri, üretim maliyeti, sera gazı emisyonları, küresel ısınma potansiyeli, verimlilik, uygunluk ve güvenilirlik olarak belirlenmiştir. Tüm kriterler için eşit ağırlık varsayıldığında ve alternatifler Basit Toplam Ağırlıklandırma yöntemine göre sıralandığında en uygun üretim yönteminin hidroişlenmiş esterler ve yağ asitleri (HEFA) olduğu görülmüştür.

Narayanamoorthy vd. (2021) elektrik, doğal gaz, biyodizel, etanol ve propan yakıtları arasından sera gazı emisyonlarını azaltacak en uygun yakıtın seçimi için bir karar modeli oluşturmuşlardır. Karar kriterleri çevre güvenliği, CO₂ emisyon seviyesi, teknik maliyet, yakıt maliyeti olarak belirlenmiş olup ağırlıklandırması DEMATEL, kriter seçimi ise COPRAS yöntemi ile yapılmıştır. Çalışma sonucunda en uygun yakıtın doğalgaz olduğu görülmüştür.

Kumar vd. (2017) en iyi biyodizel üretim yöntemini belirleyebilmek için bulanık analitik hiyerarşi prosesini kullanmışlardır. Çalışmada asitkatalizör, alkalikatalizör, enzimatik katalizör, mikrodalga ve ultrason destekli emülsiyon ve süperkritik alkol yöntemleri arasından seçim yapılmıştır. Değerlendirme kriterleri olarak asit değeri, viskozite, gliserol ayırma, dönüştürme, sülfür içeriği, emisyon karakteristikleri ve maliyeti dikkate alınmıştır. Uygulama neticesinde süperkritik alkol yöntemi en uygun yöntem olarak tespit edilmiştir.

Nwokoagbara vd. (2015) biyodizel üretimi için en iyi mikroalg türünü belirlemek amacıyla AHP ve TOPSIS yöntemlerini kullanmıştır. Çeşitli mikroalg türleri arasından en iyi olan tür; büyüme oranı, lipid içeriği, yağ asidi profili, hasat yöntemi ve enerji tüketimi kriterleri değerlendirilerek belirlenmiştir. Çalışmada Scenedesmus sp. alg türünün en uygun olduğu sonucuna ulaşılmıştır.

Durairaj vd. (2014) tarafından bulanık AHP ve GRA-TOPSIS yöntemleri kullanılarak çeşitli tohumlardan üretilmiş biyodizel yakıtların arasından en uygun olan yakıt seçilmiştir. Viskozite, setan sayısı, parlama noktası, bulutlanma noktası, akma noktası ve ısı değeri kriterleri değerlendirilerek alternatifler sıralanmıştır. Çalışmada Pongamia tohumunun en ideal olduğu sonucuna ulaşılmıştır.

Abdulvahitoglu ve Kilic (2022) biyodizel üretimi için en uygun mahsulü belirlemek için AHP-TOPSIS yöntemini kullanmıştır. Çeşitli fiziko-kimyasal özellikler (setan sayısı, yoğunluk, viskozite, parlama noktası, akma noktası, ısı değeri), performans özellikleri (tork, özgül yakıt tüketimi, güç) ve üretilen emisyonlara (NO_x, CO, HC) dayalı olarak kolza yağı Türkiye'de en uygun ürün olarak belirlenmiştir.

Agar vd. (2023) İsveç'te enerji kullanımı için biyokütle yakıt peletlerinin seçimi için oluşturdukları karar modelinde üretim maliyeti, enerji yoğunluğu, dayanıklılık, kül içeriği, sülfür içeriği, klorine içeriği, hammadde kullanılabilirliği kriterlerini kullanmışlardır. DIRECT, SMART, SWING, AHP, PAPRIKA, Entropy yöntemleri ile ayrı ayrı kriter ağırlıkları belirlenmiş ve TOPSİS yöntemi ile alternatifler sıralanmıştır. Biyokütle pelet üretimi için en uygun yakıtın referans odun peletleri olduğu görülmüştür.

Sakthivel vd. (2015) en iyi yakıt karışım oranını belirleyebilmek için ANP-TOPSIS ve ANP-VIKOR hibrit modellerini kullanmışlardır. Değerlendirme kriterleri olarak fren termal verimliliği, egzoz gaz sıcaklığı, NO_x emisyonu, CO₂ emisyonu, CO emisyonu, HC emisyonu, duman, tutuşma gecikmesi, yanma süresi ve maksimum basınç artış oranı tercih edilmiştir. Dizel, B20, B40, B60, B80 ve B100 alternatifleri arasından en iyi yakıt karışımı B20 (%20 biyodizel + %80 dizel) olarak belirlenmiştir.

Erdoğan vd. (2019) çalışmasında kemik iliği yağlarından üretilen hayvansal biyodizel yakıtı ek olarak aspir ve kanola yağı kökenli bitkisel biyodizel yakıt temin etmiştir. Hacimsel olarak %5, %20, %50 ve %100 oranlarında bitkisel biyodizel ile hayvansal biyodizel ayrı ayrı dizel yakıtla harmanlanarak 8 farklı yakıt karışımı oluşturmuştur. Performans, emisyon ve yanma karakteristiklerine göre en iyi yakıtın seçimi için ANP-MOORA ve SWARA-MOORA yöntemleri hibrit olarak kullanılmıştır. Karar kriterleri efektif verim, özgül enerji tüketimi, NO_x emisyonu, CO₂ emisyonu, CO emisyonu, HC emisyonu, yanma süresi, maksimum silindir basıncı, statik tutuşma gecikmesi ve ortalama gaz sıcaklığıdır. Çalışmada VOB20 bitkisel karışimli yakıtın en iyi yakıt karışımı olduğu belirlenmiştir.

Majji vd. (2023) performans ve emisyon özelliklerine bağlı olarak, farklı motor yüklerinde 16 adet mikroemülsiyon yakıt arasından en uygun yakıtın seçimi için bir karar modeli ortaya koymuşlardır. Karar kriterleri olarak ısıl değer, fren ısı verimlilik, fren özgül yakıt tüketimi, CO, HC, NO_x, partikül madde emisyonları olarak seçilmiştir. AHP-VIKOR, AHP-TOPSIS, AHP-PROMETHEE yöntemlerini hibrit olarak kullanılarak hacimsel olarak %80 dizel+%20 mikroemülsiyon (%19,6 bütanol+ %0,4 su) yakıtın en iyi yakıt karışımı olduğu belirlenmiştir.

Yusuf vd. (2022) %20'ye kadar bütanol, %40 atık plastik yağ ve 60 ppm nanoparçacık içeren on dört dizel yakıt karışımı alternatifinden en uygun olanını Entropi+TOPSIS ve Entropi+PROMETHEE-II yöntemlerini hibrit kullanarak araştırmıştır. CO, NO_x, HC, organik karbon, temel karbon emisyonları karar kriterlerini oluşturmaktadır. Her iki yöntemde de 60 ppm nanoparçacık içeren bütanol-atık plastik yağ-dizel karışımlarının diğer karışımlara kıyasla daha iyi olduğu belirlenmiştir.

Debbarma vd. (2017) bir içten yanmalı motor için en iyi hidrojenle zenginleştirilmiş etanol-biyodizel yakıt karışımını seçmek için PROMETHEE-II ve VIKOR yöntemleri kullanılmıştır. NO_x, İ_s, CO, HC emisyonları, özgül yakıt tüketimi, egzoz gazı sıcaklığı kriterlerine göre bir karar modeli oluşturulmuştur. Kriterler uzman görüşleri dikkate alınarak AHP yöntemine göre ağırlıklandırılmıştır. Hidrojen enjeksiyon süresi, motor yükü ve biyodizel ethanol oranına göre belirlenen 10 farklı alternatif yakıt içerisinde en uygun yakıtın %75 motor yükünde 9000 µs enjeksiyon süresine sahip %100 biyodizel yakıt olduğu sonucuna ulaşılmıştır.

Swathi ve Seela (2020) en iyi nano emülsifiye dizel - biyodizel karışımı seçimi için karar modeli oluşturmuşlardır. Karar kriterleri CO, HC, CO₂, NO_x, O₂, Duman emisyonları, fren ısı verimlilik ve özgül yakıt tüketimi olarak belirlenmiştir. Dizel, B10 (Jatropha biyodizel karışımı), B10'un 25, 50 ve 100 ppm Al₂O₃ içeren nano emülsiyonları karşılaştırılan yakıtlardır. Motor yükü %0, 25, 50, 75 ve 100 olacak şekilde değiştirilmiştir. Karar modeline göre B10+50 ppm Al₂O₃ içeren nano emülsiyonlu karışım yakıt en uygun yakıt seçilmiştir.

Anandavelu vd. (2023) çalışmalarında dizel-biyodizel karışımı yakıtları çeşitli motor yüklerinde geleneksel yanma ve çift yakıtlı yanma modlarında yakarak deneysel çalışma yapmışlardır. Ayrıca %10, 20 ve 30 oranlarda hekzanol katarak performans ve emisyon değerlerindeki değişimleri gözlemlemişlerdir. Optimizasyon çalışmasında ise en


uygun yakıt kombinasyonunu yapay sinir ağı+TOPSIS tekniklerini kullanarak araştırmışlardır. Karar modeli fren ısı verimliliği, özgül yakıt tüketimi, maksimum silindir basıncı gibi performans parametreleri ile CO, HC, NO_x, duman emisyon parametrelerini içermekte olup hepsine eşit ağırlık verilmiştir. Geleneksel yanma prosesinde %25 ve %50 yüklerde dizel, çift yakıtlı yanma prosesinde ise %75 yükte B50 +%30 hekzanol karışımının, %100 yükte B70+%30 hekzanol karışımının en ideal yakıt karışımları olduğu tespit edilmiştir.

Chaitanya vd. (2020) çalışmalarında dizel-pungam yağlı biyodizel karışımı yakıtlar (B0, B20, B40, B60, B80 ve B100) kullanılarak 1500 d/d sabit motor devrinde, %0, 25, 50, 75 ve 100 motor yüklerinde deneysel çalışma yapılmıştır. Deney verilerine göre en uygun yakıt karışımlarını sıralamak amacıyla oluşturulan karar modeli için AHP+TOPSIS yöntemleri hibrit şekilde kullanılmıştır. NO_x, CO₂, O₂, CO, HC, Duman emisyonları karar kriterleri olarak belirlenmiştir. Düşük motor yüklerinde B20 karışımının, yüksek motor yüklerinde ise B80 karışımının en iyi seçenek olduğu görülmüştür.

Biyodizel karışım yakıtlarının ve dizelin sıralanması sadece çok kriterli karar verme yöntemine değil aynı zamanda motorun çalışma (devir ve yük) koşullarına da bağlıdır. Dolayısıyla, bu çalışmanın amacı, motor yükleme koşullarından bağımsız olarak biyodizel yakıtların sürdürülebilir bir alternatif olarak dizelden daha iyi performans gösterip gösteremeyeceğini değerlendirmek için kullanılabilecek genelleştirilmiş bir ÇKKV çerçevesi geliştirmektir.

ÇOK KRİTERLİ KARAR VERME


Bu çalışma karar kriterlerinin ölçüldüğü deneysel çalışma ve alternatiflerin bütüncül bir karar modeli ile sıralandığı teorik çalışma olmak üzere iki aşamadan oluşmaktadır. Yönteme ilişkin adımları Şekil 1’de yer almaktadır.



Şekil 1. Yönteme ilişkin işlem adımları

DeneySEL Çalışma

DeneySEL çalışmaa kullanılan test ünitesi; tek silindirli deney motoru, Eddy akımı dinamometre, emisyon ölçüm cihazı, hava ve yakıt ölçüm düzeneği ve silindir içi basınç ölçüm sisteminden oluşmaktadır. Deney düzeneğinin şematik görünümü Şekil 2’de verilmiştir. Motor yüklemesi krank miline bağlı bir dinamometre ile sağlanmaktadır. Deney motorunun yer aldığı oda, şartlandırılmış standart 1 atm 25 °C sıcaklıkta klimalı bir ortamdır. Motor soğutma suyu, motor yağı, yakıt sıcaklığı sistem tarafından sıcaklıkları ortam sıcaklığına şartlandırılmaktadır. Deney motorunun püskürtme basıncı, püskürtme avansı, dinamometre yükü, turbo basıncı elektronik olarak kontrol edilerek değiştirilebilmektedir. Motor çalışma koşullarına gelmeden çalışmamaktadır. Motor, bilgisayar sistemi üzerinden dinamometre üzerinden hareket verilerek ateşlenmektedir. Tablo 1’de deney motorunun teknik özellikleri verilmiştir.



Şekil 2. Deney düzeneğinin şematik görünümü 1- Deney motoru, 2- Dinamometre, 3- Veri toplayıcı, 4- Egzoz emisyon analizörü, 5-Dinamometre kontrol ünitesi

Tablo 1. Deney motorunun teknik özellikleri

Özellik	Değer
Yakıt	Dizel
Motor Zamanlaması	Dört Zamanlı
Silindir Sayısı	Tek Silindirli
Subap Sayısı/Türü	3 (2 Emme - 1 Egzoz)/ Üstten Subap
Silindir Hacmi	1120 cm ³
Silindir Çapı	106,5 mm
Silindir Stroğu	127 mm
Sıkıştırma Oranı	16,4/1
Maksimum Tork	160 Nm
Maksimum Güç	50 kW
Maksimum Motor Devri	2500 devir/dakika
Maksimum Silindir İçi Basınç	190 bar

Çalışmada kullanılan dizel – biyodizel karışımları için bitkisel kaynaklı biyodizel satın alınmıştır. Biyodizel hacimsel olarak %0, %50 ve %100 oranlarında ticari dizel yakıt ile karıştırılmıştır. Hazırlanan karışım yakıtlarının içerisinde hacimsel olarak karıştırılan biyodizelin oranı ile “B” harfi ile isimlendirilmiştir. Örneğin; yakıt karışımının içerisinde

%50 oranında biyodizel ve %50 oranında dizel yakıt varsa ortaya çıkan karışım yakıtın isimlendirilmesi “B50” olarak isimlendirilmiştir. Deneylerde kullanılan yakıtlar B0 (ticari dizel), B50 ve B100 (saf biyodizel) olmak üzere üç (3) çeşittir.

Motor ilk önce standart dizel yakıt (B0) ile boşa yüksüz çalıştırılmış daha sonrasında genel kontroller yapılarak motorda ve dinamometrede herhangi bir sorunun olup olmadığı kontrol edilmiştir. Deneysel çalışmamızda B0, B50 ve B100 yakıtları için 1000, 1250 ve 1500 d/d olmak üzere üç farklı devirde ölçümler yapılmıştır. Her bir ölçüm aralığında motor %25, %50 ve %75 yük altında çalıştırılmıştır. Deneysel çalışmalarda elde edilen veriler ile motor performansı, egzoz emisyonları ve yanma karakteristikleri analiz edilmiştir.

Çok Kriterli Karar Verme Analizi

Literatürde biyodizel karışımları ile yapılan çeşitli deneysel çalışmalarda araştırmacılar, yakıtların motor performansı, yanma ve emisyon karakteristiklerini maksimum faydayı veren yakıtları vurgulayarak ayrı ayrı yorumlamışlardır. Ancak bu çalışmada amacımız, alternatif yakıtların değerlendirilmesinde kullanılan tüm parametrelerin olumlu ve olumsuz etkilerini bütüncül bir yaklaşımla dikkate alan en optimum yakıtın belirlenmesine dair bir karar modeli oluşturmaktır. Birden çok kriterin değerlendirildiği karar modellerinde ise çok kriterli karar verme teknikleri sıklıkla kullanılmaktadır.

Çok kriterli karar verme yöntemlerinde ilk olarak alternatiflerin ve kriterlerin tanımlaması yapılır. Sonrasında her bir alternatifin ayrı ayrı, her kritere göre ölçümleri elde edilir, kriterlere göre ağırlıkları atanır. Atanan kriter ağırlıkları ve alternatiflerin tek kriterli değer ölçümleri bir bütüncülleştirme modeli ile bir araya getirilerek alternatiflerin bütünsel değerleri saptanır. Son olarak duyarlılık analizleri gerçekleştirilir ve sonuç önerileri ile değerlendirmeleri ortaya konulur (TÜSSİDE, 2020).

Deneysel çalışmada elde edilen verilere göre performans, yanma, emisyon ve elektrik üretimi karakteristikleri açısından bütüncül bir yaklaşımla en iyi yakıtın seçimi hedeflenmiştir. Karar sürecinde karar vericilerin görüşleri doğrultusunda kriter ağırlıklarının belirlenmesinde **CRITIC Yöntemi**, alternatiflerin seçiminde ise **TOPSIS Yöntemi** kullanılarak iki farklı yöntemin hibrit kullanımı esas alınmıştır.

Karar kriterlerinin ve alternatiflerin belirlenmesi

Deney sonuçlarından elde edilen veriler incelenmiş olup performans, emisyon, yanma ve ısı geri kazanımını boyutları açısından belirlenen karar kriterleri Tablo 2.2’de verilmiştir.

Tablo 2. Dizel motorda alternatif yakıt seçimi için belirlenen karar kriterleri

Kriter	Kriter adı	Birimi	Amaç
K1	Özgül yakıt tüketimi	g/kWh	Min
K2	Efektif verim	%	Max
K3	CO emisyonları	%	Min
K4	HC emisyonları	ppm	Min
K5	CO ₂ emisyonları	%	Min
K6	NO _x emisyonları	ppm	Min

Özgül yakıt tüketimi (ÖYT), birim zamanda tüketilen yakıt miktarının efektif güce oranı olarak tanımlanır ve denklem (1)’deki formülle hesaplanmaktadır.

$$\text{ÖYT} = \frac{m_y \cdot 3600}{\Delta t \cdot N_e} \quad (1)$$

Burada m_y : tüketilen yakıt miktarını, Δt : birim zamanı, N_e : efektif gücü ifade etmektedir.

Efektif verim, birim zamanda motorda tüketilen kütleli yakıt enerjisinin motordan elde edilen efektif güce oranı olarak tanımlanır ve denklem (2)’deki formülle hesaplanmaktadır.

$$\text{EFV} = \left(\frac{1}{\text{ÖYT} \cdot H_u} \cdot 1000 \cdot 3600 \right) \cdot 100 (\%) \quad (2)$$

Burada EFV: % cinsinden efektif verimi, ÖYT: özgül yakıt tüketimini, H_u : yakıtın alt ısı değeri (kJ/kg) ifade etmektedir.

CO emisyonları, yanma reaksiyonunun zengin karışımda yanması sonucunda oluşan, yani yanma odasında yetersiz oksijen olması durumunda ortaya çıkan emisyon türüdür.

HC emisyonları, yanma reaksiyonun düşük sıcaklık, düşük oksijen, yetersiz zaman ya da hava/yakıt oranının zengin olması gibi nedenlerden dolayı yakıtın sahip olduğu kimyasal enerjinin tamamen yakılamaması nedeniyle ortaya çıkan emisyon türüdür.

CO₂ emisyonları, yanma reaksiyonunun tam yanma olması sonucunda oluşan emisyon türüdür. CO₂ emisyonunun bir kısmı fotosentezde kullanılarak doğada dönüşse de bir kısmı atmosferde birikerek sera gazı etkisi oluşturmaktadır.

NO_x emisyonları, yanma reaksiyonu esnasında, yüksek sıcaklık ile beraber azot ve oksijenin reaksiyona girmesi ile ortaya çıkan emisyon türü olup insan sağlığına olumsuz etkileri vardır.

Karar modeli oluşturulurken öncelikle seçilen 6 adet karar kriteri, belirlenen 3 adet alternatif yakıt için 3 farklı motor devri ile 3 farklı motor yükü ve 3 farklı avans değeri dikkate alınarak başlangıç karar matrisleri oluşturulmuştur. Seçilen kriterlerden K2 ve K5 kriterleri maksimizasyon yönlü olup, diğer kriterler (K1, K3, K4 ve K6) minimizasyon yönlüdür. Dizel motor 1000 d/d, 1250 d/d ve 1500 d/d iken elde edilen verilere göre oluşturulan başlangıç karar matrisleri sırasıyla Tablo 2.3, Tablo 2.4 ve Tablo 2.5'te yer almaktadır.

Tablo 3. Başlangıç karar matrisi (1000 d/d)

Yük (%)	Karışım	ÖYT (g/kWh)	EV (%)	CO (%)	HC (ppm)	CO ₂ (%)	NO _x (ppm)
25%	B0	410,26	20,36%	0,08	18	4,47	247,19
	B50	437,56	20,05%	0,04	14	4,12	288,67
	B100	448,09	19,50%	0,032	13	4,3	295,96
50%	B0	398,27	20,76%	0,068	19	5,21	494,05
	B50	432,06	20,19%	0,032	15	5,32	518,75
	B100	439,27	20,02%	0,025	14	5,34	529,03
75%	B0	386,27	20,98%	0,052	22	4,7	553,23
	B50	426,27	20,48%	0,027	16	4,62	604,61
	B100	432,06	20,32%	0,018	15	4,61	628

Tablo 4. Başlangıç karar matrisi (1250 d/d)

Yük (%)	Karışım	ÖYT (g/kWh)	EV (%)	CO (%)	HC (ppm)	CO ₂ (%)	NO _x (ppm)
25%	B0	394,46	23,10%	0,09	17	4,6	305,8
	B50	408,58	21,60%	0,06	13	4,45	332,17
	B100	432,86	21,20%	0,044	12	4,67	355,31
50%	B0	382,56	24,00%	0,079	18	5,36	556,49
	B50	402,35	22,50%	0,054	14	5,46	585,23
	B100	430,26	22,21%	0,043	13	5,51	600,08
75%	B0	378,89	25,10%	0,062	19	5,58	671,26
	B50	398,49	23,40%	0,035	15	5,84	713,07
	B100	426,13	22,70%	0,02	13	5,48	718,24

Tablo 5. Başlangıç karar matrisi (1500 d/d)

Yük (%)	Karışım	ÖYT (g/kWh)	EV (%)	CO (%)	HC (ppm)	CO ₂ (%)	NO _x (ppm)
25%	B0	382,52	23,51%	0,14	16	4,49	338,13
	B50	397,81	22,05%	0,085	11	4,36	363,67
	B100	421,53	21,25%	0,05	10	4,51	381,77
50%	B0	366,25	24,32%	0,092	17	5,4	594,25
	B50	389,81	22,75%	0,069	14	5,52	642,89
	B100	416,93	22,35%	0,048	11	5,62	649,36
75%	B0	362,25	25,35%	0,07	18	5,76	741,86
	B50	383,88	23,23%	0,042	13	5,3	822,17
	B100	410,55	22,65%	0,03	12	5,87	853,37

Kriter ağırlıklarının belirlenmesi

Kriter ağırlıkları belirlenirken kriterlerin hiyerarşik yapısının ve önem sırasının belirlenmesi, uzman görüşlerine başvurulması gibi belirli şartların ve varsayımların yerine getirilmesi öngörülmektedir. Kriter ağırlıkları belirlenirken AHP, ANP, CRITIC,

DEMATEL, Delphi, Entropi, MACBETH, Puanlama, SMART, SWARA, FUCOM gibi yöntemler yaygın olarak kullanılabilmektedir.

CRITIC, Entropi gibi nicel yöntemler, DIRECT, SMART, SWING, AHP ve PAPRIKA gibi nitel yöntemlere göre daha az kullanılır çünkü ağırlıklar, problemle ilgili değerlerden ziyade her bir kriterde gözlenen varyasyon düzeyine göre tahsis edilir (Blagojevic vd., 2019).

Bu çalışmada en iyi yakıt karışımının belirlenmesine yönelik seçilen kriterlerin ağırlıklarını belirlemek için Criteria Importance Through Intercriteria Correlation (CRITIC) yöntemi tercih edilmiştir.

CRITIC yöntemi, Diakoulaki vd. (1995) tarafından geliştirilmiş olup kriterlerin önem düzeylerinin elde edilmesinde kullanılan bir yöntemdir. CRITIC yöntemi, kriterler arasındaki zıtlığı esas alan kriterlerin standart sapmalarının ve kriterler arası korelasyonun birlikte kullanıldığı bir ağırlıklandırma yöntemidir. CRITIC yöntemi dört adımdan oluşmaktadır:

Adım 1 - Karar matrisinin oluşturulması ve normalize edilmesi: Oluşturulan karar matrisindeki verilerin her biri farklı birimlerde olduğu için normalize edilmesi gerekmektedir. Normalizasyon sürecinde kriterin maksimizasyon ve minimizasyon yönlü olması dikkate alınarak geliştirilmiş normalizasyon denklemleri kullanılabilmektedir.

Kriter değerlerinin ortak birime dönüştürülmesi amacıyla Denklem (5) ile normalizasyon işlemi gerçekleştirilir. Kriterlerin fayda/maliyet durumuna göre $x_j^{kötü}$ j. kriterine ait en kötü değeri, x_j^{iyi} j. kriterine ait en iyi değeri, r_{ij} , her bir değer normalize edilmiş halini ifade etmektedir.

$$r_{ij} = \frac{x_{ij} - x_j^{kötü}}{x_j^{iyi} - x_j^{kötü}} \quad (5)$$

Adım 2 - Kriterler arası ilişki derecesinin belirlenmesi: Kriterler arasında ilişkiyi tespit etmek amacıyla Denklem (6) ile kriter çiftleri arasındaki korelasyon katsayıları (ρ) hesaplanır.

$$\rho_{jk} = \frac{\sum_{i=1}^m (r_{ij} - \bar{r}_j)(r_{ik} - \bar{r}_k)}{\sqrt{\sum_{i=1}^m (r_{ij} - \bar{r}_j)^2 \sum_{i=1}^m (r_{ik} - \bar{r}_k)^2}} \quad (6)$$

Adım 3 - Toplam bilgi miktarının belirlenmesi: Her bir kriter için toplam bilgi miktarı (c_j), Denklem (7)'deki standart sapma (σ_j) formülü dikkate alınarak Denklem (8)

ile hesaplanır. Standart sapma değeri yüksek ve korelasyon katsayıları nispeten düşük olan kriterler en yüksek bilgiyi barındıran, dolayısıyla en yüksek önem düzeyine sahip kriterler olarak kabul edilmektedir (Madić ve Radovanović, 2015).

$$\sigma_j = \sqrt{\frac{\sum_{i=1}^m (r_{ij} - \bar{r}_j)^2}{m}} \quad (7)$$

$$c_j = \sigma_j \sum_{k=1}^n (1 - \rho_{jk}) \quad (8)$$

Adım 4 - Kriter ağırlıklarının hesaplanması: Denklem (9) yardımıyla j. kriterin ağırlık katsayısını ifade eden kriter ağırlıkları (w_j) hesaplanır. En yüksek değere sahip kriterin en önemli kriter olduğu kabul edilir.

$$w_j = \frac{c_j}{\sum_{k=1}^n (c_k)} \quad (9)$$

En optimum alternatifi seçimi

Dizel motorlarda kullanılabilecek en iyi alternatif yakıt karışımının deney sonuçlarından elde edilen verilere göre seçimi için TOPSIS yöntemi kullanılmıştır. Deney sonuçlarından elde edilen verilere dayanarak dizel motorlar için en iyi alternatif yakıt karışımını seçmek amacıyla TOPSIS yöntemi kullanılmıştır. Hwang ve Yoon tarafından 1981’de geliştirilen TOPSIS, hem kavramsal hem de uygulama açısından basit bir sıralama yöntemidir. Standart TOPSIS yöntemi, pozitif ideal çözüme en kısa mesafeye ve negatif ideal çözüme en uzak mesafeye sahip alternatifleri seçmeyi amaçlar.

Pozitif ideal çözüm, fayda kriterlerini maksimize ederken maliyet kriterlerini minimize eder. Negatif ideal çözüm ise maliyet kriterlerini maksimize edip fayda kriterlerini minimize eder (Behzadian ve ark., 2012). Alternatifler Denklem (10), kriterler ise Denklem (11) ile ifade edilir. Burada mmm, alternatiflerin sayısını, nnn ise kriterlerin sayısını temsil eder.

$$A = a_1, a_2, a_3, \dots, a_m \quad (10)$$

$$K = k_1, k_2, k_3, \dots, k_n \quad (11)$$

Adım 1 - Karar Matrisi Oluşturulması: Alternatiflerin satırları ve kriterlerin sütunları temsil ettiği karar matrisi Denklem (12) ile oluşturulur.

$$x_{ij} = \begin{bmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{m1} & \cdots & x_{mn} \end{bmatrix} \quad (12)$$

Adım 2 - Karar Matrisi Normalizasyonu: Karar matrisi Denklem (13) kullanılarak normalize edilir ve standart bir karar matrisi oluşturulur. Burada r_{ij} normalize edilmiş değerleri ifade eder.

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}} \quad i=1, \dots, m; \quad j=1, \dots, n \quad (13)$$

Adım 3 - Ağırlıklı Standart Karar Matrisi Oluşturulması: Normalize edilmiş karar matrisi, kriter ağırlıkları (w_j) ile çarpılarak Denklem (14) ile ağırlıklı standart karar matrisi elde edilir.

$$V_{ij} = \begin{bmatrix} w_1 r_{11} & \cdots & w_1 r_{1n} \\ \vdots & \ddots & \vdots \\ w_n r_{m1} & \cdots & w_n r_{mn} \end{bmatrix} \quad (14)$$

Adım 4 - Pozitif ve Negatif İdeal Çözümlerin Belirlenmesi: Ağırlıklı standart karar matrisinden, fayda odaklı kriterler için Denklem (15) ile pozitif ideal çözüm (A^+) ve maliyet odaklı kriterler için Denklem (16) ile negatif ideal çözüm (A^-) belirlenir.

$$A^+ = \{(\max_i v_{ij} | j \in J), (\min_i v_{ij} | j \in J')\} \quad i=1, \dots, m$$

$$A^+ = \{v_1^+, v_2^+, \dots, v_n^+\} \quad (15)$$

$$A^- = \{(\min_i v_{ij} | j \in J), (\max_i v_{ij} | j \in J')\} \quad i=1, \dots, m$$

$$A^- = \{v_1^-, v_2^-, \dots, v_n^-\} \quad (16)$$

Adım 5 - İdeal Çözüme Olan Uzaklıkların Hesaplanması: Her bir alternatif (A_i) için pozitif ideal çözüme uzaklık (S_i^+) Denklem (17) ile, negatif ideal çözüme uzaklık (S_i^-) ise Denklem (18) ile hesaplanır.

$$S_i^+ = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^+)^2} \quad i=1, \dots, m \quad (17)$$

$$S_i^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^-)^2} \quad i= 1, \dots, m \quad (18)$$

Adım 6 - İdeal Çözüme Göre Görelî Yakınlık Derecesinin Hesaplanması: Pozitif ideal çözüme (S_i^+) ve negatif ideal çözüme (S_i^-) olan uzaklıklar kullanılarak, her alternatif için pozitif ideal çözüme görelî yakınlık (C_i^+) Denklem (19) ile hesaplanır ve alternatifler sıralanır. Pozitif ideal çözüme en yakın alternatif en uygun olarak belirlenir.

$$C_i^+ = \frac{S_i^-}{S_i^- + S_i^+} \quad 0 \leq C_i^+ \leq 1, \quad i= 1, \dots, m \quad (19)$$

BULGULAR ve HESAPLAMALAR

CRITIC yöntemi hesaplamaları

Çalışmamızda ilk senaryoda kriterlerin ağırlık oranları, kriterlerarası korelasyonların dikkate alındığı ve objektif ağırlıklandırmanın yapıldığı CRITIC yöntemine göre tespit edilmiştir. Karar matrisleri denklem (5)'deki normalizasyon denklemine göre normalize edilmiş, denklem (6) ile kriter çiftleri arasındaki korelasyon katsayıları hesaplanmıştır. Her bir kritere ait standart sapma denklem (7) ile toplam bilgi miktarı ise denklem (8) ile hesaplanarak denklem (9)'a göre hesaplanan kriter ağırlıklılıklarına Tablo 3.1- 3.3'de yer verilmiştir.

Tablo 6. CRITIC yöntemiyle hesaplanan kriter ağırlıklılıkları

	Kriterler					
	K1	K2	K3	K4	K5	K6
	ÖYT	VERİM	CO	HC	CO2	NOX
STD. SAPMA	0,221	0,246	0,208	0,19	0,305	0,272
CJ katsayısı	1,123	1,042	1,081	0,998	1,438	1,93
WJ	0,147	0,136	0,142	0,131	0,188	0,253

TOPSIS yöntemi hesaplamaları

Çalışmamızda dizel motorlarda kullanılabilecek en iyi alternatif yakıt karışımının seçimi TOPSIS yöntemi ile yapılmıştır. CRITIC yöntemiyle belirlenen kriter ağırlıkları dikkate alınarak hesaplamalar yapılmıştır. Normalizasyon karar matrisleri denklem (13)'e göre hesaplanarak 1000 d/d, 1250 d/d ve 1500 d/d için sırasıyla Tablo 3.6'da verilmiştir.

Tablo 7. Normalizasyon matrisi

NORMALLEŞTİRİLMİŞ KARAR MATRİSİ						
	Kriterler					
	K1	K2	K3	K4	K5	K6
Alternatifler	ÖYT	VERİM	CO	HC	CO2	NOX
B0Y2A0D1	0,4010	0,0694	0,5263	0,3333	0,1977	0,9967
B0Y2A0D2	0,6749	0,4026	0,4511	0,5000	0,2712	0,9009
B0Y2A0D3	0,7150	0,4585	0,0752	0,5000	0,2090	0,8480
B0Y2A1D1	0,4150	0,0846	0,4511	0,4167	0,1751	0,9651
B0Y2A1D2	0,6573	0,3787	0,5263	0,3333	0,2825	0,8854
B0Y2A1D3	0,7071	0,4473	0,0752	0,3333	0,2090	0,8412
B0Y2A2D1	0,4089	0,0780	0,3759	0,5000	0,1921	1,0000
B0Y2A2D2	0,5641	0,2584	0,6015	0,4167	0,2147	0,9061
B0Y2A2D3	0,5890	0,2896	0,0000	0,5000	0,2147	0,8647
B0Y3A0D1	0,4740	0,1508	0,6165	0,2500	0,6158	0,5930
B0Y3A0D2	0,7522	0,5121	0,5338	0,3333	0,7006	0,4909
B0Y3A0D3	0,7881	0,5657	0,4361	0,4167	0,7232	0,4291
B0Y3A1D1	0,5103	0,1932	0,6316	0,3333	0,6102	0,5752
B0Y3A1D2	0,6384	0,3535	0,5263	0,2500	0,7006	0,4580
B0Y3A1D3	0,6613	0,3842	0,4511	0,2500	0,7458	0,4269

B0Y3A2D1	0,4168	0,0866	0,6241	0,5000	0,5989	0,5967
B0Y3A2D2	0,7113	0,4532	0,5639	0,4167	0,6949	0,5392
B0Y3A2D3	0,8543	0,6693	0,4511	0,3333	0,6949	0,4449
B0Y4A0D1	0,5470	0,2374	0,7368	0,0000	0,3277	0,4962
B0Y4A0D2	0,8005	0,5846	0,6617	0,2500	0,8249	0,3031
B0Y4A0D3	0,8737	0,7011	0,6015	0,3333	0,9266	0,1877
B0Y4A1D1	0,5782	0,2761	0,7444	0,2500	0,2712	0,4876
B0Y4A1D2	0,7115	0,4535	0,6617	0,1667	0,8136	0,2968
B0Y4A1D3	0,8459	0,6559	0,6015	0,1667	0,9322	0,1818
B0Y4A2D1	0,5142	0,1978	0,7519	0,2500	0,2147	0,4972
B0Y4A2D2	0,8129	0,6037	0,6692	0,1667	0,8079	0,3338
B0Y4A2D3	1,0000	0,9230	0,6015	0,1667	0,9266	0,2138
B3Y2A0D1	0,2347	0,0785	0,8271	0,6667	0,0000	0,9289
B3Y2A0D2	0,4112	0,2711	0,6767	0,7500	0,1864	0,8577
B3Y2A0D3	0,4564	0,3249	0,4887	0,9167	0,1356	0,8062
B3Y2A1D1	0,1554	0,0000	0,8271	0,5000	0,0056	0,9127
B3Y2A1D2	0,4014	0,2597	0,6391	0,5000	0,1808	0,8690
B3Y2A1D3	0,5614	0,4579	0,4887	0,5833	0,1299	0,7637
B3Y2A2D1	0,1837	0,0274	0,8421	0,5000	0,0621	0,9274
B3Y2A2D2	0,3648	0,2179	0,5639	0,5000	0,2147	0,8674

B3Y2A2D3	0,5574	0,4527	0,4511	0,5833	0,1356	0,7606
B3Y3A0D1	0,2683	0,1131	0,8872	0,5833	0,6780	0,5526
B3Y3A0D2	0,6763	0,6179	0,7218	0,6667	0,7571	0,4438
B3Y3A0D3	0,6672	0,6046	0,6090	0,7500	0,7910	0,3495
B3Y3A1D1	0,3708	0,2246	0,9023	0,5000	0,6836	0,5496
B3Y3A1D2	0,5469	0,4389	0,7143	0,4167	0,7514	0,5303
B3Y3A1D3	0,6813	0,6253	0,6090	0,5000	0,7797	0,3613
B3Y3A2D1	0,2571	0,1015	0,8872	0,4167	0,6949	0,5807
B3Y3A2D2	0,4631	0,3330	0,7068	0,3333	0,7627	0,4257
B3Y3A2D3	0,6714	0,6107	0,6015	0,5000	0,7853	0,4055
B3Y4A0D1	0,3035	0,1505	0,9248	0,5000	0,2825	0,4122
B3Y4A0D2	0,7406	0,7150	0,8647	0,5833	0,9718	0,2347
B3Y4A0D3	0,7662	0,7552	0,8120	0,6667	0,6667	0,0563
B3Y4A1D1	0,4515	0,3190	0,9323	0,4167	0,2881	0,3939
B3Y4A1D2	0,6999	0,6529	0,8421	0,4167	0,9718	0,0185
B3Y4A1D3	0,6932	0,6429	0,7895	0,4167	0,6610	0,1188
B3Y4A2D1	0,3040	0,1510	0,9398	0,4167	0,2938	0,3865
B3Y4A2D2	0,5842	0,4884	0,8271	0,4167	0,9831	0,3913
B3Y4A2D3	0,8957	0,9744	0,8271	0,3333	0,6949	0,1182
B4Y2A0D1	0,1707	0,2148	0,8872	0,7500	0,1017	0,9170

B4Y2A0D2	0,2634	0,3151	0,7970	0,8333	0,3107	0,8199
B4Y2A0D3	0,2431	0,2926	0,7519	1,0000	0,2203	0,7766
B4Y2A1D1	0,7597	1,0000	0,8872	0,5833	0,1186	0,9127
B4Y2A1D2	0,2068	0,2530	0,8271	0,6667	0,2825	0,8066
B4Y2A1D3	0,1166	0,1594	0,7143	0,7500	0,2260	0,7735
B4Y2A2D1	0,0000	0,0469	0,9173	0,6667	0,0904	0,9195
B4Y2A2D2	0,1051	0,1479	0,7895	0,6667	0,2599	0,8274
B4Y2A2D3	0,0808	0,1239	0,7519	0,6667	0,2203	0,7850
B4Y3A0D1	0,2244	0,2721	0,9398	0,6667	0,6893	0,5358
B4Y3A0D2	0,4354	0,5213	0,8045	0,7500	0,7853	0,4196
B4Y3A0D3	0,4941	0,5983	0,7669	0,9167	0,8475	0,3390
B4Y3A1D1	0,6668	0,8486	0,9774	0,5000	0,6723	0,5282
B4Y3A1D2	0,4781	0,5769	0,7895	0,5000	0,7853	0,6456
B4Y3A1D3	0,4217	0,5038	0,7594	0,5833	0,8475	0,3397
B4Y3A2D1	0,1948	0,2402	0,9023	0,5000	0,7006	0,5434
B4Y3A2D2	0,3851	0,4581	0,8271	0,5000	0,7797	0,6366
B4Y3A2D3	0,3869	0,4603	0,7744	0,6667	0,8475	0,3798
B4Y4A0D1	0,2683	0,3206	0,9925	0,5833	0,2768	0,3739
B4Y4A0D2	0,6065	0,7569	0,9774	0,7500	0,7684	0,2263
B4Y4A0D3	0,6309	0,7935	0,9023	0,8333	0,9887	0,0053

B4Y4A1D1	0,6999	0,9012	0,9925	0,5000	0,2712	0,3777
B4Y4A1D2	0,6098	0,7618	0,9398	0,5000	0,7571	0,5998
B4Y4A1D3	0,6084	0,7597	0,9023	0,5833	1,0000	0,0000
B4Y4A2D1	0,2797	0,3335	1,0000	0,5000	0,2655	0,3653
B4Y4A2D2	0,3115	0,3700	0,9774	0,5000	0,7684	0,6765
B4Y4A2D3	0,4631	0,5571	0,9023	0,5833	0,9944	0,0164
STD. SAPMA	0,221155025	0,246704757	0,208817123	0,190485491	0,305419618	0,272608065

AĞIRLIKLI NORMALLEŞTİRİLMİŞ KARAR MATRİSİ										
Alternatifler	Kriterler									
	K1	K2	K3	K4	K5	K6				
	ÖYT	VERİM	CO	HC	CO2	NOX	S+	S-	C	Sıralama
B0Y2A0D1	0,0592	0,0095	0,0748	0,0437	0,0374	0,2526	0,337651	0,146545	0,302656	71
B0Y2A0D2	0,0996	0,0551	0,0641	0,0656	0,0512	0,2283	0,309998	0,137745	0,307643	69
B0Y2A0D3	0,1055	0,0627	0,0107	0,0656	0,0395	0,2149	0,299264	0,174102	0,367795	57
B0Y2A1D1	0,0613	0,0116	0,0641	0,0546	0,0331	0,2446	0,332636	0,143857	0,301908	72
B0Y2A1D2	0,0970	0,0518	0,0748	0,0437	0,0534	0,2244	0,304745	0,145288	0,322838	64
B0Y2A1D3	0,1044	0,0612	0,0107	0,0437	0,0395	0,2132	0,293976	0,183576	0,384411	55
B0Y2A2D1	0,0604	0,0107	0,0534	0,0656	0,0363	0,2534	0,337997	0,145608	0,301089	73

B0Y2A2D2	0,0833	0,0354	0,0855	0,0546	0,0406	0,2297	0,319792	0,129066	0,287544	77
B0Y2A2D3	0,0869	0,0396	0,0000	0,0656	0,0406	0,2192	0,302239	0,180426	0,373812	56
B0Y3A0D1	0,0700	0,0206	0,0876	0,0328	0,1163	0,1503	0,234519	0,208014	0,470052	39
B0Y3A0D2	0,1110	0,0701	0,0758	0,0437	0,1323	0,1244	0,207661	0,229004	0,524439	29
B0Y3A0D3	0,1163	0,0774	0,0620	0,0546	0,1366	0,1088	0,196086	0,242567	0,552981	25
B0Y3A1D1	0,0753	0,0264	0,0897	0,0437	0,1153	0,1458	0,233447	0,202941	0,465047	42
B0Y3A1D2	0,0942	0,0484	0,0748	0,0328	0,1323	0,1161	0,200104	0,236173	0,541338	27
B0Y3A1D3	0,0976	0,0526	0,0641	0,0328	0,1409	0,1082	0,189271	0,248922	0,568065	18
B0Y3A2D1	0,0615	0,0118	0,0887	0,0656	0,1131	0,1512	0,245313	0,194807	0,442623	51
B0Y3A2D2	0,1050	0,0620	0,0801	0,0546	0,1313	0,1367	0,219133	0,215002	0,495243	32
B0Y3A2D3	0,1261	0,0916	0,0641	0,0437	0,1313	0,1128	0,200002	0,244134	0,549684	26
B0Y4A0D1	0,0807	0,0325	0,1047	0,0000	0,0619	0,1258	0,245585	0,210378	0,461392	45
B0Y4A0D2	0,1181	0,0800	0,0940	0,0328	0,1558	0,0768	0,18466	0,273356	0,596826	13
B0Y4A0D3	0,1290	0,0959	0,0855	0,0437	0,1750	0,0476	0,173124	0,305652	0,638403	5
B0Y4A1D1	0,0853	0,0378	0,1057	0,0328	0,0512	0,1236	0,252153	0,189173	0,428647	53
B0Y4A1D2	0,1050	0,0621	0,0940	0,0219	0,1537	0,0752	0,181195	0,274417	0,602304	10
B0Y4A1D3	0,1249	0,0898	0,0855	0,0219	0,1761	0,0461	0,166956	0,312622	0,651869	4
B0Y4A2D1	0,0759	0,0271	0,1068	0,0328	0,0406	0,1260	0,261119	0,186206	0,416266	54
B0Y4A2D2	0,1200	0,0826	0,0951	0,0219	0,1526	0,0846	0,187954	0,271177	0,590631	14
B0Y4A2D3	0,1476	0,1263	0,0855	0,0219	0,1750	0,0542	0,181123	0,318495	0,637477	6

B3Y2A0D1	0,0346	0,0107	0,1175	0,0874	0,0000	0,2354	0,360085	0,125347	0,258218	81
B3Y2A0D2	0,0607	0,0371	0,0961	0,0984	0,0352	0,2174	0,321603	0,121054	0,273472	80
B3Y2A0D3	0,0674	0,0445	0,0694	0,1202	0,0256	0,2043	0,317428	0,129916	0,290416	75
B3Y2A1D1	0,0229	0,0000	0,1175	0,0656	0,0011	0,2313	0,355169	0,144686	0,289455	76
B3Y2A1D2	0,0592	0,0355	0,0908	0,0656	0,0342	0,2203	0,314288	0,135149	0,300707	74
B3Y2A1D3	0,0829	0,0627	0,0694	0,0765	0,0245	0,1936	0,295838	0,143417	0,326501	63
B3Y2A2D1	0,0271	0,0038	0,1196	0,0656	0,0117	0,2350	0,351701	0,140751	0,285817	78
B3Y2A2D2	0,0538	0,0298	0,0801	0,0656	0,0406	0,2198	0,308878	0,143495	0,317205	65
B3Y2A2D3	0,0823	0,0619	0,0641	0,0765	0,0256	0,1928	0,293536	0,146656	0,333164	61
B3Y3A0D1	0,0396	0,0155	0,1260	0,0765	0,1281	0,1401	0,247693	0,210728	0,459682	46
B3Y3A0D2	0,0998	0,0846	0,1025	0,0874	0,1430	0,1125	0,213581	0,230708	0,519274	30
B3Y3A0D3	0,0985	0,0827	0,0865	0,0984	0,1494	0,0886	0,19797	0,250842	0,558903	22
B3Y3A1D1	0,0547	0,0307	0,1282	0,0656	0,1291	0,1393	0,24074	0,209217	0,464971	43
B3Y3A1D2	0,0807	0,0601	0,1015	0,0546	0,1419	0,1344	0,214387	0,223385	0,510277	31
B3Y3A1D3	0,1006	0,0856	0,0865	0,0656	0,1473	0,0916	0,186131	0,254588	0,577665	17
B3Y3A2D1	0,0379	0,0139	0,1260	0,0546	0,1313	0,1472	0,245796	0,216449	0,468256	40
B3Y3A2D2	0,0683	0,0456	0,1004	0,0437	0,1441	0,1079	0,196583	0,244298	0,554113	24
B3Y3A2D3	0,0991	0,0836	0,0855	0,0656	0,1483	0,1028	0,190955	0,248102	0,565079	21
B3Y4A0D1	0,0448	0,0206	0,1314	0,0656	0,0534	0,1045	0,257617	0,201122	0,438424	52
B3Y4A0D2	0,1093	0,0978	0,1228	0,0765	0,1836	0,0595	0,194889	0,292758	0,600348	11

B3Y4A0D3	0,1131	0,1033	0,1154	0,0874	0,1259	0,0143	0,197568	0,295903	0,599636	12
B3Y4A1D1	0,0666	0,0436	0,1325	0,0546	0,0544	0,0998	0,248406	0,202396	0,448969	50
B3Y4A1D2	0,1033	0,0893	0,1196	0,0546	0,1836	0,0047	0,174002	0,334474	0,657797	2
B3Y4A1D3	0,1023	0,0880	0,1122	0,0546	0,1249	0,0301	0,182834	0,286382	0,610341	9
B3Y4A2D1	0,0449	0,0207	0,1335	0,0546	0,0555	0,0980	0,25243	0,210141	0,45429	49
B3Y4A2D2	0,0862	0,0668	0,1175	0,0546	0,1857	0,0992	0,197414	0,270141	0,577774	16
B3Y4A2D3	0,1322	0,1333	0,1175	0,0437	0,1313	0,0300	0,193453	0,305683	0,612425	8
B4Y2A0D1	0,0252	0,0294	0,1260	0,0984	0,0192	0,2324	0,3472	0,134127	0,27866	79
B4Y2A0D2	0,0389	0,0431	0,1132	0,1093	0,0587	0,2078	0,308535	0,143242	0,317064	66
B4Y2A0D3	0,0359	0,0400	0,1068	0,1311	0,0416	0,1968	0,315756	0,142346	0,31073	68
B4Y2A1D1	0,1121	0,1368	0,1260	0,0765	0,0224	0,2313	0,339916	0,155622	0,314046	67
B4Y2A1D2	0,0305	0,0346	0,1175	0,0874	0,0534	0,2044	0,304942	0,150571	0,330552	62
B4Y2A1D3	0,0172	0,0218	0,1015	0,0984	0,0427	0,1961	0,305475	0,15911	0,342478	59
B4Y2A2D1	0,0000	0,0064	0,1303	0,0874	0,0171	0,2331	0,354223	0,156787	0,306818	70
B4Y2A2D2	0,0155	0,0202	0,1122	0,0874	0,0491	0,2097	0,312375	0,158064	0,335992	60
B4Y2A2D3	0,0119	0,0170	0,1068	0,0874	0,0416	0,1990	0,307967	0,162941	0,346014	58
B4Y3A0D1	0,0331	0,0372	0,1335	0,0874	0,1302	0,1358	0,241611	0,21742	0,47365	38
B4Y3A0D2	0,0643	0,0713	0,1143	0,0984	0,1483	0,1063	0,210029	0,239846	0,53314	28
B4Y3A0D3	0,0729	0,0819	0,1090	0,1202	0,1601	0,0859	0,207058	0,259215	0,555929	23
B4Y3A1D1	0,0984	0,1161	0,1389	0,0656	0,1270	0,1339	0,235479	0,225041	0,488668	34

B4Y3A1D2	0,0706	0,0789	0,1122	0,0656	0,1483	0,1636	0,231579	0,217797	0,484666	35
B4Y3A1D3	0,0622	0,0689	0,1079	0,0765	0,1601	0,0861	0,184989	0,264242	0,58821	15
B4Y3A2D1	0,0287	0,0329	0,1282	0,0656	0,1323	0,1377	0,233523	0,224952	0,490653	33
B4Y3A2D2	0,0568	0,0627	0,1175	0,0656	0,1473	0,1613	0,233667	0,217354	0,481915	37
B4Y3A2D3	0,0571	0,0630	0,1100	0,0874	0,1601	0,0963	0,196374	0,255785	0,565697	20
B4Y4A0D1	0,0396	0,0439	0,1410	0,0765	0,0523	0,0948	0,252163	0,21093	0,455481	47
B4Y4A0D2	0,0895	0,1036	0,1389	0,0984	0,1451	0,0574	0,208041	0,273327	0,567813	19
B4Y4A0D3	0,0931	0,1086	0,1282	0,1093	0,1868	0,0013	0,194551	0,337445	0,634299	7
B4Y4A1D1	0,1033	0,1233	0,1410	0,0656	0,0512	0,0957	0,251306	0,221287	0,46824	41
B4Y4A1D2	0,0900	0,1042	0,1335	0,0656	0,1430	0,1520	0,237716	0,222026	0,482937	36
B4Y4A1D3	0,0898	0,1040	0,1282	0,0765	0,1889	0,0000	0,177276	0,342415	0,658882	1
B4Y4A2D1	0,0413	0,0456	0,1421	0,0656	0,0502	0,0926	0,249652	0,214664	0,462323	44
B4Y4A2D2	0,0460	0,0506	0,1389	0,0656	0,1451	0,1715	0,253856	0,212106	0,4552	48
B4Y4A2D3	0,0683	0,0762	0,1282	0,0765	0,1878	0,0041	0,175059	0,335716	0,657268	3
A+	0,0000	0,1368	0,0000	0,0000	0,1889	0,0000				
A-	0,1476	0,0000	0,1421	0,1311	0,0000	0,2534				

SONUÇ VE ÖNERİLER

Çalışmada, TÜBİTAK RUTE tesislerinde bulunan tek silindirli 1,12 litre hacimli, ön püskürtmeli ve direkt enjeksiyonlu yüksek basınçlı enjeksiyon sistemine sahip bir dizel motor ve test ünitesinde biyodizel-dizel yakıt karışımları kullanılarak motor testleri gerçekleştirilmiştir. Motor testleri için ticari dizel ile saf biyodizel yakıt üç farklı hacimsel oranda (%0, %50 ve %100) karıştırılarak sırasıyla B0, B50 ve B100 yakıtları hazırlanmıştır. Testler, 1000 d/d, 1250 d/d ve 1500 d/d olmak üzere üç farklı motor devri ile %25, %50 ve %75 olmak üzere üç farklı motor yükünde gerçekleştirilmiştir.

Motorun çalıştırılması esnasında yakıtların motor performansı, egzoz emisyonu ve yanma karakteristikleri bütüncül bir yaklaşımla en iyi yakıtın seçimi hedeflenmiştir. Zira biyodizel karışımının doğru seçimi ile emisyonlar, motor performansı ve yanma karakteristikleri iyileştirilebilmektedir.

Yenilenebilir yakıtlarla çalışan dizel motorların performans, yanma ve emisyon özelliklerini incelemek için maliyetli ve zaman alıcı deneyler yapmaktansa modelleme kullanmak daha verimli olacaktır.

Bu çalışmanın sonucunda en iyi yakıt ve çalışma koşulunun %75 motor yükü, 1500 d/d motor hızında ve +2 püskürtme avansında B100 yakıtı olduğu tespit edilmiştir.

TEŞEKKÜR

Çalışmanın deney aşamalarında imkânlarını seferber eden bilimin ve bilim insanının destekçisi olan TÜBİTAK'a ve personeline teşekkür ederim. Bu araştırma, kamu, ticari veya kar amacı gütmeyen sektörlerdeki herhangi bir fon kuruluşundan bir maddi destek almamıştır.

KAYNAKÇA

- Abdolvahitoglu, A., Kilic, M., (2022) A new approach for selecting the most suitable oilseed for biodiesel production; the integrated AHP-TOPSIS method. *Ain Shams Eng. J.* 13, 101604. <https://doi.org/10.1016/j.asej.2021.10.002>.
- Agar, D. A., Hansen, P., Rudolfso, M., Blagojević, B. (2023) Combining behavioural TOPSIS and six multi-criteria weighting methods to rank biomass fuel pellets for energy use in Sweden. *Energy Reports*, 10, 706-718.
- Anandavelu, T., Rajkumar, S., Thangarasu, V. (2023) Dual fuel combustion of 1-hexanol with diesel and biodiesel fuels in a diesel engine: An experimental investigation and multi criteria optimization using artificial neural network and TOPSIS algorithm. *Fuel*, 338, 127318.
- Arora, R., Kaushik, S.C., Arora, R. (2015) Multi-objective and multi-parameter optimization of two-stage thermoelectric generator in electrically series and parallel configurations through NSGA-II. *Energy*, 91, 242-254.
- Blagojevic, B., Jonsson, R., Björheden, R., Nordström, E.M., Lindroos, O. (2019) Multi-criteria decision analysis (MCDA) in forest operations – an introductory review. *Croat. J. Eng.* 40, 191–205.
- Chaitanya, G.S., Kumar, M. R., Deivanathan, R. (2020) Multi criteria decision making approach for selection of biodiesel blend using AHP-TOPSIS analysis, *Journal of Physics: Conference Series*, 1716, 012022.
- Debbarma, B., Chakraborti, P., Bose, P.K., Deb, M., Banerjee, R. (2017) Exploration of PROMETHEE II and VIKOR methodology in a MCDM approach for ascertaining the optimal performance-emission trade-off vantage in a hydrogen-biohol dual fuel endeavour. *Fuel* 210, 922–935. <https://doi.org/10.1016/j.fuel.2017.08.016>.
- Diakoulaki, D., Mavrotas, G., Papayannakis, L. (1995). Determining Objective Weights In Multiple Criteria Problems: The Critic Method. *Computers & Operations Research*, 22(7), 763-770.
- Durairaj S., Sekar K.S., Ilankumaran M., RamManohar M., Thyalan B., Yuvaraj E., Ramesh S. (2014) Multi-Criteria Decision Model For Biodiesel Selection In An Electrical Power Generator Based On Fuzzy-Gra-Topsis. *International Journal of Research in Engineering and Technology*, 3(11), 226-233.
- Erdoğan, S., Balki, M. K., Aydın, S., Sayin, C. (2019) The best fuel selection with hybrid multiple-criteria decision making approaches in a CI engine fueled with their blends and pure biodiesels produced from different sources. *Renewable Energy*, 134, 653-668.
- Kishita, Y., Ohishi, Y., Uwasu, M., Kuroda, M., Takeda, H., Hara, K. (2016) Evaluating the life cycle CO₂ emissions and costs of thermoelectric generators for passenger automobiles: a scenario analysis. *Journal of Cleaner Production*, 126, 607-619.
- Kumar K.A., Kumar P.S., Madhusudanan S., Pasupathy V., Vignesh P.R., Sankaranarayanan A.R. (2017) A simplified model for evaluating best biodiesel production method: Fuzzy analytic hierarchy process approach. *Sustainable Materials and Technologies*, 12, 18-22.
- Liang, X., Sun, X., Shu, G., Sun, K., Wang, X., Wang, X. (2013) Using the analytic network process (ANP) to determine method of waste energy recovery from engine. *Energy Conversion and Management*, 66, 304–311.
- Madić, M., Radovanović, M., Petković, D. (2015) Non-conventional machining processes selection using multi-objective optimization on the basis of ratio analysis method. *Journal of Engineering Science and Technology*, (10)11, 1441-1452.

- Majji, D., Abrar, I., Dutta, A. (2023) Multi-criteria decision-making framework for selection of surfactant-free microemulsion fuels as a sustainable diesel alternative. *Computers & Chemical Engineering Journal*, 177, 108366.
- Meng, J.H., Wu, H.C., Wang, L., Lu, G., Zhang, K., Yan, W.M. (2020) Thermal management of a flexible controlled thermoelectric energy conversion-utilization system using a multi-objective optimization. *Applied Thermal Engineering*, 179, 115721.
- Meng, J.H., Liu, Y., Zhu, X.H., Yang, Z.J., Zhang, K., Lu, G., (2022) Performance enhancement for exhaust thermoelectric power generation system by using porous pin fins based on a fully automatic optimization method. *Energy Conversion and Management*, 273, 116404.
- Narayanamoorthy, S., Ramya, L., Kalaiselvan, S., Kureethara, J. V., Kang, D. (2021) Use of DEMATEL and COPRAS method to select best alternative fuel for control of impact of greenhouse gas emissions. *Socio-Economic Planning Sciences*, 76, 100996.
- Nwokoagbara E., Olaleye A.K., Wang M. (2015) Biodiesel from microalgae: The use of multi-criteria decision analysis for strain selection. *Fuel*, 159, 241–249.
- Okolie, J.a., Awotoye, D., Tabat, M. E., Okoye, P. U., Epelle, E. I., Ogbaga, C. C., Güleç, F., Oboirien, B. (2023) Multi-criteria decision analysis for the evaluation and screening of sustainable aviation fuel production pathways. *iScience*, 26, 6, 106944.
- Sakthivel, G., Ilangkumaran, M., Gaikwad, A. (2015) A hybrid multi-criteria decision modeling approach for the best biodiesel blend selection based on ANP-TOPSIS analysis. *Ain Shams Engineering Journal*, 6(1), 239-256.
- Özbek, A., Erol, E., (2016) COPRAS ve MOORA yöntemlerinin depo yeri seçim problemine uygulanması, *Ekonomi İşletme Siyaset ve Uluslararası İlişkiler Dergisi*, 2, 1, 23-42.
- Pamucar, D., Stević, Ž., Sremac, S. (2018) A new model for determining weight coefficients of criteria in MCDM models: Full consistency method (FUCOM). *Symmetry*, 10(9), 393. <https://doi.org/10.3390/sym10090393>.
- Swathi, A., Seela, C. (2020) Nano emulsified diesel - biodiesel blend selection through a MCDM technique. *IOP Conference Series: Materials Science and Engineering*, 988, 012012.
- Türkiye Sanayi Sevk ve İdare Enstitüsü (TÜSSİDE), 2020, Çok Kriterli Karar Verme Teknikleri, <http://tusside.tubitak.gov.tr/tr/yontemlerimiz/Cok-Kriterli-Karar-Verme-Teknikleri>, erişim tarihi: 12.08.2023.
- Söyler, H. (2023). Biyoyakıt üretiminde yapay zeka uygulaması. *Mühendislikte yapay zeka araştırmaları* (pp. 23–36). Nobel yayınevi.
- Söyler, Hüseyin, Mustafa Kemal Balki, and Cenk Sayin. 2023. "Determination of OptimumParameters for Esterification in High Free Fatty Acid Olive Oil and Ultrasound-Assisted Biodiesel Production." *Biomass Conversion and Biorefinery*. doi: 10.1007/s13399-021-01976-y.
- Söyler, Hüseyin, Mustafa Kemal Balki, and Cenk Sayin. 2024. "The Impact of Injection Timing and Pressure on a CRDI Engine's Combustion Characteristics." *Journal of Engineering Research*. doi: 10.1016/J.JER.2024.02.015.
- Yusuf, A.A., Dankwa Ampah, J., Soudagar, M.E.M., Veza, I., Kingsley, U., Afrane, S., Jin, C., Liu, H., Elfakhany, A., Buyondo, K.A., (2022) Effects of hybrid nanoparticle additives in n-butanol/waste plastic oil/diesel blends on combustion, particulate and gaseous emissions from diesel engine evaluated with entropy-weighted PROMETHEE II and TOPSIS: Environmental and health risks of plastic wa. *Energy Conversation Management*, 264, 115758. <https://doi.org/10.1016/j.enconman.2022.115758>.

BÖLÜM 5

YAYILMA MODELLERİYLE EL ALETLERİNİN GÖRSEL TEMSİLİ

İsmail Umut DURAN
Öğr. Gör., Sinop Üniversitesi, iduran@sinop.edu.tr
 0000-0002-7785-8326

Yapay zeka (YZ), günümüzde hem akademik hem de endüstriyel dünyada çok önemli değişimlere yol açan bir disiplin olarak öne çıkmaktadır. İnsanların öğrenme, problem çözme ve karar verme süreçlerini taklit edebilen algoritmalar, çağımızın en karmaşık sorunlarına çözüm üretme potansiyeline sahiptir. Yapay zeka teknolojileri, sağlık, eğitim, ulaşım, üretim ve tasarım gibi pek çok sektörde etkisini hissettirmekte ve toplumsal dönüşümlerin öncüsü olmaktadır (Russell & Norvig, 2021).

YZ'nin kökenleri, 20. yüzyılın ortalarında bilgisayar biliminin gelişmesiyle birlikte atılmıştır. 1956 yılında Dartmouth Konferansı'nda, bilim insanları "makinelere insan gibi düşünebilmesi" fikrini ilk kez sistematik bir şekilde tartışmışlardır (McCarthy vd., 2006). Bu konferans, modern yapay zeka araştırmalarının başlangıcı olarak kabul edilmektedir. Alan Turing'in "Turing Testi" ile makinelerin zekasını ölçme önerisi, bu disiplinin teorik çerçevesini şekillendiren önemli bir kilometre taşıdır (Turing, 1950).

YZ'nin ilk yıllarındaki çalışmalar, sembolik sistemlere ve mantıksal çıkarımlara dayanmaktadır. Ancak bu yaklaşımlar, büyük ölçekli verilerin analiz edilmesinde ve karmaşık problemlerin çözülmesinde yetersiz kalmaktadır. Bu eksiklik, veri odaklı ve öğrenme temelli yaklaşımlara olan ihtiyacı artırmış ve böylece yapay sinir ağları gibi daha dinamik modellerin geliştirilmesine yol açmıştır (Goodfellow vd., 2016).

YZ'nin temellerinden biri olan Perceptron, 1958 yılında Frank Rosenblatt tarafından geliştirilmiştir. Perceptron, bir biyolojik nöronun işleyişini matematiksel olarak modelleyen ve temel olarak sınıflandırma problemlerini çözmek için tasarlanmış bir yapıdır (Rosenblatt, 1958). Tek katmanlı perceptronlar, doğrusal olarak ayrılabilen problemleri çözmede başarılı olsa da, daha karmaşık problemlerde yetersiz kalmıştır. Bu

durum, çok katmanlı yapay sinir ağlarının (Multi-Layer Perceptrons, MLP) geliştirilmesine öncülük etmiştir.

Yapay sinir ağları (ANN), biyolojik sinir sistemlerinden ilham alınarak tasarlanmış ve paralel işlemeyi temel alan öğrenme modelleridir. Bu ağlar, birden fazla katman ve nöron kullanarak doğrusal olmayan ilişkileri modelleme kapasitesine sahiptir (LeCun vd., 2015). Girdi katmanı, gizli katmanlar ve çıktı katmanlarından oluşan bu yapı, karmaşık veri kümeleri üzerinde yüksek doğrulukla çalışabilmektedir. Özellikle geriye yayılım algoritması (Backpropagation), yapay sinir ağlarının eğitiminde bir dönüm noktası olmuştur (Rumelhart vd., 1986).

Son yıllarda yapay zeka (YZ) araştırmalarında yaşanan gelişmeler, insan kapasitesini aşan düzeyde öğrenme ve problem çözme yeteneğine sahip algoritmaların doğmasına olanak sağlamıştır. Bu gelişimin merkezinde, büyük veri setlerini ve hesaplama gücünü etkin bir şekilde kullanabilen derin öğrenme (Deep Learning) modelleri bulunmaktadır. Derin öğrenme, geleneksel makine öğrenmesi algoritmalarından farklı olarak, çok katmanlı yapılar üzerinden yüksek seviyeli özelliklerin öğrenilmesini sağlar (LeCun vd., 2015).

Derin öğrenme, yapay sinir ağlarının evrimi ile ortaya çıkmıştır. Ancak o dönemde sınırlı veri ve işlemci gücü nedeniyle derin öğrenme modelleri geniş çapta uygulanamamıştır. 2000'li yıllarda büyük veri setlerinin erişilebilirliği ve grafik işlem birimlerinin (GPU) hesaplama kapasitelerinin artması, derin öğrenme modellerinin yeniden popülerlik kazanmasına yol açmıştır (Krizhevsky vd., 2012).

2014 yılında Ian Goodfellow ve ekibi tarafından tanıtılan Üretken Çekişmeli Ağlar (Generative Adversarial Networks, GAN), üretken modellerde bir dönüm noktası olmuştur (Goodfellow vd., 2014). GAN'lar, iki ağın (üretici ve ayrımcı) birbirine karşı çalıştığı bir sistem üzerinde öğrenme gerçekleştirilmektedir. Bu yaklaşım, gerçekçi görüntüler ve veri setleri üretmede önemli bir adım olarak nitelendirilmektedir.

Yayılma modelleri, 2020'lerde YZ topluluğunda öne çıkan bir başka üretken model türüdür. Bu modeller, bir veriyi iteratif olarak gürültüyle bozan ve daha sonra bu gürültüyü tersine çevirerek orijinal veri ya da türetilmiş veri üreten bir süreç üzerine kuruludur (Sohl-Dickstein vd., 2015). Özellikle Latent Diffusion Models (Gizli Yayılma Modelleri), daha az hesaplama gücü gerektirerek yüksek çözünürlüklü görsellerin oluşturulmasını sağlamıştır (Rombach vd., 2022).

Yapay zekanın tarihsel gelişimi, insan zekasını taklit etmeye yönelik basit girişimlerden, karmaşık modeller ve algoritmalar geliştirmeye kadar uzanan bir gelişime sahiptir. Bu süreç, hem teorik hem de pratik anlamda büyük yenilikler getirmiştir. Yapay sinir ağlarının ve öğrenme modellerinin gelişimi, YZ'nin sadece bilimsel bir merak olmaktan çıkarak, hayatın her alanında vazgeçilmez bir araç haline gelmesini sağlamıştır.

Yapay zekanın görsel oluşturma alanındaki başarısı, birçok sektörde yaratıcı süreçleri desteklemek amacıyla kullanılmaktadır. Özellikle yayılma modelleri, kullanıcıların basit metin girdileriyle görsel içerik üretmesine olanak tanıyarak tasarım süreçlerini hızlandırmıştır (Nichol & Dhariwal, 2021). Bu gelişmeler, sanat, medya ve eğlence sektörlerinde yeni olanaklar sunarken, eğitici ve simülatif içeriklerin oluşturulmasını da kolaylaştırmaktadır.

Günümüzde metin girdileri ile görsel içerik üretme uygulamaları genellikle günlük belirli bir kullanım limitine kadar ücretsiz ya da tamamen ücretli olarak sunulmaktadır. Bu durum, açık kaynaklı üretken çekişmeli ağlar (GAN) ve yayılma modellerinin (diffusion models) ortaya çıkmasına zemin hazırlamıştır. Bu modellerin tüm ağırlıkları ile açık kaynak olarak sunulması, yerel cihazlarda çalıştırılabilmesi ve kullanıcılar tarafından yeniden eğitilebilmesi, önemli avantajlar sağlamaktadır. Ancak, her ne kadar bu modeller büyük ölçekli veri setleri üzerinde eğitilmiş olsalar da, bazı özel alanlarda görsel içerik üretme konusunda yeterli performansı gösterememektedir.

Bu çalışmada, açık bir yayılma modeli olan Stable Diffusion'ın, günlük hayatta kullanılan pense, tornavida gibi el aletlerinin görsellerini oluşturabilmesi amacıyla yeniden eğitimi gerçekleştirilmiştir. Modelin, belirli bir görev alanında doğruluğunu artırmak için özel veri setleri ile yeniden eğitilmesi süreci ele alınmıştır.

YAYILMA MODELLERİ

Yayılma modelleri yapay zeka ve makine öğreniminde kullanılan, özellikle üretken modellerin bir türü olan, veri dağılımını öğrenme ve yeniden üretme yeteneğine sahip bir yöntemdir. Bu modeller, bir veri setindeki öğeleri adım adım bozarak ve ardından bu bozma işlemini tersine çevirerek veri setinin dağılımını modellemeyi amaçlar. Yayılma modelleri, son yıllarda metin tabanlı görsel oluşturma, yüksek çözünürlüklü görüntü üretimi ve diğer yaratıcı yapay zeka uygulamalarında önemli başarılar elde etmiştir (Hovd., 2020).

Yayılma modelleri, aşağıdaki amaçlar doğrultusunda yaygın olarak kullanılmaktadır:

a- Görsel İçerik Üretimi

Metin tabanlı görsel oluşturma (text-to-image generation), Stable Diffusion ve DALL·E gibi sistemlerle yayılma modellerinin popüler bir uygulama alanıdır. Bu modeller, kullanıcı tarafından sağlanan metin girdilerini estetik açıdan zengin ve anlamlı görsellere dönüştürebilmektedir (Ramesh vd.,2022)

b- Video ve Animasyon Üretimi

Yayılma modelleri, kare kare video üretiminde veya animasyonlarda sahnelerin oluşturulmasında kullanılmaktadır. Günümüzde bu amaçla çeşitli kısa film ve kısa videolar oluşturulabilmektedir (Ho vd., 2022)

c- Veri Tamamlama ve Restorasyon

Eksik veya hasarlı verilerin tamamlanması (örneğin, görüntü onarımı) bu modellerin güçlü olduğu bir diğer alandır. Siyah-beyaz resimlerin renklendirilmesi ve görselde yer alan çeşitli unsurların kaldırılarak arka planın orjinal görselin yapısına uygun bir şekilde yeniden oluşturulması, yayılma modellerinin bu amaçla kullanımına örnektir (Lugmayr vd., 2022)

d- Sanat ve Tasarım

Yayılma modelleri, sanat eserlerinin yaratılmasında, dijital tasarımda ve konsept geliştirme süreçlerinde kullanılmaktadır (Crowson vd.,2022).

e- Medikal Görüntüleme

Medikal görüntülerin sentezi ve yeniden yapılandırılması gibi alanlarda kullanılarak, tıbbi araştırmalara ve teşhise katkı sağlamaktadır (Mok vd., 2023).

f- Veri Artırma

Yayılma modelleri, veri setlerini genişletmek ve çeşitlendirmek için kullanılabilmektedir. Bu, özellikle sınırlı veri setleriyle çalışan uygulamalarda daha yüksek bir performans sağlayabilmektedir (Baranchuk vd., 2021).

YAYILMA MODELLERİNİN ÇALIŞMA PRENSİBİ

Yayılma modelleri, bir veri setindeki karmaşık dağılımları modellemek amacıyla tasarlanmış üretken modellerdir. Bu modeller, veri öğelerini iteratif bir şekilde bozarak (forward process) ve bu bozulmayı tersine çevirerek (reverse process) veri dağılımını öğrenir. Özellikle Denoising Diffusion Probabilistic Models (DDPM) gibi popüler yaklaşımlar, bu prensipleri temel alarak başarılı sonuçlar elde etmiştir (Ho vd., 2020).

a- İleri Yayılma Süreci (Forward Diffusion)

İleri yayılma süreci, yayılma modellerinin temel yapı taşıdır ve görüntünün zamanla rastgele gürültü eklenerek bozulduğu bir işlemi ifade eder. Amaç, gerçek veri dağılımını daha basit ve izlenebilir bir forma dönüştürmek ve bu süreçte modelin tersine bir öğrenme mekanizması oluşturmasını sağlamaktır. Bu süreç, belirli sayıda adım boyunca çalışır ve her bir adımda veri üzerine Gaussian dağılımı kullanılarak gürültü eklenir. (Sohl-Dickstein vd., 2015). Hesaplama süreci aşağıdaki gibi ifade edilir.

$$q(x_t|x_{t-1}) = N(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t I)$$

Fomülde yer alan $q(x_t|x_{t-1})$ ifadesi t -inci adımda x_t veri durumunun x_{t-1} veri durumuna göre olasılığını ifade eder. β_t t -inci adımdaki gürültü miktarını kontrol eden bir hiperparametredir. Bu değer, adım sayısı ilerledikçe artar. N , ortalama $\mu = \sqrt{1 - \beta_t} x_{t-1}$ ve varyans $\sigma^2 = \beta_t$ olan bir Gaussian dağılımıdır. I ise birim matristir ve her piksele bağımsız olarak gürültü eklenmesini sağlar.

Bu işlem, temiz veri (x_0) üzerinde iteratif bir şekilde uygulanarak, t -inci adımda kadar veriyi rastgele gürültüye (x_t) dönüştürür.

Şekil 1’de örnek bir resim üzerinde her bir adımda eklenen gürültü gösterilmektedir.



Şekil 1: Yayılma modellerinde ileri yayılma süreci

b- Tersine Yayılma Süreci (Reverse Diffusion)

Tersine yayılma süreci, yayılma modellerinin temelinde yer alan, rastgele gürültüden anlamlı ve yapılandırılmış veriye ulaşmayı hedefleyen bir adımdır. Bu süreç, ileri yayılma sırasında bozulan veriyi orijinal hâline döndürmeyi amaçlar ve bir olasılık dağılımı öğrenerek gerçekleştirilir (Sohl-Dickstein vd., 2015).

$$p_0(x_{t-1}|x_t) = N(x_{t-1}; \mu_0(x_t, t), \Sigma_0(x_t, t))$$

Formülde yer alan x_t tersine yayılma sürecinin t -inci zaman adımındaki veri durumudur. $\mu_0(x_t, t)$ Modelin tahmin ettiği ortalamadır. $\Sigma_0(x_t, t)$ Modelin tahmin ettiği varyansı, belirsizliği ve bozulma seviyesini ifade eder. $p_0(x_{t-1}|x_t)$ ise t zamanında $t - 1$ zamanına geçişin olasılık dağılımıdır. Tersine yayılma süreci, tamamen rastgele gürültü (x_t) ile başlar. Bu rastgele durum, ileri yayılma sürecinde oluşan bozulmanın son adımıdır. Her bir adımda, model $p_0(x_{t-1}|x_t)$ olasılık dağılımını kullanarak önceki adıma geri döner. Bu süreç, toplam adım t boyunca devam eder. Şekil 2’de örnek bir resim üzerinde her bir adımda gerçekleştirilen tersine yayılma süreci gösterilmiştir.




Şekil 2: Yayılma modellerinde tersine yayılma süreci

c- U-NET

Yayılmalı modellerde tersine yayılma sürecinde gürültülerden oluşan bir resmin anlamlı bir hale dönüştürülmesi aşamasında bir çeşit evrişimli sinir ağı (CNN) olan U-Net ten faydalanılmaktadır. Bu mimari İlk olarak medikal görüntü segmentasyonu için geliştirilmiştir. (Ronneberger vd., 2015)

Şekil 3’de U-Net derin sinir ağının mimarisi gösterilmektedir.



Şekil 3: U-Net Mimarisi

U-Net, bir Kodlayıcı-Kod Çözücü yapısı üzerine kuruludur.

- Encoder (Kodlayıcı): Girdi verisini daha düşük çözünürlükte özellik haritalarına dönüştürerek önemli bilgi özniteliklerini çıkartır. Bu süreçte ardışık evrişim (convolution) ve maksimum havuzlama (max pooling) işlemleri uygulanır.
- Bottleneck (Dar Boğaz Katmanı): Kodlayıcı ve kod çözücü arasında yer alır. Girdi verisinin yüksek seviyeli, sıkıştırılmış bir temsili burada öğrenilir.

- Decoder (Kod Çözücü): Kodlayıcı tarafından öğrenilen öznitelikleri, tersine yayılma sürecinde daha yüksek çözünürlükteki veriye dönüştürür. Bu süreçte ardışık evrişim ve yukarı örnekleme (up-sampling) işlemleri uygulanır.
- Skip Connections (Atlama Bağlantıları): Kodlayıcı ve kod çözücü arasındaki aynı çözünürlük seviyelerindeki katmanlar arasında bağlantılar kurar. Bu bağlantılar, kodlama sırasında kaybolan ince detayların korunmasını sağlar ve modelin çıktı kalitesini artırır.

Yayılma modellerinde U-Net kullanımının bir çok avantajı bulunmaktadır. U-Net, çok katmanlı derin yapısıyla girdi verisinin özniteliklerini öğrenmek ve yeniden yapılandırmak için idealdir. Atlama bağlantıları, modelin hem küresel yapı hem de ince detayları aynı anda öğrenmesini sağlar. Görsel üretiminin yanı sıra görüntü onarımı ve veri tamamlama gibi yayılma modellerinin birçok uygulama alanında kullanılabilmektedir.

YAYILMA MODELLERİNDE EĞİTİM VE GÖRSEL OLUŞTURMA

Bu modeller, temel olarak gürültü ekleme ve bu gürültüyü tersine yayılma yoluyla temizleme süreci üzerine çalışmaktadır. Eğitim süreci, genellikle gürültü ekleme ve kaldırma işlemlerine dayalıdır ve her iki adımın optimizasyonu ile modelin doğruluğu arttırılmaktadır. Eğitimde, modelin doğru bir şekilde gürültüyü tahmin etmesi ve orijinal veriyi yeniden oluşturması sağlanmaya çalışılır.


İleri yayılma süreci, modelin eğitim sırasında nasıl gürültü eklediğini ve görüntülerin bozulmasını simüle eder. Her bir veri örneği, zaman adımlarına bağlı olarak azar azar gürültü eklenerek yavaşça bozulur. Bu aşama, modelin her adımda görüntünün orijinal haline ulaşmaya çalışacak şekilde eğitim almasını sağlar. Gürültü oranı, eğitim sırasında artan bir şekilde eklenir, bu da modelin her bir zaman adımında daha fazla bozulma ile başa çıkmasını sağlar (Ho vd., 2020).

Eğitimde en önemli aşamalardan biri, modelin tersine yayılma sürecini öğrenmesidir. Model, gürültülü görüntüyü alarak, her bir zaman adımında gürültüyü azaltarak orijinal görüntüyü yeniden oluşturmayı öğrenir. Bu süreç, bir çeşit gürültü tahminidir. Modelin her bir adımda, önceki zaman adımındaki gürültüyü tahmin etmesi ve bu tahmine dayanarak orijinal görüntüyü yeniden oluşturması sağlanır (Kingma vd., 2021). Yayılma modellerinin eğitim süreci, büyük ve çeşitlendirilmiş veri setlerine

dayanır. Eğitimde kullanılan veri setleri, modelin çeşitli görseller üzerinde eğitilmesini sağlayarak genelleme yeteneğini artırır. Özellikle metin-görsel eşleştirme uygulamalarında, görsellerin yanı sıra metin açıklamaları da kullanılır. Bu tür veriler, modelin hem görsel hem de semantik bilgilere dayanarak etkili tahminler yapabilmesini sağlar.

Eğitim sırasında kullanılan optimizasyon teknikleri, modelin performansını doğrudan etkiler. Genellikle, modelin her adımda gürültü ve veri arasındaki ilişkiyi öğrenmesini sağlamak için Adam optimizasyon algoritması gibi adaptif optimizasyon teknikleri kullanılır. Eğitim sürecinin sonunda, modelin doğru bir şekilde görsel içerik üretme yeteneği gelişmiş olur (Rombach vd., 2022).


Şekil 4’de Stable Diffusion modelinin eğitim esnasındaki mimarisi verilmiştir (Marvik 2023).



Şekil 4: Stable Diffusion modelinin eğitim esnasındaki mimarisi

X_0 başlangıçta temiz olan bir görüntü verisini, E (Kodlayıcı) girdi görüntüsünü (X_0) daha düşük boyutlu bir latent uzaya (latent space) kodlayan bir sinir ağını, Z_0 encoder çıkışını, Forward Diffusion ileri yayılma sürecini, Z_t : T zaman adımıdaki gürültülü latent temsili, D (Kod Çözücü) Gürültülü latent temsili (Z_t) alarak, buradan tekrar bir görüntü (X'_t) üretmeye çalışan bir sinir ağını, Condition modelin öğrenme sürecini yönlendirmek için kullanılan ek bilgileri ifade etmektedir.

Yayılmalı modellerde görsel oluşturma işlemi genellikle girilen bir text prompt aracılığı ile gerçekleştirilmektedir. Şekil 5'de Stable Diffusion modelinin örnekleme sırasındaki mimarisi verilmiştir (Marvik 2023).



Şekil 5: Stable Diffusion modelinin örnekleme esnasındaki mimarisi

Bu aşamada gürültüden oluşan veri U-Net aracılığı ile tahmin edilmeye çalışılır. Belirli adım sonunda kod çözücü aracılığı ile görsel oluşturulur.

STABLE DIFFUSION MODELİNİN EL ALETLERİ GÖRSELLERİ İLE EĞİTİMİ:

Görsel oluşturmak amacı ile kullanılan yapay zekalar yerel kaynakları kullanabilen ve kullanıcıların modeli yeniden eğitmesine olanak sağlayan modellerdir. Stable Diffusion modeli günümüzde en çok kullanılan açık yayılma modellerinden biridir. Stable Diffusion, latent diffusion models (LDMs) adı verilen bir sınıfın temsilcisidir ve boyut azaltma teknikleri ile yüksek çözünürlüklü görüntüler üretebilir. Özellikle latent space üzerinde çalışarak hesaplama maliyetlerini düşürür. Model, metin-görsel eşleme için CLIP (Contrastive Language-Image Pretraining) modelini kullanır ve geniş çapta özelleştirilebilir. Akademik alanda bu model, veri artırma, yaratıcı sanat üretimi ve eğitim materyalleri geliştirme gibi farklı alanlarda kullanılmaktadır. Diğer ticari görsel oluşturma uygulamalarının ücretli ya da limitli kullanımı göz önüne alındığında Stable Diffusion önemli avantajlara sahiptir. Bu avantajlardan en önemlisi güncel GPU'ya sahip hemen her sistemde çalışabilmesi, ücretsiz ve sınırsız kullanıma olanak tanımasıdır. Ancak bu model

her ne kadar büyük veri setleri ile eğitilmiş olsa da bazı alanlarda görsel oluşturma noktasında yetersiz kalmaktadır. Bu alanlardan biride özellikle iş hayatında tamir ve onarım işlerinde sıklıkla kullanılan el aletleridir. Bu eksikliğin giderilmesi amacı ile model çeşitli el aletleri görselleri ile yeniden eğitilmiştir. Eğitim süreci aşağıdaki aşamaları içermektedir.

a- Veri Setinin Hazırlanması:

21 adet pense ve tornavida görselinden oluşan veri seti ayrı ayrı oluşturulmuştur. Görseller internet ortamında bulunan fotoğraflardan seçilmiştir. Şekil 6'da pense sınıfına ait görseller gösterilmektedir.



Şekil 6: Stable Diffusion modeli eğitiminde kullanılacak pense görselleri

Benzer şekilde 21 adet tornavida resmi internet ortamından bulunarak tornavida sınıfı veri seti oluşturulmuştur. Şekil 7'de tornavida sınıfına ait görseller gösterilmektedir.



Şekil 7: Stable Diffusion modeli eğitiminde kullanılacak tornavida görselleri

b- Programlama Ortamı ve Programlama Dilinin Belirlenmesi


Model eğitimi için Google Colab geliştirme ortamı tercih edilmiştir. Google Colab, özellikle veri bilimi, yapay zeka ve makine öğrenimi projelerinde yaygın olarak kullanılan, bulut tabanlı bir platformdur. Jupyter Notebook tabanlı bir arayüz sunan Colab, Python programlama dili ile uyumlu olup, kullanıcılarına ücretsiz GPU (Grafik İşleme Birimi) ve TPU (Tensör İşleme Birimi) desteği sağlar. Bu özellikler, yüksek hesaplama gücü gerektiren diffusion modellerinin eğitimi ve ince ayarı (fine-tuning) için büyük bir avantaj sunmaktadır. Colab, kullanıcıların güçlü işlemciler ve geniş bellek kaynaklarına kendi cihazlarına ihtiyaç duymadan erişmelerine olanak tanır. Kullanıcılar, NVIDIA Tesla T4 veya P100 gibi GPU'ları ya da TPU'ları kullanarak eğitim sürecini hızlandırabilir. Bu özellikler, özellikle büyük veri setleri üzerinde çalışan derin öğrenme modelleri için oldukça önemlidir. Ayrıca TensorFlow, PyTorch ve Transformers gibi popüler makine öğrenimi kütüphaneleri Google Colab ortamında kolayca entegre edilebilir. Stable Diffusion modelinin el aletleri görselleri ile yeniden eğitilmesi için bu çalışmada, Google Colab'de 83 GB RAM ve 40 GB video belleğe sahip Tesla A100 GPU kullanılmıştır.

Eğitim PyTorch kütüphanesi kullanılarak Python programlama dili ile gerçekleştirilmiştir. Eğitim parametreleri Çizelge 1’de gösterilmiştir.

Epoch	1
Train batch	2
Adım Sayısı	300
Öğrenme Oranı	0.000005
Optimizasyon Algoritması	Adam

Çizelge 1 Eğitim Parametreleri

Eğitim, 300 iterasyon boyunca gerçekleşmiş olup süresince kullanılan system kaynakları Şekil 8’de gösterilmiştir.



Şekil 8: Sistem kaynakları kullanımı

Şekil 8’de görüldüğü gibi bellek kullanımı yaklaşık 6 GB civarındadır. Buna karşılık GPU belleği kullanımı 12.1 GB boyutundadır. 21 adet görselden oluşan her bir veri setinin eğitimi yaklaşık 6 dakika sürmektedir. Bu donanım gereksinimler güncel donanıma sahip bir kişisel bilgisayar tarafından dahi kolaylıkla karşılanabilecek düzeydedir. Her ne kadar model eğitim için 12.1 GB GPU belleği gerekse de model kullanımı için 4 GB video belleği dahi yeterli olmaktadır.

c- Eğitim Öncesi ve Eğitim Sonrası Model Karşılaştırması

Stable Diffusion modeli varsayılan katsayıları ile colab ortamında çalıştırılarak “pense” promptu girilmiş ve görsel oluşturulması sağlanmıştır. Ardından model pense resimlerinden oluşan veriseti ile eğitilmiş ve yine aynı prompt girilerek elde edilen görseller kayıt edilmiştir. Girilen prompt sonrasında model tarafından oluşturulan görseller Şekil 9’da gösterilmiştir.

Stable Diffusion		
Prompt	Eğitim Öncesi	Eğitim Sonrası
Pense		
Pense		
Pense		
Pense		

Şekil 9: Eğitim öncesi ve sonrası Stable Diffusion ile oluşturulan pense görselleri

Benzer şekilde Stable Diffusion modeli varsayılan katsayıları ile colab ortamında çalıştırılarak “tornavida” promptu girilmiştir. Ardından model tornavida resimlerinden oluşan veri seti ile eğitilmiş ve yine aynı prompt girilerek elde edilen görseller kayıt edilmiştir. Girilen prompt sonrasında model tarafından oluşturulan görseller Şekil 10’da gösterilmiştir

Stable Diffusion		
Prompt	Eğitim Öncesi	Eğitim Sonrası
Tornavida		
Tornavida		
Tornavida		
Tornavida		

Şekil 10: Eğitim öncesi ve sonrası Stable Diffusion ile oluşturulan tornavida görselleri

Şekil 9 ve Şekil 10 incelendiğinde varsayılan katsayılar ile Stable Diffusion modelinin el aletleri görselleri üretme yeteneğinin çok düşük olduğu görülmektedir. 21 adet görselden oluşan bir veri seti ile eğitim sonucu model tarafından üretilen görseller modelin el aletleri görselleri üretebilme yeteneğini kazandığını göstermektedir. Eğitim sonrası modelden elde edilen görseller incelendiğinde modelin tornavida ve pense görsellerinin genel hatlarının doğru oluşturulduğu ancak pense üzerindeki izler ya da tornavidanın ucu gibi detay çizimleri gerçekleştiremediği görülmüştür. Eğitim için kullanılan verisetindeki görsel sayısı artırılarak bu durumun iyileştirilebileceği öngörülmektedir.

SONUÇ

Günümüzde ticari amaçla bir çok yayılma modeli, metinden görsel oluşturmak, görsel üzerinde restorasyon yapmak, görselden görsel oluşturmak ve video üretmek amacı ile kullanılmaktadır. Ancak bu modeller ya ücretli ya da kısıtlı kullanıma sahip modellerdir. Ticari modellere karşılık açık modeller, kullanıcılar tarafından ücretsiz ve sınırsız kullanımın yanı sıra yeni görseller ile eğitilerek özelleştirme kabiliyetine de sahiptir. Geniş bir veriseti ile genel amaçlı olarak üretilmiş açık modeller günlük işlerde oldukça başarılı sonuçlar verebilmektedir. Ancak belirli özel alanlarda görsel üretme kapasiteleri yetersiz kalabilmektedir. Bu alanlardan birisi de el aletleri görselleri üretme becerisidir. Bu çalışmada açık bir yayılma modeli olan Stable Diffusion modeli “pense” ve “tornavida” görselleri kullanılarak oluşturulan veri setleri ile tekrar eğitilmiş ve bu sınıflardaki görsel üretme becerisi incelenmiştir. Eğitim sonrası modelin yeni görsellere adapte olduğu ve varsayılan eğitim çıktılarına göre çok daha iyi sonuçlar verdiği görülmüştür. Açık yayılma modelleri özellikle belirli Alana özgü görsel material ihtiyacı olan işletme ve kuruluşlarda, uygun veri seti ile eğitim sonrasında kullanılabileceği belirlenmiştir.

KAYNAKÇA

- Baranchuk, D., von Kügelgen, J., Krasheninnikov, A., Chaudhuri, S., Rützi, S., Ganey, P., ... & Vetrov, D. P. (2021). Label-efficient semantic segmentation with diffusion models. *arXiv preprint arXiv:2112.03126*.
- Crowson, K., Biderman, S., Kornis, D., Stander, B., Hallahan, E., Castriato, L., & Raff, E. (2022). VQ-diffusion: Vector quantized diffusion for text-to-image synthesis. *arXiv preprint arXiv:2111.14822*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. In *Advances in neural information processing systems* (Vol. 27, ss. 2672–2680).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (ss. 770–778).
- Ho, J., Jain, A., & Abbeel, P. (2020). Denoising diffusion probabilistic models. *arXiv preprint arXiv:2006.11239*.
- Ho, J., Saharia, C., Chan, W., Salimans, T., Fleet, D. J., & Norouzi, M. (2022). Video diffusion models. *arXiv preprint arXiv:2204.03458*.
- Kingma, D. P., Salimans, T., & Poole, B. (2021). Variational diffusion models. In *Advances in neural information processing systems*.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (Vol. 25, ss. 1097–1105).
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Lugmayr, A., Danelljan, M., Romero, A., Yu, F., Timofte, R., & Van Gool, L. (2022). RePaint: Inpainting using denoising diffusion probabilistic models. *arXiv preprint arXiv:2201.09865*.
- Marvik AI. (2023, Kasım 28). *An introduction to diffusion models and Stable Diffusion*. Marvik Blog. <https://blog.marvik.ai/2023/11/28/an-introduction-to-diffusion-models-and-stable-diffusion/>
- McCarthy, J., Minsky, M., Rochester, N., & Shannon, C. (2006). A proposal for the Dartmouth summer research project on artificial intelligence, August 31, 1955. *AI Magazine*, 27(4), 12–14.
- Mok, T. C., & Chung, A. C. S. (2023). Learning data representations with diffusion models: A review. *Medical Image Analysis*, 82, 102614.
- Nichol, A., & Dhariwal, P. (2021). Improved denoising diffusion probabilistic models. *arXiv preprint arXiv:2102.09672*.
- Ramesh, A., Pavlov, M., Goh, G., Gray, S., & Voss, C. (2022). Hierarchical text-conditional image generation with CLIP latents. *arXiv preprint arXiv:2204.06125*.
- Rombach, R., Blattmann, A., Lorenz, D., Esser, P., & Ommer, B. (2022). High-resolution image synthesis with latent diffusion models. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (ss. 10684–10695).
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. *arXiv preprint arXiv:1505.04597*.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408.

- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536.
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Sohl-Dickstein, J., Weiss, E., Maheswaranathan, N., & Ganguli, S. (2015). Deep unsupervised learning using nonequilibrium thermodynamics. *arXiv preprint arXiv:1503.03585*.
- Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433–460.

BÖLÜM 6

TÜRKÇE DOĞAL DİL İŞLEME VE GELECEĞİ

Ahmet KARAOĞLU

Dr. Öğr. Üyesi, Sinop Üniversitesi, akaraoglu@sinop.edu.tr

 0000-0002-7507-3031

Yapay zeka her disiplinde etkili bir şekilde kullanılmaktadır (Söyler, 2023). Görüntü işlemeden, makine öğrenmesine kadar büyük bir çerçevede çalışmalar bulunmaktadır (Söyler vd., 2023). Doğal Dil İşleme (DDİ), bilgisayar bilimleri, yapay zeka ve dilbilimin kesişim noktasında yer alan ve bilgisayarlar ile insan dili arasındaki etkileşime odaklanan multidisipliner bir alandır (Amit Shrivastava, 2020; V. Geetha & C K Gomathy, 2023). Geçmişi 1950'lere kadar uzanmakta, kural tabanlı sistemlerden istatistiksel yaklaşımlara ve daha yakın zamanda gelişmiş derin öğrenme modellerine doğru evrilmektedir (Rajarshi SinhaRoy, 2021; Sharavana vd., 2024; Söyler vd., 2024). NLP, konuşma tanıma, makine çevirisi ve metin özetleme gibi çeşitli görevleri kapsamaktadır (A. Reshamwala vd., 2013). Alan, her biri makine çevirisi, yapay zeka etkisi ve mantıksal gramer stillerinin benimsenmesi gibi farklı odak noktalarıyla işaretlenmiş farklı dönemler boyunca ilerlemiştir (Rajarshi SinhaRoy, 2021). NLP'deki son gelişmeler, büyük veri kümelerinin kullanılabilirliği, artan hesaplama gücü ve sofistike makine öğrenimi modelleri, özellikle de LSTM'ler ve Transformers gibi derin öğrenme teknikleri tarafından yönlendirilmiştir (Raghvendra Kumar & B. K. Mishra, 2020; Sharavana vd., 2024). NLP gelişmeye devam ettikçe, araştırmacılar yorumlanabilirlik, etik ve çok modlu veri entegrasyonu ile ilgili zorlukları araştırmaktadır (Sharavana vd., 2024).

Türkçe, karmaşık morfolojik yapısı ve serbest kelime sıralaması nedeniyle Doğal Dil İşleme (DDİ) için benzersiz zorluklar sunmaktadır (Ofłazer, 2014; Tohma & Kutlu, 2020). Türkçenin sondan eklemeli yapısı, çekim ve türetim biçimbirimlerinin yaygın kullanımı ile potansiyel olarak sonsuz bir kelime hazinesi yaratır ve geleneksel NLP yaklaşımlarını zorlaştırır (Ofłazer & Saraçlar, 2018). Türkçede bağımlılık ayrıştırması, doğruluğu artırmak için temel birimler olarak tüm kelimeler yerine çekim gruplarının dikkate alınmasını gerektirir (Eryiğit vd., 2008; Gulşen & Kemal, 2006). Araştırmacılar bu zorlukların üstesinden gelmek için Türkçe NLP görevleri için web hizmetleri de dahil

olmak üzere çeşitli araçlar ve kaynaklar geliştirmişlerdir (Çagri, 2015; Eryiğit, 2014). Ön işleme ve özellik çıkarma yöntemleri, özellikle gerçek dünya verilerindeki tutarsız yazım ve karmaşık dilbilgisi yapılarıyla uğraşırken, Türkçe'de duygu analizi için çok önemlidir (Cavusoglu vd., 2020). Genel olarak, Türkçe NLP araştırmaları, morfolojik bilgilerin dahil edilmesinin ve mevcut tekniklerin dilin benzersiz özelliklerine uyarlanmasının önemini vurgulamaktadır.

Morfolojik açıdan zengin bir dil olan Türkçe, doğal dil işleme (NLP) alanında benzersiz zorluklar ve fırsatlar sunmaktadır. Eklemeli yapısı ve karmaşık gramer kuralları, onu dilbilimsel araştırmalar için ilginç bir konu haline getirmektedir (Tohma & Kutlu, 2020). Türkçe, Ural-Altay ve Nostratik teorileriyle ilişkisi hakkında devam eden tartışmalarla birlikte Altay dil ailesine aittir (Ercilasun, 2013). Geniş konuşmacı nüfusuna rağmen, Türkçe NLP kaynakları azdır (Altinok, 2023). Bununla birlikte, son gelişmeler arasında nöral NLP araç setlerinin (Huseyin vd., 2022), web hizmetlerinin (Eryiğit, 2014) ve kıyaslama veri setlerinin (Safaya vd., 2022) geliştirilmesi yer almaktadır. BERT gibi modern tekniklerin uygulanması, çeşitli Türkçe NLP görevlerinde umut verici sonuçlar göstermiş ve kapsamlı ön işleme ihtiyacını azaltmıştır (Özçift vd., 2021). Türkçe dilinin mantıksal yapısı da NLP uygulamaları için, özellikle soru-cevaplama sistemlerinde potansiyel avantajlar sunmaktadır (Adalı, 2024). Bu gelişmeler Türkçe NLP araştırma ve uygulamalarının büyümesine katkıda bulunmaktadır.

TÜRKÇE İÇİN GELİŞTİRİLEN NLP TEKNİKLERİ VE ARAÇLARI

Türkçe Doğal Dil İşleme (NLP) alanındaki son gelişmeler, çeşitli araç ve platformların geliştirilmesine yol açmıştır. İTÜ Türkçe NLP Web Servisi ön işleme, morfoloji, sözdizimi ve varlık tanıma araçları sunmaktadır (Eryiğit, 2014). Kapsamlı bir açık kaynak paketi olan VNLP, duygu analizi ve adlandırılmış varlık tanıma gibi görevler için son teknoloji modeller sağlar (Turker vd., 2024). TurkishDelightNLP morfolojik düzeyden semantik düzeye kadar bir dizi NLP görevi sunmaktadır (Huseyin vd., 2022). TULAP platformu Türkçe NLP kaynaklarını paylaşmayı ve keşfetmeyi kolaylaştırmaktadır (Uskudarli vd., 2023). Araştırmalar, NLP tekniklerinin Türkçede bilgi erişimini geliştirebileceğini göstermiştir (Pembe & Say, 2004). BERT uygulaması, ön işleme gereksinimlerini azaltırken çeşitli Türkçe NLP görevlerinde gelişmiş performans göstermiştir (Özçift vd., 2021). Bu gelişmeler, Türkçe NLP'nin birçok alanda ve uygulamada ilerlemesine katkıda bulunmaktadır.

TÜRKÇE NLP MORFOLOJİK ANALİZ ve ÇÖZÜMLEME ARAÇLARI

Türkçe biçimbilimsel analiz son yıllarda önemli gelişmeler göstermiş, birçok açık kaynak kodlu araç ve kaynak kullanıma sunulmuştur. İki seviyeli bir morfolojik analizör olan TRmorph, Türkçe için ücretsiz olarak kullanılabilen ilk araçlardan biri olarak tanıtılmıştır (Çöltekin, 2010). Daha sonra, TRMOR (Kayabaş vd., 2019) ve hızlı, genişletilebilir bir analizör (Yildiz vd., 2019) dahil olmak üzere çeşitli başka analizörler geliştirilmiştir. Bu araçlar genellikle Türkçe morfolojisini ele almak için sonlu durum dönüştürücüleri ve kural tabanlı yaklaşımları kullanmaktadır (Oztürel vd., 2019; Sak vd., 2010). İTÜ Türkçe NLP Web Servisi gibi bazı analizörler, ön işleme ve sözdizimi analizi gibi ek işlevler sunmaktadır (Eryiğit, 2014) Büyük web derlemleri ve değerlendirme için altın standart veri kümeleri de dahil olmak üzere kapsamlı kaynaklar oluşturmak için de çaba gösterilmiştir (Kayabaş vd., 2019; Sak vd., 2010). Sözlük kullanmadan ek çıkarma gibi alternatif yaklaşımlar da araştırılmıştır (Eryiğit & Adalı, 2003). Bu gelişmeler, Türkçe morfolojik analiz araçlarının erişilebilirliğini ve performansını önemli ölçüde artırmıştır.

TÜRKÇE DİL MODELLERİ

Türkçe dil modelleri üzerine yapılan son araştırmalar, tek dilli ve çok dilli yaklaşımların geliştirilmesi ve değerlendirilmesine odaklanmıştır. CosmosGPT gibi tek dilli modeller, çok dilli muadillerinden daha küçük olmalarına rağmen umut verici performans göstermiştir (Kesgin vd., 2024). Kodlayıcı-kod çözücü bir model olan TURNA, hem anlama hem de üretme görevlerinde çok dilli modellerden daha iyi performans göstermektedir (Uludougan vd., 2024). Karşılaştırmalı çalışmalar, çeşitli modellerin bağlamsal öğrenme ve soru cevaplama (Doğan vd., 2024) ve duygu analizindeki (Güven, 2022) performansını değerlendirmiştir. Araştırmacılar ayrıca Türkçe dil anlama görevleri için dönüştürücü tabanlı modellere ince ayar yapmayı (Yildirim, 2024) ve derin öğrenme tabanlı otomatik konuşma tanıma sistemleri geliştirmeyi (Görmez, 2024) araştırmışlardır. Daha önceki çalışmalar, Türkçenin eklemeli yapısının zorluklarını morfoleksik dil modelleri (Sak vd., 2012) ve kök tabanlı yaklaşımlar (Çiloğlu vd., 2004) aracılığıyla ele almıştır. Bu çalışmalar toplu olarak, çeşitli uygulamalarda Türkçe doğal dil işleme yeteneklerinin geliştirilmesine katkıda bulunmaktadır.

Türkçe Dil Modelleri, dilin eklemeli yapısının getirdiği benzersiz zorlukları ele alarak son yıllarda önemli adımlar atmıştır. Bu modellerin geliştirilmesi, doğal dil işlemede Türkçe ile iyi kaynaklara sahip diller arasındaki boşluğu doldurma ihtiyacından

kaynaklanmıştır. Tek dilli eğitim, cosmosGPT gibi modellerin çok dilli alternatiflerden önemli ölçüde daha küçük olmasına rağmen rekabetçi performans göstermesiyle umut verici bir yaklaşım olarak ortaya çıkmıştır. Bu yöntem, çok dilli modellerin Türkçe derlemlerle ince ayarlanmasına yönelik yaygın uygulamayla tezat oluşturmaktadır.

Dönüştürücü tabanlı mimariler Türkçe NLP'nin ilerlemesinde önemli bir rol oynamıştır. Bir kodlayıcı-kod çözücü çerçevesi olan TURNA gibi modeller, hem anlama hem de üretme görevlerinde etkileyici yetenekler göstermiştir. Benzer şekilde, ince ayarlı bir BERT modeli olan BERTurk, isim-varlık tanıma, duygu analizi ve soru cevaplama dahil olmak üzere çeşitli Türkçe dil anlama görevlerinde en gelişmiş sonuçları elde etmiştir. Türkçe dil modelleri kıyaslama tablosu Tablo 1'de verilmiştir.

Tablo 1. Türkçe dil modelleri kıyaslama tablosu.

Özellik	CosmosGPT	TURNA	BERTurk
Model Türü	GPT-tabanlı (Generative Pre-trained Transformer)	Transformer Encoder	Transformer Encoder
Eğitim Verisi	Geniş Türkçe ve çok dilli metinler	Türkçe haber, sosyal medya ve resmi belgeler	Türkçe haber, Wikipedia, web sayfaları
Odak Alanı	Üretken dil modelleme ve içerik üretimi	Türkçe doğal dil işleme (sentimsen analizi vb.)	Türkçe doğal dil işleme
Performans	Üretkenlik ve yaratıcı yazma işlerinde güçlü	Doğruluk ve görev spesifik çalışmalarda güçlü	Doğruluk ve genel NLP görevlerinde güçlü
Parametre Sayısı	Milyarlarca	Milyonlarca	Milyonlarca
Model Büyüklüğü	Büyük (yüksek donanım gereksinimi)	Orta	Orta
Eğitim Dili	Türkçe ve diğer diller	Sadece Türkçe	Sadece Türkçe
Kullanım Alanları	Metin üretimi, diyalog oluşturma, yaratıcı işler	Sentiment analizi, sınıflandırma, etiketleme	Sınıflandırma, etiketleme, QA
Özelleştirilebilirlik	Yüksek (API ve ince ayar imkanı)	Orta (ince ayar için uygun)	Orta (ince ayar için uygun)
Türkçe Performansı	İleri düzey üretkenlik, karmaşık sorular	Türkçe spesifik görevlerde yüksek başarı	Genel Türkçe NLP görevlerinde yüksek başarı


Açık Kaynak Durumu	Ticari, açık kaynak değil	Açık kaynak	Açık kaynak
Geliştiren Ekip	OpenAI veya benzeri bir büyük geliştirici	TÜBİTAK, Boğaziçi Üniversitesi	DBMDZ (Deep Learning Berlin)

Araştırmacılar ayrıca Türkçe morfolojisini ele almak için yenilikçi yaklaşımlar keşfetmişlerdir. Bunlar arasında kökleri ve sonları ayrı ayrı kullanan alt kelime tabanlı dil modelleri ve kelimeleri birlikte oluşlarına göre gruplayan sınıf tabanlı modeller bulunmaktadır. Bu tür yöntemlerin, geleneksel kelime tabanlı modellerin eklemeli dillerde zorlandığı konuşma tanıma görevlerinde özellikle etkili olduğu kanıtlanmıştır. Özel veri kümelerinin ve değerlendirme ölçütlerinin geliştirilmesi, Türkçe NLP'nin ilerlemesinde çok önemli olmuştur. Türkçe dil modellerinin çeşitli görevlerdeki yeteneklerini ölçmek için yeni ince ayar ve değerlendirme veri kümeleri tanıtılmıştır. Bu kaynaklar, kamuya açık modellerle birlikte, Türkçe NLP alanında daha fazla araştırma ve uygulama yapılmasını teşvik etmektedir.

TÜRKÇE NLP'NİN KULLANIM ALANLARI

Türkçe Doğal Dil İşleme (NLP), Türkçe dilindeki metin ve konuşma verilerini anlamak, analiz etmek ve işlemek için kullanılan bir teknoloji dalıdır. Türkçe NLP'nin kullanım alanları oldukça geniştir ve birçok sektörde etkili bir şekilde uygulanmaktadır. Türkçe NLP'nin Kullanım Alanları Şekil 1'de gösterilmektedir.

Şekil 1. Türkçe NLP'nin Kullanım Alanları.



EĞİTİMDE TÜRKÇE NLP’NİN KULLANIM ALANLARI

Doğal Dil İşleme (NLP) Türkçe eğitiminde umut verici uygulamalar göstermiştir. Öğretmenlerin mesleki başarılarını ve motivasyonlarını artırabilir (H. Turan vd., 2016) ve dil öğrenimini, analizini ve değerlendirmesini geliştirebilir (Khaled, 2014). İTÜ Türkçe NLP Web Servisi araştırmacılara ve öğrencilere son teknoloji NLP araçları sağlarken (Eryiğit, 2014), TurkishDelightNLP çeşitli dilbilimsel analizler için kapsamlı bir araç seti sunmaktadır (Alecakir vd., 2022). BERT, kapsamlı ön işleme ihtiyacını azaltarak Türkçe NLP görevlerinde verimlilik göstermiştir (Özçift vd., 2021). Son zamanlardaki çabalar, ücretsiz olarak kullanılabilen dilbilimsel kaynaklar (Altınok, 2023) ve Türkçe NLP kaynaklarını paylaşmak için TULAP gibi erişilebilir platformlar (Üsküdarlı vd., 2023) geliştirmeye odaklanmıştır. Öğretmen eğitimindeki NLP uygulamaları, dil öğretmenlerinin aksanlarını geliştirmeyi ve mesleki becerilerini artırmayı içerir (Zhu, 2023). Bu gelişmeler, eğitimde büyüyen Türkçe NLP alanına katkıda bulunmaktadır. Eğitimde NLP kullanımının durumu Tablo 3’de gösterilmektedir.

Tablo 2. Eğitimde yapay zeka.

Artılar	vs	Eksiler
 Öğretmen başarısını artırır		 Hukuk dilinde karmaşıklık
 Dil öğrenimini geliştirir		 Uyum zorlukları
 Gelişmiş araçlar sağlar		 Kapsamlı ön işleme ihtiyacı
 Ön işleme ihtiyaçlarını azaltır		 Sınırlı erişilebilirlik
 Ücretsiz kaynakları destekler		 Entegrasyon sorunları

Son araştırmalar, gelişmiş teknikler kullanarak eğitim materyallerini özetlemeye yönelik çeşitli yaklaşımları araştırmıştır. Dönüştürücü ağlar, EDUVSUM veri kümesinde gelişmiş doğruluk elde ederek eğitim videolarının özetlenmesinde umut vaat ettiğini göstermiştir (M. R. Oliveira vd., 2023). Diğer yöntemler arasında öğrenme materyallerinin çoklu belge özetlemesi için bigram gömme ve tamsayı doğrusal programlama kullanımı (Iyyappan & Balasundaram, 2023) ve eğitim video altyazılarını özetlemek için Gizli Dirichlet Tahsisi uygulaması (Alrumiah & Al-Shargabi, 2022) yer almaktadır. Araştırmacılar ayrıca çoklu belge özetleme için hiyerarşik konu modellemesini (Haghighi & Vanderwende, 2009) ve özetleme tekniklerinin eğitim teknolojisi sistemlerine entegrasyonunu (Benedetto vd., 2022) araştırmışlardır. Çalışmalar, otomatik olarak oluşturulan özetlerin öğrenme faaliyetlerini desteklemek için yararlı olabileceğini (Baralis vd., 2015) ve derin öğrenme tabanlı metin özetleyicilerin öğrenme nesnelerini etkili bir şekilde oluşturabileceğini göstermiştir (L. M. R. Oliveira vd., 2021). Bu gelişmeler, eğitim içeriğinin daha verimli bir şekilde oluşturulmasına ve tüketilmesine katkıda bulunmaktadır.

SAĞLIKTA TÜRKÇE NLP’NİN KULLANIM ALANLARI

Son araştırmalar, tıp ve eğitim alanları için metin özetleme tekniklerine odaklanmıştır. Önemli bilgileri korurken büyük hacimli metinleri yoğunlaştırmak için özetleyici ve soyutlayıcı yöntemler de dahil olmak üzere çeşitli yaklaşımlar araştırılmıştır (Deepika vd., 2021; Ghodratnama Samira vd., 2021). Çalışmalar, tıbbi terminoloji ve ilaç geri bildirimlerini işlemek için LSA, TextRank ve BERT gibi farklı özetleme tekniklerinin etkinliğini değerlendirmiştir (Monika vd., 2023). Araştırmacılar ayrıca doğal dil işleme kullanarak taburcu özetlerinden hasta sorun listeleri oluşturmak (Cao Hui vd., 2004) ve özetleri doktorlar ve hastalar gibi farklı kullanıcı grupları için uyarlamak için yöntemler geliştirmiştir (McKeown & Elhadad, 2006). Ayrıca, duygu analizi eğitim ortamlarında öğrenci geri bildirimlerini özetlemek için uygulanmıştır (Sharma & Jain, 2020). Bu gelişmeler, aşırı bilgi yükü ve çeşitli kullanıcı ihtiyaçlarının zorluklarını ele alarak tıbbi ve eğitim bağlamlarında bilgi erişilebilirliğini ve anlamayı iyileştirmeyi amaçlamaktadır (İbrahim vd., 2023; Johnson vd., 2002)

HUKUKTA TÜRKÇE NLP'NİN KULLANIM ALANLARI

Son zamanlarda yapılan çalışmalar, yapay zekânın Türkiye'deki hukuki bağlamlarda uygulanmasını araştırmıştır. Araştırmacılar, Türk Anayasa Mahkemesi kararlarını yüksek doğrulukla tahmin etmek için makine öğrenimi algoritmalarını başarıyla kullanmışlardır (Aydemir, 2023; Sert vd., 2021; H. Turan vd., 2016). Türk hukuk belgelerinin metin sınıflandırması için geleneksel makine öğrenimi, derin öğrenme ve dönüştürücü tabanlı modeller de dahil olmak üzere çeşitli teknikler kullanılmıştır (Erdoğanymaz & Mengunoğul, 2022; Üsküdarlı vd., 2023). YZ'nin hukuktaki potansiyeli, yasal belgelerin risk analizindeki uygulamalar (Chakrabarti vd., 2018) ve yasal bir konu olarak YZ tartışmaları (Zeytin & Gençay, 2019) ile tahmin ve sınıflandırmanın ötesine uzanmaktadır. Bu gelişmelerin Türk yargı sisteminde yasal süreçleri kolaylaştırması, iş yükünü azaltması ve karar desteği sağlaması beklenmektedir (T. Turan vd., 2020). Bununla birlikte, YZ'nin hukuk dilinin karmaşıklığına ve alana özgü gereksinimlere uyarlanmasında zorluklar devam etmektedir. Türk hukuk sisteminde NLP kullanımının durumu Tablo 3'de gösterilmektedir.

Tablo 3. Türk hukuk sisteminde yapay zeka.


Artılar	vs	Eksiler
 Tahminlerde yüksek doğruluk		 Hukuk dilinin karmaşıklığı
 Çeşitli ileri teknikler		 Alana özgü gereksinimler
 Hukuki süreçleri kolaylaştırır		 Uyum zorlukları
 İş yükünü azaltır		
 Karar desteği sağlar		

E-TİCARET VE PAZARLAMADA TÜRKÇE NLP'NİN KULLANIM ALANLARI

Doğal Dil İşleme (NLP), e-ticaret ve pazarlamada, özellikle Türkçe dil uygulamaları için giderek daha önemli hale gelmiştir. Araştırmalar, ürün kategorisi sınıflandırması (Deniz vd., 2022), duygu analizi (Demircan vd., 2021) ve ürün tavsiyesi (Malik vd., 2022)için modeller geliştirmeye odaklanmıştır. Bu modeller, Türkçe dil işleme için BERT, ELECTRA ve RoBERTa gibi çeşitli makine öğrenimi tekniklerini kullanmaktadır. İTÜ Türkçe NLP Web Servisi, araştırmacılara ön işleme, morfoloji, sözdizimi ve varlık tanıma için son teknoloji araçlar sunmaktadır (Eryiğit, 2014). NLP'deki son gelişmeler, metin özetleme ve üretken soru cevaplama gibi yeni uygulamalara olanak sağlamıştır (Hartmann & Netzer, 2023). Ayrıca, Latent Dirichlet Allocation ve word2vec'i birleştiren yeni yaklaşımlar, Türk e-ticaret web sitelerindeki çevrimiçi incelemelerden tüketici ilgi alanlarını keşfetmede gelişmiş performans göstermiştir (Ekinci & Omurca, 2023). Bu gelişmeler, NLP ve e-ticaretin büyüyen kesişimini vurgulamaktadır (Ueffing vd., 2019).

TÜRKÇE NLP'NİN GELECEĞİ

Türkçe'de Doğal Dil İşleme'nin (DDİ) geleceği, teknoloji ve araştırmalardaki son gelişmelerin de etkisiyle önemli ilerlemeler kaydetmeye hazırlanıyor. Morfolojik açıdan zengin bir dil olan Türkçe, NLP görevleri için tarihsel olarak benzersiz zorluklar sunmuştur (Özçift vd., 2021). Ancak, BERT gibi güçlü nöral dil modellerinin ortaya çıkması, karmaşık ön işleme adımlarına olan ihtiyacı ortadan kaldırırken aynı zamanda tahmin yeteneklerini geliştirerek Türkçe NLP'de devrim yaratmaktadır. Bu değişim, NLP alanında hem yetersiz kaynaklara sahip olduğu hem de yeterince araştırılmadığı düşünülen Türkçe için özellikle önemlidir. Mukayese gibi kapsamlı ölçütlerin kullanıma sunulması, çeşitli Türkçe NLP görevlerini değerlendirmek ve ilerletmek için standart bir yol sağlayarak bu boşluğu gidermektedir (Safaya vd., 2022). Türkçe NLP araştırma ve uygulamalarını desteklemek için yeni araçlar ve kaynaklar ortaya çıkmaktadır. Örneğin TurkishDelightNLP, "Bağlam Modeli" gibi yeni mimarileri kullanarak morfolojik analizden semantik ayrıştırmaya kadar bir dizi NLP aracı sunmaktadır (Alecakir vd., 2022).

Tablo 4. Türkçe NLP'nin Geleceği: Zorluklar ve Fırsatlar.

Benzer şekilde, VNLP, temel metin normalleştirmeden gelişmiş token sınıflandırma modellerine kadar görevleri kapsayan, Türkçe için özel olarak tasarlanmış eksiksiz, açık kaynaklı bir NLP paketi sunmaktadır (Turker vd., 2024). Bu gelişmeler, Türkçe NLP araçlarının CLARIN gibi uluslararası altyapılara entegre edilmesiyle tamamlanıyor ve daha geniş araştırma iş birliğini kolaylaştırıyor (Adalı, 2024). Türkçe dilbilgisinin mantıksal yapısı, özellikle soru-cevap sistemleri gibi alanlarda gelecekteki NLP gelişmeleri için avantaj sağlayabilir. Bu kaynaklar ve araçlar gelişmeye devam ettikçe, Türkçe'de daha doğru ve verimli NLP uygulamalarının, potansiyel olarak daha yaygın olarak çalışılan diller için mevcut olanlara rakip olacağını öngörebiliriz. Gelecekte, Türkçe metinlerde duygu analizi, siber zorbalığın belirlenmesi ve duygu tanıma gibi özel alanlara daha fazla odaklanması da söz konusu olabilir. Özellikle büyük modellerin eğitimi için gereken hesaplama kaynakları açısından zorluklar devam ederken, Türkçe NLP'nin gidişatı kesinlikle olumludur ve Türkçe dil işleme yeteneklerinin diğer dillerle eşleştiği veya aştığı bir gelecek vaat etmektedir.

SONUÇ

Türkçe Doğal Dil İşleme (NLP) teknolojileri, dilin kendine has yapısı ve az kaynaklı diller arasında yer alması nedeniyle çeşitli zorluklarla karşılaşmaktadır. Eklemeli dil yapısı, kelime türleri ve bağlam bağımlılığı gibi özellikler, Türkçe NLP modellerinin eğitimi ve doğruluğu üzerinde doğrudan etki yaratmaktadır. Ancak, bu zorlukların üstesinden gelmek için doğru stratejiler ve iş birlikleri kullanıldığında, Türkçe NLP'nin önünde büyük fırsatlar bulunmaktadır.

Türkçe NLP'nin Karşılaştığı Zorluklar

- **Dil Yapısının Karmaşıklığı:** Türkçe'nin eklemeli yapısı ve sondan eklemeli sözcük yapısı, veri etiketleme ve model eğitimi süreçlerini zorlaştırmaktadır.
- **Kaynak Eksikliği:** Türkçe dilinde büyük, temizlenmiş veri setlerinin ve yeterli model öncüllerinin azlığı, NLP'nin geniş ölçekli gelişimini sınırlamaktadır.
- **Yerel Diyalektler ve Sözcük Kullanımları:** Türkçe'nin farklı bölgelerdeki varyasyonları, tek bir modelin genelleştirilebilirliğini zorlaştırmaktadır.

Gelecekteki Fırsatlar

- **Yeni Veri Setleri ve Araçlar:** Yerel veri kaynaklarının artırılması, etiketleme süreçlerinin otomatikleştirilmesi ve açık kaynak projelere yatırım yapılması, Türkçe NLP'nin gelişimini hızlandırabilir.
- **Makine Öğrenimi ve Transfer Öğrenme:** Büyük dil modellerinin Türkçe'ye özel ince ayarları ve transfer öğrenme yöntemleri, sınırlı kaynaklarla yüksek doğruluk elde etmeyi mümkün kılmaktadır.
- **Üretken Yapay Zeka ve Çok Dillilik:** Türkçe'nin çok dilli modellerde daha geniş desteklenmesi, hem yerel hem de küresel çapta Türkçe'ye daha fazla teknolojik fırsat sunabilir.

Yerel ve Küresel İş Birliği

Türkçe NLP'nin gelişimi, sadece yerel araştırma topluluklarının değil, aynı zamanda uluslararası kuruluşların iş birliğini gerektirir. Türkiye içindeki üniversiteler, araştırma merkezleri ve teknoloji şirketlerinin, dünya çapındaki yapay zeka topluluklarıyla ortak çalışması, Türkçe'nin NLP alanındaki ilerlemesini hızlandırabilir.

Özellikle açık kaynak projelere destek ve veri paylaşımı bu iş birliğinin temel taşlarını oluşturabilir.

Türkçe'nin Yapay Zeka Çağında Avantaj Sağlayabileceği Alanlar

- **Eğitim ve Dil Öğretimi:** Türkçe NLP, dil öğrenme uygulamaları ve eğitim teknolojilerinde önemli bir fark yaratabilir.
- **Kamu Hizmetleri:** Türkçe odaklı chatbotlar ve dil modelleri, vatandaşlara daha etkili kamu hizmetleri sunulmasını sağlayabilir.
- **Küresel Rekabet:** Türkçe'nin yapay zeka çağında rekabetçi bir dil haline gelmesi, hem yerel şirketlere hem de uluslararası yatırımcılara fırsatlar sunar.

Sonuç olarak, Türkçe NLP'nin geleceği, dilin özgünlüğüne yönelik zorlukların üstesinden gelinmesi ve fırsatların değerlendirilmesiyle şekillenecektir. Türkçe, yapay zeka çağında teknolojik bir avantaj sağlayabilecek potansiyele sahiptir ve bu potansiyel, doğru stratejilerle tam anlamıyla kullanılabilir.

KAYNAKÇA

- A. Reshamwala, Dharendra S. Mishra, & Prajakta S. Pawar. (2013). *REVIEW ON NATURAL LANGUAGE PROCESSING*.
- Adalı, E. (2024). THE LOGIC OF TURKISH LANGUAGE FOR NLP. *Journal of Problems in Computer Science and Information Technologies*.
- Alecakir, H., B\ " ol\ " uc\ " u, N., & Can, B. (2022). TurkishDelightNLP: A Neural Turkish NLP Toolkit. *Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies: System Demonstrations*, 17-26.
- Alrumiah, S., & Al-Shargabi, A. (2022). Educational Videos Subtitles' Summarization Using Latent Dirichlet Allocation and Length Enhancement. *Computers Materials & Continua*. <https://www.techscience.com/cmc/v70n3/45033/pdf>
- Altinok, D. (2023). A Diverse Set of Freely Available Linguistic Resources for Turkish. *Annual Meeting of the Association for Computational Linguistics*. <https://aclanthology.org/2023.acl-long.768.pdf>
- Amit Shrivastava, J. K. J. (2020). Natural language processing: A literature survey. *International journal of communication and information technology*. <https://www.computersciencejournals.com/ijcit/article/13/1-2-5-725.pdf>
- Aydemir, E. (2023). Estimation of Turkish Constitutional Court Decisions in Terms of Admissibility with NLP. *2023 IV International Conference on Neural Networks and Neurotechnologies (NeuroNT)*.
- Baralis, E., Luca, C., & L., F. (2015). Generation and Evaluation of Summaries of Academic Teaching Materials. *2015 IEEE 39th Annual Computer Software and Applications Conference*.
- Benedetto, I., Lorenzo, C., L., F., Luca, C., & Moreno, L. Q. (2022). Leveraging summarization techniques in educational technology systems. *Annual International Computer Software and Applications Conference*.
- Cao Hui, F. Chiang Michael, Cimino J., & Friedman C. (2004). *Automatic Summarization of Patient Discharge Summaries to Create Problem Lists using Medical Language Processing*.
- Cavusoglu, I., Pielka, M., & Sifa, R. (2020). Adapting Established Text Representations for Predicting Review Sentiment in Turkish. *2020 IEEE 7th International Conference on Data Science and Advanced Analytics (DSAA)*, 755-756.
- Chakrabarti, D., Neelam, P., Udayan, B., Indranil, M., Satyaki, R., Jayanta, M., Nandini, R., & Prasun, N. (2018). Use of Artificial Intelligence to Analyse Risk in Legal Documents for a Better Decision Support. *IEEE Region 10 Conference*.
- Çagri, Ç. (2015). *Turkish NLP web services in the WebLicht environment*.
- Çöltekin, Ç. (2010). A Freely Available Morphological Analyzer for Turkish. *International Conference on Language Resources and Evaluation*.
- Deepika, S., Krishna N Lakshmi, & S S. (2021). Extractive Text Summarization for COVID-19 Medical Records. *2021 Innovations in Power and Advanced Computing Technologies (i-PACT)*.
- Demircan, M., Seller, A., Abut, F., & Akay, M. (2021). Developing Turkish Sentiment Analysis Models Using Machine Learning and E-Commerce Data. *International Journal of Cognitive Computing in Engineering*.
- Deniz, K., Alacan, M. M., Ecesu, O., & Sakar, C. O. (2022). Natural Language Processing-Based Product Category Classification Model for E-Commerce. *Signal Processing and Communications Applications Conference*.

- Ekinci, E., & Omurca, S. I. (2023). An alternative word embedding approach for knowledge representation in online consumers' reviews. *Pamukkale University Journal of Engineering Sciences*, 29(3), 220-229.
- Ercilasun, A. B. (2013). *The Place of Turkish among the World Languages*.
- Erdoğanymaz, C., & Mengunoğlu, B. (2022). An Original Natural Language Processing Approach to Language Modeling in Turkish Legal Corpus: Improving Model Performance with Domain Classification by Using Recurrent Neural Networks. *2022 Innovations in Intelligent Systems and Applications Conference (ASYU)*.
- Eryiğit, G., & Adalı, E. (2003). *AN AFFIX STRIPPING MORPHOLOGICAL ANALYZER FOR TURKISH*.
- Eryiğit, G. ulşen. (2014). ITU Turkish NLP Web Service. *Proceedings of the Demonstrations at the 14th Conference of the European Chapter of the Association for Computational Linguistics*.
- Eryiğit, G. ulşen, Nivre, J., & Oflazer, K. (2008). Dependency Parsing of Turkish. *Computational Linguistics*, 34(3), 357-389.
- G\" ulşen, E., & Kemal, O. (2006). Statistical Dependency Parsing for Turkish. *Conference of the European Chapter of the Association for Computational Linguistics*.
- Ghodratnama Samira, Zakershahra Mehرداد, & Beheshti A. (2021). Summary2vec: Learning Semantic Representation of Summaries for Healthcare Analytics. *IEEE International Joint Conference on Neural Network*.
- Haghighi, A., & Vanderwende, L. (2009). Exploring content models for multi-document summarization. *Proceedings of Human Language Technologies: The 2009 Annual Conference of the North American Chapter of the Association for Computational Linguistics on - NAACL '09*, 362.
- Hartmann, J., & Netzer, O. (2023). *NATURAL LANGUAGE PROCESSING IN MARKETING*.
- Huseyin, A., Necva, B., & Burcu, C. (2022). TurkishDelightNLP: A Neural Turkish NLP Toolkit. *North American Chapter of the Association for Computational Linguistics*. <https://aclanthology.org/2022.naacl-demo.3.pdf>
- Ibrahim, A. M., Alfonse, M., & Aref, M. (2023). A SYSTEMATIC REVIEW ON TEXT SUMMARIZATION OF MEDICAL RESEARCH ARTICLES. *International Journal of Intelligent Computing and Information Sciences*. https://ijicis.journals.ekb.eg/article_305254_e217f264a805c0839c02c92f63002fd.pdf
- Iyyappan K, S., & Balasundaram, Sr. (2023). A Multi Document Summarization of Learning Materials using Bigram Embedding Technique and Integer Linear Programming. *International Journal of Membrane Science and Technology*. <https://cosmosscholars.com/phms/index.php/ijmst/article/download/3149/2069>
- Johnson David, Zou Q., Dionisio J., Z. Liu Victor, & Chu W. (2002). Modeling Medical Content for Automated Summarization. *Annals of the New York Academy of Sciences*.
- Kayabaş, A., Schimit, H., Topcu, A. E., & Kılıç, Ö. (2019). TRMOR: a finite-state-based morphological analyzer for Turkish. *TURKISH JOURNAL OF ELECTRICAL ENGINEERING & COMPUTER SCIENCES*, 27(5), 3837-3851.
- Khaled, M. A. (2014). *Natural Language Processing and its Use in Education*.
- Malik, V., Mittal, R., & Shubhranshu, V. S. (2022). EPR-ML: E-Commerce Product Recommendation Using NLP and Machine Learning Algorithm. *International Conferences on Contemporary Computing and Informatics*.
- McKeown K. & Elhadad Noemie. (2006). *User-sensitive text summarization: Application to the medical domain*.

- Monika, A., Pooja, M., Utkarsh, S., Chaitanya, C., & Ngangbam, H. S. (2023). Evaluation of text summarization techniques in healthcare domain: Pharmaceutical drug feedback. *International Journal of Intelligent Decision Technologies*.
- Oflazer, K. (2014). Turkish and its challenges for language processing. *Language Resources and Evaluation*, 48(4), 639-653.
- Oflazer, K., & Saraçlar, M. (2018). Turkish and Its Challenges for Language and Speech Processing. İçinde *Theory and Applications of Natural Language Processing* (ss. 1-19). Springer International Publishing.
- Oliveira, L. M. R., Busson, A. J. e G., S. Neto, C. de S., Santos, G. N. P. dos, & Colcher, S. ergio. (2021). Automatic Generation of Learning Objects Using Text Summarizer Based on Deep Learning Models. *Anais do XXXII Simp\ 'osio Brasileiro de Inform\ 'atica na Educaço (SBIE 2021)*, 728-736.
- Oliveira, M. R., L., S., Allan, K. assio B. S. da C., & Carlos, de S. S. (2023). Summarization of Educational Videos with Transformers Networks. *Brazilian Symposium on Multimedia and the Web*.
- Ozturel, A., Kayadelen, T., & Demirsahin, I. (2019). A Syntactically Expressive Morphological Analyzer for Turkish. *Proceedings of the 14th International Conference on Finite-State Methods and Natural Language Processing*, 65-75.
- Özçift, A., Akarsu, K., Yumuk, F., & Söylemez, C. (2021). Advancing natural language processing (NLP) applications of morphologically rich languages with bidirectional encoder representations from transformers (BERT): An empirical case study for Turkish. *Automatika*.
<https://www.tandfonline.com/doi/pdf/10.1080/00051144.2021.1922150?needAccess=true>
- Pembe, F. C., & Say, A. C. C. (2004). A Linguistically Motivated Information Retrieval System for Turkish. İçinde *Lecture Notes in Computer Science* (ss. 741-750). Springer Berlin Heidelberg.
- Raghvendra Kumar, & B. K. Mishra. (2020). *Natural Language Processing in Artificial Intelligence*.
- Rajarshi SinhaRoy. (2021). A Study on the journey of Natural Language Processing models: From Symbolic Natural Language Processing to Bidirectional Encoder Representations from Transformers. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, 331-345.
- Safaya, A., Kurtuluş, E., Göktoğan, A., & Yuret, D. (2022). Mukayese: Turkish NLP Strikes Back. *Findings*.
- Sak, H., Güngör, T., & Saraçlar, M. (2010). Resources for Turkish morphological processing. *Language Resources and Evaluation*, 45(2), 249-261.
- Sert, M., Yıldırım, Y., & Haşlak, İ. (2021). Using Artificial Intelligence to Predict Decisions of the Turkish Constitutional Court. *Social science computer review*.
- Sharavana, K., Kedarnath, B., Jayanth, S. C. S., Jayant, C., & Meet, J. K. (2024). Evolution of Natural Language Processing: A Review. *Journal of Knowledge in Data Science and Information Management*.
- Sharma Neeraj & Jain Vaibhav. (2020). *Evaluation and Summarization of Student Feedback Using Sentiment Analysis*.
- Söyler, H. (2023). Biyoyakıt üretiminde yapay zeka uygulaması. İçinde *Mühendislikte yapay zeka araştırmaları* (ss. 23-36). Nobel Yayınevi.
- Söyler, H., Balki, M. K., & Sayin, C. (2023). Determination of optimum parameters for esterification in high free fatty acid olive oil and ultrasound-assisted biodiesel

- production. *Biomass Conversion and Biorefinery*, 13(13), 12043-12056. <https://doi.org/10.1007/s13399-021-01976-y>
- Söyler, H., Balki, M. K., & Sayin, C. (2024). The impact of injection timing and pressure on a CRDI engine's combustion characteristics. *Journal of Engineering Research*, S2307187724000439. <https://doi.org/10.1016/j.jer.2024.02.015>
- TOHMA, K., & KUTLU, Y. (2020). Challenges Encountered in Turkish Natural Language Processing Studies. *Natural and Engineering Sciences*, 5(3), 204-211.
- Turan, H., Kodaz, K., & Turan, G. (2016). *The Effect of NLP Education on the Teaching Profession in Turkey*.
- Turan, T., Nazan, N., & Kucuksille, E. (2020). Hukuk'ta Yapay Zeka: \c Çalışmalar ve Gelecek \ " Ong \ " or \ " uleri. *Mehmet Akif Ersoy \ " Universitesi Fen Bilimleri Enstit \ " us \ " u Dergisi*. <https://dergipark.org.tr/tr/download/article-file/1139253>
- Turker, M., Ari, M. E., & Han, A. (2024). VNLP: Turkish NLP Package. *arXiv.org*.
- Ueffing, N., Rokhlenko, O., & Goyal, A. K. (2019). First International Workshop on e-Commerce and NLP (ECNLP) Chairs' Welcome. *The Web Conference*.
- Uskudarli, S., Şen, M., Akkurt, F., Gürbüz, M., Gungor, O., Özgür, A., & Güngör, T. (2023). TULAP - An Accessible and Sustainable Platform for Turkish Natural Language Processing Resources. *Proceedings of the 17th Conference of the European Chapter of the Association for Computational Linguistics: System Demonstrations*, 219-227.
- Üsküdarlı, S., Şen, M., Akkurt, F., Gürbüz, M., Güngör, O., Özgür, A., & Güngör, T. (2023). TULAP - An Accessible and Sustainable Platform for Turkish Natural Language Processing Resources. *Conference of the European Chapter of the Association for Computational Linguistics*. <https://aclanthology.org/2023.eacl-demo.25.pdf>
- V. Geetha, & C K Gomathy. (2023). THE ROLE OF NATURAL LANGUAGE PROCESSING. *INTERANTIONAL JOURNAL OF SCIENTIFIC RESEARCH IN ENGINEERING AND MANAGEMENT*. <https://ijsrem.com/download/the-role-of-natural-language-processing/?wpdmdl=25497&refresh=6569792f9efb61701411119>
- Yildiz, O. T., Avar, B., & Ercan, G. (2019). *An Open, Extendible, and Fast Turkish Morphological Analyzer*. Incoma Ltd., Shoumen, Bulgaria.
- Zeytin, afer, & Gençay, E. (2019). *HUKUK VE YAPAY ZEK^ A: E-K\ . I\c S\ . I, MAL\ . I SORUMLULUK VE B\ . IR HUKUK UYGULAMASI*.
- Zhu, Q. (2023). Natural Language Processing in Teacher Training: A systematic review. *Lecture Notes in Education Psychology and Public Media*, 18(1), 83-90.

BÖLÜM 7

NÜKLEER MÜHENDİSLİKTE YAPAY SİNİR AĞLARININ UYGULAMALARI

Hüseyin ŞAHİNER
Dr. Öğr. Üyesi, Sinop Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Nükleer
Enerji Mühendisliği, hsahiner@sinop.edu.tr,
 0000-0002-3191-1590.

Artan bilgisayar teknolojisi ve matematiksel algoritmalar sayesinde elle çözülmesi mümkün olmayan problemlerin çözümünde bilgisayarlar hayatımızda önemli bir araç haline gelmiştir.

Yapay zeka nükleer mühendisliği de içeren birçok mühendislik alanında etkili bir araç olmakta ve kullanımı her geçen gün artmaktadır. Nükleer endüstride yapay zeka yöntemleri reaktör tasarım optimizasyonundan işletme ve kontrolüne kadar birçok alanda kullanılmaktadır. Genellikle matematiksel çözümlerin kolay elde edilemediği durumlarda kolaylık sağlar. Buna ek olarak tahmin alanlarında da geçmiş verileri kullanarak sistemlerin gelecekteki davranışını tahmin etmeye yarar.

Gerçek hayatta bazı karmaşık problemler, lineer ve lineer olmayan ya da bunların her ikisinin birleşiminden oluşan fonksiyonlar ve denklemlerle ifade edilebilir. Fizik gerçek doğa olayların davranışlarını matematiksel olarak ifade etmeye yarayan bilim dalıdır. Ancak gerçek doğa olayları bazen tam olarak temsil edilemez veya kolaylıkla çözülmez. Bazen de o olayın tüm davranışını temsil eden tüm parametreleri bilinemez. Böyle durumda girdiler ile çıktılar arasında bir kara kutu oluşur. İşte bu noktada yapay sinir ağları girdiler ile çıktılar arasında bağlantıların ne kadar kuvvetli olduğunu hata minimizasyonu yöntemleri ile bulabilir. Buna bağlantıların ağırlıkları denir. Bağlantılar arasındaki ağırlıklar eldeki verilerle bulunduğu için bu işleme eğitme (veya öğrenme) aşaması denir. Bazı kaynaklarda bu işleme “Makine Öğrenmesi” adı da verilmektedir. Bağlantılar arasındaki ağırlık değerleri bulunduktan sonra artık girdi olarak bilinen değerler böyle bir ağ yapısına verildiğinde ağırlıkları bulunmuş bağlantılar ile çıktı değerleri elde edilmiş olur. Buradaki bağlantı noktalarının ağırlıklarının elde edilmesi son yıllarda matematikçiler için çekici bir konu haline gelmiştir. Problemin türüne göre farklı

öğrenme algoritmaları geliştirilerek çözüme sunulmuştur. Ağırlıkların elde edilmesinde hata minimizasyonu teknikleri gerektiği için problemin türüne göre uygulanması gereken algoritmalar da farklılıklar gösterir (Haykin, 2011; Hagan vd., 2014; Gurney, 1997).


Makine öğrenmesi kavramı denetimli, denetimsiz ve pekiştirilmiş makine öğrenme yöntemlerini kapsamaktadır. Denetimli öğrenmede, bilgisayar kendini bir sistemin bilinen giriş verileri ile bunlara karşılık gelen çıktıları kullanarak eğitir. Denetimsiz öğrenmede ise hedef veri makineye sağlanmaz. Bunun yerine, makine girişlerdeki benzerlikleri bulur ve giriş verilerini kategorize eder. Makine öğrenmesinin birçok alt sınıfı bulunmaktadır. Bunlardan en bilinenleri *güçlendirilmiş karar ağaçları*, *destek vektör makineleri*, *radyal tabanlı fonksiyonlar* ve *çok değişkenli analiz* yöntemleridir (Ao vd., 2010). Yapay sinir ağı (Artificial Neural Network-ANN), makine öğreniminin bir başka sınıfıdır. Mühendislik, bilim, matematik, ekonomi ve birçok diğer disiplindeki problemleri çözmek için kullanılır. ANN, insan beyninin çalışma şeklini taklit eder. İnsan beyni, deneyimlerden öğrenir. Örneğin, bebekler nesneleri yumuşak ya da sert, sıcak ya da soğuk olduğunu anlamak için dokunarak öğrenmeye başlar. Küçük çocuklar ise nesneleri tanımlamak için kokularını, şekillerini ve renklerini öğrenir. İnsan beyninde öğrenme nöron hücreleri ile sağlanır (yaklaşık 10^{11} nöron ve her bir nöron için 10^4 bağlantı). Canlıdaki reseptörlerden gelen sinyaller, nöronlar arasında kimyasal süreçlerle sağlanan elektrik sinyalleri ile aktarılır. Bu süreç elektronikteki gibi sinyal iletiminden daha yavaştır. Ancak beyin hücrelerinde bulunan bağlantı sayısı çok daha fazla olması temel avantajdır. Bir nöron komşu nöronlardan gelen sinyalleri toplar ve bir eşik değeri ile karşılaştırır. Eğer gelen sinyal eşik değerinden yüksekse nöron bu sinyali sonraki bağlantılarına iletir. Eğer gelen sinyal değeri eşik değerinden küçükse iletim gerçekleşmez. Yapay sinir ağları da insan beyninin çalışma prensibini matematiksel olarak taklit etme prensibine sahiptir. Bu işlemlerin matematiksel hale dökümü ile ANN yapısı oluşur (Haykin, 2011; Hagan vd., 2014; Gurney, 1997).

YAPAY SİNİR AĞLARI YAPISI

Genellikle bir yapay sinir ağı; bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı içerir. Bu katmanlarda bir veya birden fazla nöron bulunabilir. Bir sinir ağı yapısına yönelik kesin bir kılavuz yoktur çünkü yapı problem odaklıdır. Giriş katmanındaki ve çıkış katmanındaki nöron sayısı, probleme göre değişiklik gösterir. Problemin bağlı olduğu parametrelerin sayısı, genellikle katman sayısı ve bu

katmanlardaki nöron sayısında bağlayıcı bir etkidir. Eğer problemin bağlı olduğu parametreler tam olarak bilinmiyorsa bu durumda bu bilinmeyen etkileri temsil etmek için bir adaptasyon değeri atanır. Adaptasyon değeri atama işlemi nöronların bağlı olduğu bir üst katmandaki nörona ek ağırlık olarak uygulanır. Bu ek ağırlığa 'bias' (önyargı) denir. Bir bias ile başlangıç ağırlık vektörünün boyutu bir artar. Yapay sinir ağı, bias ile ya da bias olmadan tasarlanabilir. Ancak, daha iyi sonuçlar elde etmek için bias eklenmesi önerilir. Örneğin, yapay sinir ağları sıfır girdiler için sıfır çıktı üretebilir. Bu istenmeyen bir durumdur. Bu sorunun üstesinden gelmek için biaslar matematiksel bir yöntem olarak kullanılır. Biaslar genellikle sabit bir değere sahiptir (Hagan vd., 2014).

Tek bir nöronun tanımında (Şekil 1), ağırlıklı girdilerin toplamı bir aktivasyon (transfer) fonksiyonundan geçirilir. Aktivasyon fonksiyonları, bir nöronun çıktısına karar verir. Bu nedenle, çıkış katmanı için aktivasyon fonksiyonlarının seçimi kısmen problemin özelliklerine bağlıdır. Kullanıcılar lineer veya lineer olmayan kendi fonksiyonlarını seçebilirler. İleri beslemeli ağlarda lineer aktivasyon fonksiyonları kullanırken, geri beslemeli ağlarda düzgün türevlenebilir fonksiyonlar kullanır. Ayrıca, gizli katman için aktivasyon fonksiyonlarının seçimi dikkat gerektirebilir. [0,1] aralığında sonuç veren lojistik (sigmoid) fonksiyon, sistematik yanlılığa neden olabilir.



Şekil 1: Yapay Sinir Ağlarında kullanılan tek bir nöron bağlantıları

İleri beslemeli bir ağ, girdiden çıktıyı tek bir geçişte hesaplar. Geri besleme, son katmandaki türevleri hesaplar ve zincir kuralıyla türevleri geriye doğru iletir. Geri besleme, çok katmanlı ağlar için kullanılır.

Yapay sinir ağlarında en fazla zaman alan aşama öğrenme aşamasıdır. Ancak öğrenme gerçekleştiğinde problemin karmaşıklığına bakılmaksızın anında sonuç verir (Hagan vd., 2014).

Öğrenme sırasında yapay sinir ağı, performans fonksiyonuna dayalı olarak ağırlıkları, gradyanın en çok azaldığı yönde günceller. Standart performans fonksiyonu genellikle ortalama kare hata (MSE) olarak kullanılır. Yapay sinir ağı, bu hata minimize edildiğinde optimum ağırlıkları bulur. MSE' nin minimizasyonu, performans fonksiyonunun gradyanı ile doğrulanır. Eğitim verileri genellikle ağı eğitmek, doğrulamak ve test etmek için bölünür (Hagan vd., 2014).

$$x_{k+1} = x_k + a_k g_k \quad (1)$$

Eşitlik 11' de x_k mevcut ağırlık vektörünü, g_k mevcut gradyanı ve a_k öğrenme oranını temsil eder. Eğitim algoritmaları, yineleme sürecinde hatayı azaltmak için farklı matematiksel yaklaşımlar kullanılır. Eşitlik 1 gradyan azaltımı yöntemine bir örnektir. Öğretme yönteminin secimi problemin kompleksliğine, hedeflenen hata değerine, problemin tipine ve toplam veri miktarına bağlıdır.

Nöron bağlantıları arasında doğru ağırlıkları elde etmede kullanılan temelde Jacobian veya gradyan yaklaşımlarına bağlıdır. Bu algoritmaların en çok kullanılanları Levenberg- Marquard algoritması (LM), Bayes düzenlileştirmesi (BR), Ölçekli Eşlenik Gradyan (SCG) kullanılır.

LM algoritması, ağırlıkları bulmak için sayısal bir yaklaşım kullanır. LM, birçok durumda en hızlı algoritma olarak bilinir. Ancak, Newton yaklaşımı için gereken bellek nedeniyle büyük ağlar için daha az verimli olduğu bilinmektedir. Bu algoritma, desen tanıma problemlerinden ziyade doğrusal olmayan regresyon problemleri için kullanılır.

LM, performans dayalı Newton yaklaşımı bir algoritmadan oluşur ve nihai denklem Eşitlik 2 şeklindedir.

$$x_{k+1} = x_k + [J^T(x_k)J(x_k) + \mu_k I]^{-1} J^T(x_k) v(x_k) \quad (2)$$

J Jacobian matrisini, x_k ağırlık vektörünü, $J^T J$ Hessian matrisini temsil eder. v hatayı, I birim matrisini ve μ Hessian matrisinde tersi alınmayan durumlardan kaçınmak için bir parametreyi ifade eder. Eğer μ sıfıra çekilirse, algoritma Gauss-Newton yaklaşımına dönüşür.


Bayes düzenlileştirme, performans indeksini minimize etmek için olasılıksal bir yaklaşım kullanır. Bayes teoremine göre, iki rastgele olay (A ve B) varsa, bir olayın gerçekleşme olasılığı, Eşitlik 3 ile ifade edilir.

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)} \quad (3)$$

Teorik olarak, Bayes düzenleme, ağırlıkların rastgele ve Gauss dağılımına sahip olduğunu varsayar. Olasılıksal bir yaklaşım olduğundan, BR algoritması aşırı öğrenme (overfitting) problemini önler. Aşırı öğrenme problemi, ağda çok fazla nöron kullanılması nedeniyle ortaya çıkabilir. BR algoritması kullanıldığında doğrulama verisine ihtiyaç duyulmaz. Yüksek miktarda eğitim verisi olduğu durumda, BR ve LM aynı hatayı verir; çünkü biri sayısal, diğeri olasılıksal bir yaklaşımdır (Hagan vd., 2014; Gurney, 1997).

Önceki iki yönteme ek olarak, SCG yöntemi düşük bellek gereksinimleri nedeniyle büyük veri setleri için tercih edilir. SCG yöntemi, desen tanıma için büyük ağlarda verimli bir şekilde çalışır. SCG, gradyanın birinci derecesi ile doğrulanırken, LM Jacobian'da olduğu gibi gradyanın ikinci derecesi ile doğrulanır. Sonuç olarak, SCG diğer standart gradyan yöntemlerine göre doğrusal olarak daha hızlı yakınsar (Moller, 1993).

Şekil 2' de Yapay Sinir Ağlarında sık kullanılan üç önemli algoritmanın bellek ve zaman performans karşılaştırmaları verilmiştir. Burada zaman ve bellek kullanımı açısından SCG algoritmasının kullanımı en düşük olsa da bu algoritma her problem için kullanılabilir anlamına gelmez. Bu da daha önce belirtildiği gibi problemin türü, problemin karmaşıklığı, veri setine bağlıdır. SCG genellikle büyük ağlarda desen tanıma alanlarında tercih edilirken, BR büyük veri setlerinde daha iyi zaman ve bellek kullanımı açısından performansı SCG' ye göre daha düşüktür. LM genellikle regresyon problemlerinde çok tercih edilir. Birçok alanda aslında hızlı performans gösterse de büyük ağlar (Fazla nöron sayısı, fazla gizli katman sayısı) olduğu durumlarda zaman ve bellek açısından kötü bir performans gösterir.



Şekil 2: Sıklıkla kullanılan algoritmaların performans karşılaştırmaları

NÜKLEER UYGULAMALAR

Nükleer teknolojiler; enerji üretiminden, medikal uygulamalara kadar birçok alanda kritik bir rol oynamaktadır. Aynı zamanda yüksek kapasite faktörü¹, yüksek enerji yoğunluğu ve düşük karbon salınımı sayesinde modern dünyanın enerji ihtiyacını karşılamada önemli bir kaynaktır. Nükleer mühendisliğin amacı bu teknolojilerde çözülemeyen problemlere bir çözüm önermektir. Ancak bazı problemlerin davranışları tam temsil edilemediği için hesaplama maaliyeti ve güçlüğü içerir. Özellikle reaktör ile ilgili bazı hesaplamalar günler sürebilmektedir. Bazen bu hesaplamalarda anlık değer gerekebilir. Bunun için önceden elde edilmiş, öğretilmiş bir sistemden sonuç almak daha kısa sürelidir.

Son yıllarda yapay zeka ve makine öğrenmesi birçok alanda çığır açıcı gelişmelere öncülük etmektedir. Modern nükleer tesisler, nükleer hesaplamalar büyük verilerden üretir. Bu verilerin elde edilmesi, analizi ve optimizasyonu açısından yapay zeka ve makine öğrenmesi önemli bir araç haline gelir (Avdic vd., 2010; Damgov ve Litov, 2002; Doostmohammadi vd. 2009; Dragovic vd., 2005).

Yapay sinir ağlarının nükleer teknolojilerde kullanımı nükleer endüstri, reaktör modellemesi ve kontrolü, radyasyon koruması ve çevresel etkiler, nükleer güvenlik sistemleri, nükleer tıp, atom çekirdeği davranışlarında genellikle tahmin amaçlı kullanılmakta popülerliği artmıştır (Abdel-Aal ve Al-Haddad, 1997; Akkoyun vd., 2013; Ferreira vd., 2010).

Nükleer güç endüstrisinde reaktörlerin güç kapasitelerinin kullanımı ile ilgili çalışmalarda kullanışlı bir araçtır. Elektrik üretiminin ihtiyaç ve taleplerinin önceki yıllara göre eğilimlerine göre reaktörün güç planlaması yapılmasında iyi bir tahmin aracı olarak kullanılabilir. Reaktörlerin türlerine göre, sayılarının artış hızlarına göre, kullandıkları yakıtlara göre ve yakıt türünün rezervine göre bu rezervin hangi şekilde nasıl yetebileceğinin tahmin ve eğilim çalışmalarında kullanılabilecek bir araçtır.

Reaktör modelleme çalışmalarında kritiklik-yakıt, kritiklik-geometri gibi çalışmalarda kolay uygulanabilecek bir çalışmadır. Reaktör çalışırken reaktörün kontrolü ile ilgili verilerin kullanılması ile kontrol çubukları veya kimyasal dolgu kullanımı ya da reaktörün yakıtından maksimum faydalanma gibi çalışmalarda kullanım kolaylığı sunar.

¹ Kapasite Faktörü: Bir enerji üreten sistemin çalıştığı süre boyunca enerji üretimini ifade eder.

Reaktörlerin çalışma parametrelerini optimize etmek için önceden elde edilmiş veya önceden simüle edilmiş durumlar rahatlıkla kullanılabilir. Reaktörde güç kontrollerinin ve ölçümlerinin yapıldığı sensör hatalarının tespiti için kullanımları da vardır. Nükleer tesislerde güvenlik kritik bir unsurdur. Tesiste veya reaktörde meydana gelecek sistemsel arıza veya anomalilere karşı daha güvenli yaklaşım ve hazırlık durumlarının elde edilmesine yardımcı olur. Reaktörde radyasyon yayılımının takibinde radyasyon algılama sistemlerinin takibinde (Varley vd., 2015) ve oluşabilecek anomalilerin tespitinde hızlı bir araçtır.

Bahsedilen anomalilerin tespitinde hızlı bir araç olması nükleer güvenlikte de önemli bir aktördür. Güvenlik açısından düzenleyici kurumların gözünde reaktör işletmelerinin sabıka durumlarının temiz kalmasını sağlamakta kullanılabilir. Reaktör işletme senaryoları ile personel eğitimlerinde kullanımı da mümkündür. Bu senaryolar esnasında personelin vereceği aksiyonlar karşısında olabilecek reaktör reaksiyonlarını tahmin edebilir. Bunun aksi durumu ile personel eğitimi sağlanabilmesi için anlık tepki veremeyen Monte Carlo hesaplamaları kullanılması gerekir. Monte Carlo hesaplamaları istatistiki bir hesaplama yöntemi olduğu için doğru ve yakın sonucun üretimi için çok veri üretme ve hesaplama gerektirir. Eğitim sırasında bu mümkün olmadığı için personelin göstereceği aksiyonlara karşı anlık reaksiyon verilemez. Monte Carlo yerine daha hızlı hesaplamalar olan difüzyon denkleminin çözümü ile tablolaştırılmış veriler önceden üretilir. Ancak bu şekilde üretilen sonuçlar her zaman doğru olmayacağı gibi önceden tahmin edilememiş bir durum oluştuğunda tabloda o durum ile ilgili veri olmayacağı için personel aksiyonlarına tepki verilemeyecektir. Bu olumsuzlukları önceden öğrenmesi gerçekleştirilmiş bir yapay sinir ağı kolaylıkla ve hızla yerine getirebilir (Vigneron vd., 1996).

Nükleer uygulamalar ve araştırmalar çevresel etkileri ve uzun süreli etkileri nedeniyle güvenlik standartlarının en üst düzeyde tutulması gereken çalışmalardır. Nükleer tesislerde acil durum müdahaleleri için karar mekanizmalarında ANN başvurulan yöntemlerdendir. Bu yöntem acil durumda hızlı karar verme ve iyileştirilmiş acil durum protokolleri oluşturulmasına olanak sağlar. Acil durumu meydana getiren anomalileri tespit edecek sensörlerden gelen verilerin anında karar sürecini oluşturur. Kazaların başta önlenmesi için, kaza durumu meydana geldiğinde uygun standartlara göre acil müdahale yapılması için zaman çok önemlidir. Destekli karar verme mekanizmaları için

yapay sinir ağlarının kullanımı çok kritik bir öneme sahiptir. Kaza koşullarında radyasyon yayılımı, çevresel faktörler (atmosferik kararlılık, rüzgar yönü ve şiddeti, uygun atmosferik yayılım modeli), tesis durumu için uygun müdahale ve aksiyon modelleri oluşturulabilir. Bu modeller radyasyonun nerelere yayılacağı ve etkisinin ne kadar süreceği konusunda tahminler sağlayarak halk sağlığını korumada önemlidir. Bir radyasyon salınımlarında yapay sinir ağları ile elde edilmiş algoritmalarla tehlike altındaki bölgelerin haritaları hızlıca oluşturulabilir. Bu da acil müdahale ekiplerinin kaynaklarını verimli kullanmasına da olanak sağlar. Bir kaza durumu veya anomali durum oluşturulmadan da senaryolar üretilerek yine acil durum müdahale personellerinin eğitimleri sağlanabilir.

Yapay sinir ağlarının nükleer tıp alanında da kullanımı oldukça yaygındır. Nükleer tıpta teşhis, tedavi ve görüntüleme süreçlerinde önemli bir kullanıma sahiptir. Teşhis amaçlı olarak vücut anomalilerini görüntülerden elde etme gibi kolaylığın yanı sıra tedavi sürecinde de yol gösterici bir mekanizma olarak kullanımı vardır. Kanseri araştırmalarında tümör hücrelerinin yerinin, boyutunun ve yayılımının tespitini yapabilen bir yöntemdir. Özellikle tümör boyutlarının doğru tespitinde 3 boyutlu tomografi görüntülerinin tamamının detaylı bir şekilde incelenmesi insan tarafından mümkün değildir. Yapay sinir ağı algoritmaları ile bu ağır inceleme işlemi daha basit ve daha kısa sürede gerçekleştirilebilir. Teşhis, tedavi ve görüntüleme amacı ile kullanılan radyofarmasötiklerin üretimi ve kullanımı aşamasında doz optimizasyonu belirlemek için yapay sinir ağları yine etkili bir araç olarak kullanılabilir. Hastanın özelliklerine göre (yağ indeksi, cinsiyet, vs.) bireysel doz miktarının belirlenmesini sağlar. Bu da hastanın uygun doz ile kanser hücrelerinin yok edilmesini, sağlıklı hücrelerin ise korunmasını sağlar.

Radyasyon tespit ve analizlerinde de radyasyon kimliği ve miktarı konusunda kullanılabilirken, kantitatif analizlerde de başarılı bir analiz yöntemi olmaktadır (Keller ve Kouzes, 1994). Bu nedenle güvenlik amaçlı dedekte sistemlerinde yasaklı maddelerin tespitinde sıklıkla kullanımına da rastlanmaktadır (Nunes vd., 2002; Skrypnyk, 2016). Nötronlar girciliği yüksek parçacıklar olduğu için, her atom çekirdeği ile etkileşmesi (malzemenin kalınlığına bakmadan), etkileştiğinde de etkileştiği çekirdeğin gama radyasyonu yaymasına sebep olduğu için yasaklı maddelerin tespitinde nötron aktivasyon analizleri çok kullanılan bir yöntemdir (Varley vd., 2015). Ancak nötronlar bir malzeme içinde bulunan tüm çekirdeklerle etkileşme göstereceği için yasaklı maddenin o malzeme

içerisinde bulunup bulunmadığı ya tecrübe ve uzmanlık gerektirir ya da gözden kaçırılır. Ancak ilgili verilerle öğrenmesi gerçekleştirilmiş bir yapay sinir ağlarından böyle bir durumun kaçması mümkün değildir. Bu araştırmaların yanı sıra, gamma spektrumlarının açılması (Avdic vd., 2006), gamma spektrumlarındaki belirsizliklerin tahmini (Dragovic vd., 2005), etkileşim tanımlama (Damgov ve Litov, 2002), gamma spektrumlarında anomali tespiti (Sharma vd., 2012), hızlı nötron spektrumu tespiti (Kardan vd., 2004) gibi analizlerde de yapay sinir ağı kullanılmıştır.

Çekirdek özelliklerinin araştırılmasında da çekirdek davranışlarını elde etmek için yoğun deneysel çalışmalar yapılması gerekmektedir. Çekirdeklerin spinleri, enerji değerleri, bozunumları gibi özelliklerinin yanında etkileşmeler için tesir kesitlerinde yapay sinir ağları kullanılabilir. Her çekirdek için bu yoğun deneyleri yapmak gerekmez. Yoğun deneylerin bu tür çekirdekler için yapılması finansal bir maliyete, zamana ve personel kaynağına mal olur. Bu tür çekirdeklerin davranışları için yarı ampirik formüller ya da iki veri arasında interpolasyon yöntemleri kullanılmaktadır (Akkoyun vd., 2013). Ancak bu yöntemler her zaman doğru sonuçları vermeyebilir. Bunun yerine iyi eğitilmiş ve modellenmiş bir yapay sinir ağı daha doğru sonuçlar verebilir. Atom çekirdeklerinin gelen bir radyasyonla etkileşimlerinin ürünlerinin miktarını ve kimliklerini kullanarak tesir kesiti çalışmalarında kullanımı mümkündür. Buna ek olarak parçacık hızlandırıcıları ile yapılan deneylerde çok büyük veri setlerinin insan eli ile incelenmesi gerekmektedir. Örneğin bir bulut kabarcığı odası deneyinde binlerce fotoğrafta binlerce parçacık etkileşimleri çıkabilir. Çok büyük iş yükü maliyeti getiren bu işlem yapay sinir ağları tarafından çok kısa sürede yapılabilir.

Sonuç olarak, nükleer mühendislik teknolojilerinde insan tarafından yapılması mümkün olmayacak iş yüküne sahip veya insan hatasına çok bağlı durumların analizinde yapay sinir ağlarının kullanımı hem zaman hem de doğru sonuçlar açısından kullanımı kritik bir öneme sahiptir. Ancak yapay sinir ağları içerisinde kullanılacak algoritmalar da çok önemlidir. Yapay sinir ağları için geliştirilmiş matematiksel yaklaşımlar ve algoritmalar tamamen problemin türüne, karmaşıklığına ve veri setine bağlıdır. Ne yazık ki nükleer teknolojiler alanında reaktör etkileşmelerinden nükleer tıp alanına kadar çok farklı problemlerde kullanıldığı için burada ANN kullanımı için herhangi bir rehber yol gösteriminde bulunulmamıştır. Bununla birlikte yapay sinir ağları ve makine öğrenmesi konularında popüler olarak yapılan araştırmalar ve gelişen teknolojiler ile daha doğru veri

setlerinin üretilmesi yapay sinir ağlarının nükleer alanda kullanımını daha da tetikleyecektir. Özel alanlarda kullanımı ise yapay sinir alanının hızla artan popülerliğine çarpan etkisi yapacaktır.

KAYNAKÇA

- Abdel-Aal, R. E., & Al-Haddad, M. N. (1997). Determination of radioisotopes in gamma-ray spectroscopy using abductive machine learning. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 391, 275-288.
- Akkoyun, S., Bayram, T., & Kara, S. O. (2013). Improvement studies on neutron-gamma separation in hpge detectors using neural networks. *Cumhuriyet Science Journal*, 34(1), 42-51.
- Ao, S., Rieger, B. B., & Amouzegar, M. (2010). *Machine Learning and Systems Engineering*. Springer Science & Business Media.
- Avdic, S., Pozzi, S. A., & Protopopescu, V. (2006). Detector response unfolding using artificial neural networks. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 565, 742-752.
- Damgov, J., & Litov, L. (2002). Application of neural networks for energy reconstruction. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 482, 776-788.
- Doostmohammadi, V., Sardari, D., & Nasrabadi, A. M. (2009). Combined application of Monte Carlo method and neural networks to simulate qualitative prompt gamma neutron activation analysis. *Journal of Radioanalytical and Nuclear Chemistry*, 283, 403-407.
- Dragovic, S., Onjia, A., Stankovic, S., Anicin, I., & Bacic, G. (2005). Artificial neural network modelling of uncertainty in gamma-ray spectrometry. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 540, 455-463.
- Ferreira, F. J. O., Crispim, V. R., & Silva, A. X. (2010). Detection of drugs and explosives using neutron computerized tomography and artificial intelligence techniques. *Applied Radiation and Isotopes*, 68, 1012-1017.
- Ghal-Eh, N., Ahmadi, P., & Doost-Mohammadi, V. (2016). A quantitative PGNAA study for use in aqueous solution measurements using AmBe neutron source and BGO scintillation detector. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 808, 123-127.
- Gurney, K. (1997). *An Introduction to Neural Networks*. CRC Press.
- Hagan, M. T., Demuth, H. B., Beale, M. H., & Jesus, O. D. (2014). *Neural Network Design* (2nd ed.). Martin Hagan.
- Haykin, S. O. (2011). *Neural Networks and Learning Machines*. Pearson Education.
- Kardan, M. R., Koohi-Fayegh, R., Setayeshi, S., & Ghiassi-Nejad, M. (2004). Fast neutron spectra determination by threshold activation detectors using neural networks. *Radiation Measurements*, 38, 185-191.
- Keller, P. E., & Kouzes, R. T. (1994). Gamma spectral analysis via neural networks. In 1994 IEEE Nuclear Science Symposium and Medical Imaging Conference Record (Vol. 1, pp. 341-345).
- Moller, M. F. (1993). A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, 6(4), 525-533.
- Nunes, W. V., da Silva, A. X., Crispim, V. R., & Schirru, R. (2002). Explosives detection using prompt-gamma neutron activation and neural networks. *Applied Radiation and Isotopes*, 56, 937-943.

- Peng, K., Yang, J., Tuo, X., Du, H., & Zhang, R. (2016). Research on PGNAA adaptive analysis method with BP neural network. *Modern Physics Letters B*, 30, 1650386.
- Sang, H., Wang, F., Liu, L., & Sang, H. (2005). Detection of element content in coal by pulsed neutron method based on an optimized back-propagation neural network. *Nuclear Instruments and Methods in Physics Research Section B: Beam Interactions with Materials and Atoms*, 239, 202-208.
- Sharma, S., Bellinger, C., Japkowicz, N., Berg, R., & Ungar, K. (2012). Anomaly detection in gamma ray spectra: A machine learning perspective. In *2012 IEEE Symposium on Computational Intelligence for Security and Defence Applications* (pp. 1-8).
- Skrypnyk, A. I. (2016). Artificial neural networks in gamma spectrum based radionuclide identification. *Telecommunications and Radio Engineering*, 75(12).
- Varley, A., Tyler, A., Smith, L., & Dale, P. (2015). Development of a neural network approach to characterise ²²⁶Ra contamination at legacy sites using gamma-ray spectra taken from boreholes. *Journal of Environmental Radioactivity*, 140, 130-140.
- Vigneron, V., Morel, J., Lepy, M. C., & Martinez, J. M. (1996). Statistical modelling of neural networks in γ -spectrometry. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 369, 642-647.

BÖLÜM 8

ALTERNATİF ENERJİ KAYNAKLARININ KULLANIMI İLE FOSİL YAKIT KULLANIMININ YAPAY ZEKA İLE KARŞILAŞTIRILMASI VE MALİYET ANALİZİ

Hüseyin SÖYLER

Öğr. Gör. Dr., Sinop Üniversitesi, hsoyler@sinop.edu.tr

 0000-00021216-7049

Küresel enerji talebi; nüfus artışı, ekonomik gelişme ve yaşam standartlarındaki iyileşmeler nedeniyle artmaktadır (Esen et al., 2015; Uddin et al., 2016). Günümüzde enerji üretiminde fosil yakıtlar baskın durumda olsa da, bu kaynakların sınırlı rezervleri ve çevresel etkileri, sürdürülebilir alternatiflere geçişi zorunlu kılmaktadır (Gupta et al., 2018; Uddin et al., 2016). Güneş, rüzgar ve biyoenerji gibi yenilenebilir enerji kaynakları, enerji güvenliği ve iklim değişikliği endişelerini ele almak için potansiyel çözümler olarak ortaya çıkmaktadır (Gupta et al., 2018). Enerji güvenliği, küresel enerji politikalarının temel hedeflerinden biri olan, erişilebilirlik, , uygun maliyet ve kabul edilebilirlik unsurlarını kapsamaktadır (Tufail et al., 2018). Enerji kaynaklarının çeşitlendirilmesi, güvenlik risklerini azaltmak ve sürdürülebilir bir geleceği sağlamak için kritik öneme sahiptir (Esen et al., 2015; Tufail et al., 2018). Artan enerji talebini karşılarken çevresel etkileri en aza indirmek için enerji arzını optimize etmek, temiz teknolojileri teşvik etmek ve çeşitli enerji kaynaklarını etkin bir şekilde yönetmek esastır (Çavuş, V, 2021; Esen et al., 2015; Gupta et al., 2018)

2021 yılı itibarıyla fosil yakıtlar, küresel enerji tüketiminin %83'ünü oluşturmaya devam etmekte olup, çevresel sürdürülebilirlik açısından zorluklar yaratmaktadır. Sürdürülebilir enerji geleceğine ulaşmak için, yenilenebilir enerji üretiminin 6-8 kat artırılması, enerji verimliliğinin iyileştirilmesi ve koruma politikalarının uygulanması gibi çok yönlü bir yaklaşım gereklidir (Holechek et al., 2022). Yenilenebilir enerji kaynakları, küresel nihai enerji tüketiminin %20'sini oluşturmaya rağmen fosil yakıtlar, (özellikle kömür), baskın olmaya devam etmektedir. Enerji yoksulluğunun ele alınması kritik önem taşımaktadır. Çünkü 1,3 milyar insan elektriğe erişimden yoksundur (Kochtcheeva, 2020). 2050 yılına kadar yenilenebilir enerji kaynaklarına geçiş mümkün olabilir. Ancak

bu, birden fazla yolun zorunlu bir şekilde uygulanmasını, gelişmiş ülkelerde önemli yaşam tarzı değişikliklerini ve küresel işbirliğini gerektirmektedir (Holechek et al., 2022). Enerji ihtiyacını karşılamak için kullanılan kaynaklar genellikle iki ana kategoriye ayrılır: fosil yakıtlar ve yenilenebilir enerji kaynakları. Ekonomik istikrar, çevrenin korunması ve enerji güvenliği için bu kaynakların dengeli bir şekilde kullanılması çok önemlidir.

FOSİL YAKITLAR


Dünyanın enerji ihtiyacının büyük bir kısmı fosil yakıtlardan kaynaklanmaktadır. Doğalgaz, petrol ve kömür gibi fosil yakıtlar, elektrik üretiminde ve ulaşım sektöründe yaygın olarak kullanılmaktadır. Bununla birlikte, fosil yakıtların kullanımı nedeniyle meydana gelen karbon emisyonları, küresel ısınma ve iklim değişikliği gibi çevresel sorunlara yol açmaktadır (Balki et al., 2018).



Şekil 3. fosil yakıtlar ve çevreye etkileri (*Free Vector / Pollution Concept Background Flat Style*, n.d.)

YENİLENEBİLİR ENERJİ KAYNAKLARI

Sürdürülebilir bir enerji geleceği, yenilenebilir enerji kaynaklarına bağlıdır. Bu kaynaklar, güneş, rüzgar, hidroelektrik, jeotermal ve biyokütle gibi çevreye duyarlı enerji kaynaklarıdır.



Şekil 4. Yenilenebilir enerji kaynakları (*Alternatif Enerji Kaynakları ve Türkiye / TÜBİTAK Bilim Genç, n.d.*)

ALTERNATİF ENERJİ KAYNAKLARI VE FOSİL YAKITLARIN AVANTAJ VE DEZAVANTAJLARI

Alternatif Enerji Kaynaklarının Avantajları

Alternatif enerji kaynakları, fosil yakıtların sınırlı doğası ve çevresel etkilerine çözüm sunan sürdürülebilir seçenekler olarak öne çıkmaktadır. Çevresel sürdürülebilirlik, kaynakların yenilenebilirliği, enerji bağımsızlığı ve ekonomik faydalar alternatif enerji kaynaklarının başlıca avantajları olarak gösterilebilir. Ayrıca yenilenebilir enerji kaynakları; fosil yakıtların yerini alması, karbondioksit emisyonlarının azaltılması ve enerji üretiminin merkezden uzaklaştırılması gibi birçok fayda sağlar (Ploetz et al., 2016). Bununla birlikte teknolojik gelişmeleri teşvik eder ve çevreyi korurlar (Maradin, 2021). Bu kaynaklar düşük enerji verimliliği, hava koşullarına bağımlılık ve bazıları nadir bulunan büyük miktarlarda hammadde ihtiyacı gibi sorunlarla karşı karşıyadır (Armaroli & Balzani, 2011; Ploetz et al., 2016) Özellikle, mevsim, konum ve atmosferik değişiklikler güneş enerjisini etkiler. Enerji üretiminde değişkenlik, hidrojen gücü, hidrolik akümülatör istasyonları ve elektrikli akümülatörler gibi çözümler tarafından giderilmektedir (Ugli,

2019). Yenilenebilir enerji kaynakları, bu zorluklara rağmen dünya çapındaki enerji tüketiminin %20'den fazlasını oluşturmakta ve büyümeye devam etmektedir (Maradin, 2021).

Fosil Yakıtların Dezavantajları

Fosil yakıtlar, kolay ulaşılmasına rağmen dünya enerjisinin %80'inden fazlasını üretmektedir. Hava kirliliği, iklim değişikliği, toprak kirliliği ve su kirliliği gibi çevresel bozulmaya neden olurlar (Armaroli & Balzani, 2011). Fosil yakıtların yakılması, karbondioksit gibi zararlı sera gazlarının açığa çıkmasına yol açar, bu da ozon tabakasının incelmeye ve dünyanın ısınmasına sebep olur (Firoz, 2017). Fosil yakıt fiyatlarında bu çevresel etkiler, sağlık riskleri ve ekonomik sorunlar sıklıkla göz ardı edilmektedir (Armaroli & Balzani, 2011). Fosil yakıt rezervleri tükendiğinde, alternatif enerji kaynaklarına acil ihtiyaç duyulmaktadır. Biodizel ve biyogaz gibi biyoyakıtlar, daha az emisyon üreterek ve yakıt arz ve talebini dengelemeye yardımcı olabilir (Firoz, 2017)(Bhardwaj & Das, 2017). Bununla birlikte, artan biyoyakıt üretimi tarımı zorlayabilir ve gıda fiyatlarını etkileyebilir (Datta et al., 2019). Bu sorunları çözmek için fosil yakıtlardan daha sürdürülebilir alternatiflere geçmek çok önemlidir.

Enerji dönüşümü ve hibrit modeller:

Yenilenebilir enerji kaynaklarının kullanımının her geçen gün artmasına rağmen dünya nüfusundaki artış ve sanayileşme ile enerji talebi her geçen gün artmaktadır. Bu yüzden alternatif enerji kaynaklarının enerji ihtiyacını tek başına karşılayamamaktadır. Hibrit enerji dönüşüm sistemleri (HECS), verimliliği ve güvenilirliği artırmak için birden fazla enerji kaynağını birleştirir. Araştırmalar, HECS'in çeşitli yönlerini incelemiştir. Bunlar arasında paralel ve seri hibrit güç aktarma organlarında enerji dönüşüm verimliliği (Katrašnik Tomaž Trenc, Ferdinand Opresnik, 2007), güç kalitesini artırarak PV/batarya sistemlerinin şebeke entegrasyonu (Mohan et al., 2014), sağlam güç dönüşümü için hibrit geri besleme kontrol yöntemleri (Chai & Sanfelice, 2015) ve rüzgar-güneş hibrit sistemlerinin modellenmesi (Hasirci & Vural, 2022) yer almaktadır. Çalışmalar, paralel hibrit güç aktarma organlarının genellikle seri konfigürasyonlara göre daha iyi yakıt ekonomisi sunduğunu göstermiştir (Katrašnik Tomaž Trenc, Ferdinand Opresnik, 2007). Modifiye edilmiş anlık simetrik bileşenler teorisi gibi gelişmiş kontrol stratejileri, şebeke entegrasyonunu ve güç kalitesini artırabilir (Mohan et al., 2014).

Hibrit sistem araçları, analiz ve kontrolör tasarımı için sistematik yaklaşımlar sağlayarak performans ve sağlamlığı artırır (Chai & Sanfelice, 2015). Fotovoltaik güneş ve rüzgar enerjisini çok seviyeli inverterlerle birleştiren HECS tasarımları, değişen çevresel koşullar altında yükleri etkili bir şekilde besleyebilir (Hasirci & Vural, 2022).

YAPAY ZEKA İLE ENERJİ VERİMLİLİĞİ VE MALİYET OPTİMİZASYONU

Alternatif enerji kaynaklarının verimliliğini optimize eden yapay zeka algoritmalarının kullanımı giderek artmaktadır. Bu alanda kullanılan bazı yapay zeka algoritmaları ve teknikleri;

- Makine Öğrenmesi (Machine Learning)
- Derin Öğrenme (Deep Learning)
- Genetik Algoritmalar (Genetic Algorithms)
- Takviyeli Öğrenme (Reinforcement Learning)
- Fuzzy Logic (Bulanık Mantık)
- Çok Amaçlı Optimizasyon (Multi-Objective Optimization)
- Destek Vektör Makineleri (Support Vector Machines - SVM)

Bu yapay zeka algoritmaları, enerji üretiminden dağıtım ve tüketim yönetimine kadar tüm süreçlerde enerji verimliliğini artırarak sürdürülebilir enerji hedeflerine yardımcı olur (Karaoglu et al., 2023). Bu algoritmalar, alternatif enerji kaynaklarının (özellikle güneş ve rüzgar gibi değişken kaynakların) optimizasyonunu daha etkili hale getirir. Yapay zeka destekli maliyet modellemesi, alternatif enerji projelerinde maliyetlerin optimize edilmesine yardımcı olmak için yaygın olarak kullanılmaktadır. Bu tür projeler, büyük ölçekli veri analizi ve belirsizliklerin yönetimi gerektirdiği için yapay zeka (YZ) algoritmaları, hem yatırım maliyetlerini hem de işletme giderlerini öngörmede ve azaltmada önemli rol oynar. İşte bu süreçte kullanılan bazı YZ teknikleri ve modelleme yaklaşımları:

- Veri Tabanlı Tahmin Modelleri (Data-Driven Prediction Models)
- Optimizasyon Algoritmaları
- Takviyeli Öğrenme (Reinforcement Learning - RL)
- Yaşam Döngüsü Maliyet Analizi (Life Cycle Cost Analysis - LCCA)
- Talep Tahmini ve Enerji Fiyatlandırma Modelleri

- Karar Destek Sistemleri (Decision Support Systems - DSS)
- Blokzincir ile Yapay Zeka Entegrasyonu
- Dinamik Fiyatlandırma ve Enerji Ticareti
- Hibrit Yapay Zeka Algoritmaları

YZ destekli maliyet modellemesi, alternatif enerji projelerinde başlangıç maliyetlerini düşürerek ve operasyonel maliyetleri optimize ederek projelerin uzun vadede sürdürülebilirliğini sağlar. Yenilenebilir enerji projeleri, bu yapay zeka tabanlı yaklaşımlar sayesinde daha ucuz ve daha rekabetçi hale gelir (Karaoğlu et al., 2021).

Fosil Yakıtların Maliyet Analizi ve Optimizasyonu

Fosil yakıt çıkarma maliyetleri gün geçtikçe artmaktadır. Bu da enerji sektörünün kendi üretiminden daha fazlasını tükettiği ve diğer sektörler için daha az artık bıraktığı bir "enerji yayılımına" yol açmaktadır. Konvansiyonel gaz ve petrolün tükenmesi ve şeyl petrolü gibi pahalı, konvansiyonel olmayan kaynaklara olan bağımlılığın artması, bu eğilimi daha da kötüleştirmektedir (Kreps, 2020). Genel enerji durumu, fosil yakıtların ve yan ürünlerinin taşınma ve depolama maliyetlerinden tarafından önemli ölçüde etkilenmektedir. Biyoyakıt taşınma maliyetleri, depolama yerlerinin iyileştirilmesi yoluyla %79 azaltılabilir (Judd et al., 2010).

Karbon yakalama ve depolama (CCS) için taşınma ve depolama maliyeti mesafe, ölçek ve jeoloji gibi faktörlere bağlı olarak önemli ölçüde değişir ve 4 \$ ile 45 \$/ton CO₂ arasında değişebilir (Smith et al., 2021). CCS uygulamaları, özellikle Çin gibi ülkelerde bu değişkenlikten etkilenir. Enerjinin ana kaynağı fosil yakıtlar olduğu sürece, CO₂ emisyonlarını azaltmak için CCS teknolojileri büyük hacimlerde CO₂'yi işlemek ve taşımak için önemli bir altyapı ve maliyet gerektirir (Bennaceur, 2008).

Birçok ülke, fosil yakıtları ekonomik olarak desteklemek amacıyla mali yardımlar sağladığı için önemli ekonomik ve çevresel sorunlarla karşı karşıyadır. Bu sübvansiyonlar, tedarik maliyetlerinin açıkça düşük fiyatlandırılmasını ve çevresel zararlar ile kaybedilen vergilerden kaynaklanan örtük maliyetleri içermekte olup, 2020 yılında 5,9 trilyon dolara veya küresel GSYİH'nin %6,8'ine ulaşmıştır (Vernon et al., 2021). 2015 yılı için yapılan önceki tahminlere göre en büyük sübvansiyon sağlayıcılar Rusya, Çin ve Amerika Birleşik Devletleri olmuştur ve toplam 4,7 trilyon dolara ulaşmıştır (Coady et al., 2019).

Sübvansiyonların ortadan kaldırılması, hem hükümet gelirlerini önemli ölçüde artırabilir hem de küresel karbon emisyonlarını %36 oranında azaltabilir (Vernon et al., 2021). Çok sayıda hükümet, iklim değişikliğiyle mücadele etme çabalarına rağmen fosil yakıtları sübvansiyonla ederek piyasaları bozmakta ve emisyonları artırmaktadır (Stefanski, 2016).

Enerji sektöründe ekonomik sürdürülebilirliği sağlamak ve çevresel etkilerini azaltmak için fosil yakıtların maliyet analizi çok önemlidir. Yapay zeka (YZ) ve makine öğrenmesi (ML) teknolojilerinin yardımıyla, fosil yakıtların çıkarılması, taşınması, işlenmesi ve kullanımı sırasında ortaya çıkan maliyetler azaltılabilir. Fosil yakıt maliyetlerini optimize etmek için çeşitli stratejiler ve teknolojiler kullanılmaktadır. Bu stratejiler arasında yapay zeka ve makine öğrenmesi tabanlı tahmin modelleri, lojistik optimizasyonu ve rafineri verimliliğini artıran süreçler yer almaktadır. Fosil yakıtların üretim ve kullanım maliyetlerinin optimize edilmesi, enerji sektöründe kârlılığı artırmak ve çevresel etkileri en aza indirmek için önemli bir unsurdur. Yapay zeka, makine öğrenmesi ve diğer gelişmiş optimizasyon teknikleri, maliyet tahminlerinde ve süreç verimliliğinde önemli rol oynar. Bu teknolojilerin entegrasyonu, enerji üreticilerine rekabet avantajı sağlamak ve sürdürülebilir enerji üretimi için kritik bir adım olmaktadır.

YAPAY ZEKA İLE ALTERNATİF ENERJİ VE FOSİL YAKITLARIN KARŞILAŞTIRILMASI

Yapay Zeka Uygulamaları ile Enerji Arz ve Talep Yönetimi

Yapay zeka (YZ) teknikleri, enerji üretimi tahmininde giderek daha fazla kullanılmakta olup, geleneksel yöntemlere kıyasla daha doğru ve daha güvenilir sonuçlar vermektedir. (Chornovol et al., 2020; Yaren Tekin et al., 2021). Yapay zeka teknolojileri ile oluşturulan modeller, özellikle güneş ve rüzgar enerjisi gibi yenilenebilir enerji kaynakları için değerlidir. Çünkü doğru tahminler, şebeke entegrasyonu için kritik öneme sahiptir (Mane et al., 2024).

Yapay sinir ağları (ANN'ler), uzun-kısa süreli bellek (LSTM) ağları ve topluluk öğrenme yöntemleri gibi çeşitli YZ yaklaşımlarına bakıldığında; bu teknikler, enerji üretimi tahmininde zaman serisi verilerinin doğrusal olmayan ve karmaşık yapısını etkili bir şekilde ele alabilmektedir. Bu sayede maliyetlerin azalmasına yardımcı olmaktadır. Örneğin, hibrit bir topluluk çerçevesi, rüzgar ve güneş enerjisi üretimini tahmin etmede üstün performans göstermiş ve LSTM ve LightGBM gibi bireysel modelleri geride bırakmıştır (Baseer et al., 2023; Mane et al., 2024). YZ tabanlı hava tahmin modellerinden

yararlanarak, bu tahmin sistemleri daha verimli güç planlaması ve şebeke yönetimine katkıda bulunabilir (Mane et al., 2024). Bu sayede iş gücü ve toplam maliyet anlamında ciddi kazanımlar elde edilebilir.

YZ enerji arz ve talep döngülerini optimize etmek için giderek daha fazla uygulanmakta olup, bu uygulamalar hem fosil yakıtları hem de yenilenebilir kaynakları kapsamaktadır. YZ teknikleri, hava koşulları ve tüketim kalıplarını analiz ederek gelecekteki enerji taleplerini tahmin edebilir. Bu da elektrik üretiminin iyileştirilmesine ve maliyetlerin azaltılmasına yol açar (Das & Adhao, 2019). Ulaşım sektöründe, olasılık teorisine dayanarak belirsizlik altında karar verme ve tahmin yapma süreçlerini yöneten Bayesyen modelleri; araç büyüme oranlarını tahmin edebilir ve arz ile talep dengesini sağlamaya yardımcı olabilir (Arabi et al., 2018).

Yenilenebilir enerji tedarik zincirlerinde, YZ talep tahmin doğruluğunu artırır ve kaynak tahsisi optimizasyonunu geliştirir. Bu da sürdürülebilirliğe ve piyasa rekabetçiliğine katkıda bulunur (Taseen et al., 2023). Biyoenerji üretiminde, YZ teknolojileri hammadde bulunabilirliği, ekonomi ve tedarik zinciri yönetimi gibi zorlukları ele alırken, aynı zamanda biyokütleden enerji çıktısını tahmin eder ve biyodönüşüm süreçlerini optimize eder (Meena et al., 2021). YZ'nin çeşitli enerji sektörlerindeki bu uygulamaları, verimliliği artırma, maliyetleri düşürme ve daha sürdürülebilir enerji kaynaklarına geçişi destekleme potansiyelini göstermektedir.

Geleneksel ve yenilenebilir enerji kaynakları arasındaki maliyet farkları incelendiğinde, alternatif enerji projelerinin yüksek başlangıç maliyetlerine rağmen, işletme maliyetlerinin genellikle daha düşük olduğunu görülmektedir (Dale, 2013; Hearps & McConnell, 2011). Anlamlı karşılaştırmalar sağlamak için üretim profillerinin, piyasa değeri dalgalanmalarının ve yaşam döngüsü maliyetlerinin entegrasyonu kritik öneme sahiptir (Joskow, 2011). Bu zorluklara rağmen, yenilenebilir enerji teknolojileri, öğrenme oranları ve teknolojik ilerlemeler yoluyla maliyet düşüşü potansiyeli göstermekte olup, zamanla ekonomik rekabetçiliklerini artırabilir (Hearps & McConnell, 2011).

ENERJİ POLİTİKALARI VE YAPAY ZEKA TABANLI OPTİMİZASYON

Yapay zeka (YZ), sürdürülebilir enerji politikalarının şekillendirilmesi ve yenilenebilir enerjiye geçişin kolaylaştırılması için önemli bir araç olarak ortaya çıkmaktadır. YZ, enerji sistemlerini optimize edebilir, karar alma süreçlerini iyileştirebilir ve politika uygulamalarını geliştirebilir. Enerji politikalarına YZ entegrasyonu ile, adalet,

eşitlik ve kapsayıcılık iyileşirken, riskleri en aza indirebilir (Danish & Senjyu, 2023). YZ gelişiminin, özellikle çevresel izleme alanındaki iyileştirmeler yoluyla, yenilenebilir enerji tüketimine geçişi olumlu yönde etkilediği görülmektedir. Yenilenebilir enerji teknolojilerinde Ar-Ge'ye yönelik hükümet desteği ve piyasa temelli çevresel politikalar, YZ'nin enerji geçişi üzerindeki olumlu etkilerini daha da artırabilir (Yin et al., 2023). Hem AB hem de Japonya, iklim ve enerji politikalarında YZ'yi kullanarak, 2050 yılına kadar iklim nötrlüğüne (sıfır emisyon) ulaşmayı hedeflemektedir (Sokołowski, 2021).

Son araştırmalar, karbon emisyonlarını azaltmak ve enerji üretim süreçlerini optimize etmek için Yapay Zeka'nın (YZ) entegrasyonuna yoğunlaşmaktadır. YZ, karbon emisyonlarının doğru bir şekilde değerlendirilmesi, enerji sistemlerinin yapılandırılmasının optimize edilmesi ve karbondioksit giderim tesislerinin gerçek zamanlı izlenmesi için kullanılabilir (Li et al., 2024). YZ modelleri, çeşitli uygulamalarda CO₂ emisyonlarını önemli ölçüde azaltabilse de, hem olumlu hem de olumsuz çevresel etkilerini dikkate almak önemlidir (Delanoë et al., 2023). Ekonomik stratejileri sürdürülebilirlik uygulamalarıyla YZ aracılığıyla birleştiren bir yaklaşım olan Environomics çerçevesi, endüstriyel ortamlarda emisyonları %12-20 oranında azaltma potansiyeli göstermiştir (Suboyin et al., 2023). Özellikle kimya sektörü gibi enerji yoğun endüstrilerde YZ uygulamaları, süreçleri optimize ederek, emisyonları tahmin edip azaltarak ve sürdürülebilir uygulamalar geliştirerek sıfır emisyon hedefine ulaşma çabalarını destekleyebilir (Saggar & Nigam, 2023). Bu çalışmalar, YZ'nin iklim değişikliğiyle mücadelede ve çeşitli endüstrilerde sera gazı emisyonlarını azaltma potansiyelini vurgulamaktadır.

GELECEK PERSPEKTİFLERİ VE YENİLİKÇİ YAPAY ZEKA UYGULAMALARI

Akıllı şebekeler, evlerden mikro şebekelere kadar çeşitli ortamlarda otonom enerji yönetimini mümkün kılmaktadır. Ev Enerji Yönetim Sistemleri (HEMS), cihazların zamanlamasını optimize edebilir ve maliyetleri azaltabilir (Basit et al., 2017). Çoklu Aracı Sistemler (MAS), güneş mikro şebekelerinin yönetimi için dağıtılmış bir yaklaşım sunarak, dinamik koşullara hızlı karar verme ve tak-çalıştır esnekliği sağlamaktadır (Raju et al., 2016). Akıllı şebekelerde hibrit enerji yönetimi için otonom iletişim sistemleri, bağlı evler için yerel enerji yönetimini kolaylaştırabilir (Sabiri & Ailane, 2018). Akıllı binalar için katmanlı bir sistem mimarisi, çeşitli enerji kaynaklarını ve yönetim tekniklerini entegre ederek, farklı zaman ölçeklerinde otonom talep tarafı yük yönetimini mümkün kılabilir

(Costanzo et al., 2012). Bu yaklaşımlar, akıllı şebekelerin enerji verimliliğini artırma, maliyetleri düşürme ve otonom yönetim teknikleri aracılığıyla şebeke kararlılığını iyileştirme potansiyelini topluca göstermektedir.

Yapay Zeka (YZ), enerji sistemlerini devrim niteliğinde değişimler yaparak sürdürülebilirlik, verimlilik ve güvenilirliği artırmaktadır. Optimizasyon algoritmaları ve öngörücü analizler gibi YZ uygulamaları, sürdürülebilir enerji yönetiminde karar alma süreçlerini dönüştürmektedir (Kaur et al., 2024).

Makine Öğrenimi ve Derin Öğrenme teknikleri, özellikle güneş ve rüzgar enerjisinde, yenilenebilir enerji sistemlerinin performansını optimize etmek ve tahmin etmek için kritik öneme sahiptir (Bishaw et al., 2024). YZ destekli enerji yönetim sistemleri, enerji verimliliğini artırmak ve sürdürülebilir uygulamaları teşvik etmek için anahtar rol oynamaktadır (Zakizadeh & Zand, 2024). Ancak, enerji sistemlerine YZ entegrasyonu, teknolojik karmaşıklıklar, sosyo-ekonomik etkiler ve veri karmaşıklığı gibi zorluklarla karşı karşıyadır (Bishaw et al., 2024; Kaur et al., 2024). Bu sorunların üstesinden gelmek için şeffaf, adil ve kapsayıcı YZ uygulamaları gereklidir (Kaur et al., 2024). Gelecekteki araştırmalar, açıklanabilirliği artırmaya, önyargıyı azaltmaya ve insan-YZ işbirliği modellerini keşfetmeye odaklanarak dayanıklı ve sürdürülebilir bir enerji geleceği oluşturmayı hedeflemelidir (Kaur et al., 2024; Navarra, 2023).

SONUÇ

Fosil yakıtlar, uzun yıllardır tüm dünyada temel enerji kaynağı olarak kullanılmaktadır. Ancak, bu kaynakların sınırlı olması ve olumsuz çevresel etkileri sebebiyle yenilenebilir enerji kaynaklarına olan ihtiyacı artırmıştır. Fosil yakıtların her geçen gün tükenmesi; hem ekonomik ve çevresel, hem de enerjinin sürdürülebilirliği açısından ciddi sonuçlar ortaya çıkarabilir. Bu sorunlardan en önemlisi fosil yakıt rezervlerinin azalmasından dolayı enerji fiyatlarının artması ve enerji güvenliğinin tehlikeye girmesidir.

Bu bağlamda, yenilenebilir enerji kaynakları, fosil yakıtların tükenmesine karşı sürdürülebilir bir alternatif sunmaktadır. Güneş, rüzgar, hidroelektrik ve biyokütle gibi yenilenebilir enerji kaynakları, doğada bol miktarda bulunur ve çevreye zarar vermeden enerji üretimi sağlar. Yenilenebilir enerji kaynaklarının kullanımının artması bu alanda teknolojinin gelişmesine olanak sağlamıştır. Bu sayede kaynakların daha verimli, ekonomik ve ulaşılabilir olmasına imkan sağlamıştır.

Yenilenebilir enerji kaynaklarının bir başka önemi ise; fosil yakıtların yerini alarak ülkelerin enerji bağımsızlığını destekleyebilir. Ancak yenilenebilir enerjinin fosil yakıtların yerini alabilmesi için bazı zorluklar bulunmaktadır. Bu zorlukların giderilmesi ve enerjinin daha verimli üretilmesi ve tüketilmesi için yapay zeka destekli modellerin sayısı her geçen gün artmaktadır.

Ayrıca, yapay zeka ile alternatif enerji ve fosil yakıtların karşılaştırılması enerji sektörünün geleceği için çok önemlidir. Yapay zeka, enerji verimliliğini artırmak, maliyetleri düşürmek ve çevresel etkileri azaltmak için güçlü bir araç olarak ortaya çıkıyor. Küresel enerji ihtiyacının önemli bir kısmını uzun yıllardır karşılayan fosil yakıtlar, sınırlı rezervleri ve çevresel zararları nedeniyle sürdürülebilir bir çözüm değildir. Bu noktada yapay zeka, fosil yakıtların çıkarılması, taşınması ve işlenmesi süreçlerinin daha verimli bir şekilde yürütülmesine olanak tanır. Örneğin, yapay zeka destekli bakım ve lojistik sistemleri, operasyonel maliyetleri düşürür ve emisyonları kontrol eder. Alternatif enerji kaynakları ise yenilenebilir ve çevre dostu olmaları nedeniyle giderek daha fazla ilgi görmektedir.

Yapay zeka, enerji üretim ve dağıtım süreçlerini optimize ederek bu kaynakların entegrasyonunu ve yönetimini kolaylaştırır. Yapay zeka algoritmaları sayesinde güneş ve rüzgar enerjisi gibi değişken kaynakların tahmin edilmesi ve yönetimi daha güvenilir hale geldi. Yapay zeka uygulamaları aynı zamanda enerji depolama sistemlerini daha verimli hale getirmekte ve akıllı şebeke teknolojilerini geliştirir.

Sonuç olarak, yapay zeka, hem fosil yakıtların hem de alternatif enerji kaynaklarının etkinliğini artırmak için çok önemlidir. Enerji sektöründe yapay zekanın daha yaygın kullanılması, sürdürülebilir enerji çözümlerine geçişi hızlandırabilir ve dünya çapında enerji güvenliğini artırabilir. Yapay zeka destekli enerji sistemleri, gelecekte daha esnek, daha temiz ve daha verimli enerji altyapılarının temelini oluşturacaktır. Bu değişiklik, hem ekonomik hem de çevresel açıdan önemli faydalar sağlayarak enerji sektörünün sürdürülebilirliğini destekleyecektir.

KAYNAKÇA

- Alternatif Enerji Kaynakları ve Türkiye / TÜBİTAK Bilim Genç.* (n.d.). Retrieved November 17, 2024, from <https://bilimgenc.tubitak.gov.tr/makale/alternatif-enerji-kaynaklari-ve-turkiye>
- Arabi, M., Mohammad, A., & Shokrgozar, M. (2018). *Modeling transportation supply and demand forecasting using artificial intelligence parameters (Bayesian model)*. <https://api.semanticscholar.org/CorpusID:55664801>
- Armaroli, N., & Balzani, V. (2011). The legacy of fossil fuels. *Chemistry, an Asian Journal*, 6, 768–784. <https://api.semanticscholar.org/CorpusID:44554665>
- Balki, M. K., Çavuş, V., Duran, İ. U., Tuna, R., & Sayin, C. (2018). Experimental Study and Prediction of Performance and Emission in an SI Engine Using Alternative Fuel with Artificial Neural Network. *International Journal of Automotive Engineering and Technologies*, 7(1), 58–64. <https://doi.org/10.18245/ijaet.438048>
- Baseer, M. A., Almunif, A., Alsaduni, I., & Tazeen, N. (2023). Electrical Power Generation Forecasting from Renewable Energy Systems Using Artificial Intelligence Techniques. *Energies*. <https://api.semanticscholar.org/CorpusID:261576603>
- Basit, A., Sidhu, G. A. S., Mahmood, A., & Gao, F. (2017). Efficient and Autonomous Energy Management Techniques for the Future Smart Homes. *IEEE Transactions on Smart Grid*. <https://doi.org/10.1109/TSG.2015.2504560>
- Bennaceur, K. (2008). *CO2 Capture and Storage: A Key Carbon Abatement Option*. <https://api.semanticscholar.org/CorpusID:221027820>
- Bhardwaj, S. B., & Das, P. (2017). *A Review: Advantages and Disadvantages of Biogas*. <https://api.semanticscholar.org/CorpusID:212586282>
- Bishaw, F. G., Ishak, M. K., & Atyia, T. H. (2024). Review Artificial Intelligence Applications in Renewable Energy Systems Integration. *Journal of Electrical Systems*. <https://api.semanticscholar.org/CorpusID:269559074>
- Çavuş, V. S. M. (2021). *Yapay Zeka Uygulamalarında Güncel Konular ve Araştırmalar, Yapay Sinir Ağları ve Güneş Enerji Sistemlerinde Uygulamaları* (p. 153). Çizgi Yayınevi.
- Chai, J., & Sanfelice, R. G. (2015). Hybrid Feedback Control Methods for Robust and Global Power Conversion. *IFAC Conference on Analysis and Design of Hybrid Systems*. <https://api.semanticscholar.org/CorpusID:16233647>
- Chornovol, O., Kondratenko, G. V., Sidenko, I. V., & Kondratenko, Y. P. (2020). Intelligent Forecasting System for NPP's Energy Production. *2020 IEEE Third International Conference on Data Stream Mining & Processing (DSMP)*, 102–107. <https://api.semanticscholar.org/CorpusID:221916048>
- Coady, D. P., Parry, I. W. H., Le, N.-P., & Shang, B. (2019). Global Fossil Fuel Subsidies Remain Large: An Update Based on Country-Level Estimates. *IMF Working Papers*. <https://api.semanticscholar.org/CorpusID:182322938>
- Costanzo, G. T., Zhu, G., Anjos, M. F., & Savard, G. (2012). A system architecture for autonomous demand side load management in smart buildings. *IEEE Transactions on Smart Grid*. <https://doi.org/10.1109/TSG.2012.2217358>
- Dale, M. (2013). A Comparative Analysis of Energy Costs of Photovoltaic, Solar Thermal, and Wind Electricity Generation Technologies. *Applied Sciences*, 3, 325–337. <https://api.semanticscholar.org/CorpusID:111325201>
- Danish, M. S. S., & Senjyu, T. (2023). AI-Enabled Energy Policy for a Sustainable Future. *Sustainability*. <https://api.semanticscholar.org/CorpusID:258576785>
- Das, M., & Adhao, H. (2019). Artificial Intelligence for Energy Efficiency: Predicting the Unpredictable. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3422838>

- Datta, A., Hossain, A., & Roy, S. D. (2019). An Overview on Biofuels and Their Advantages and Disadvantages. *Asian Journal of Chemistry*. <https://api.semanticscholar.org/CorpusID:198361521>
- Delanoë, P., Tchuente, D., & Colin, G. (2023). Method and evaluations of the effective gain of artificial intelligence models for reducing CO2 emissions. *Journal of Environmental Management*. <https://doi.org/10.1016/j.jenvman.2023.117261>
- Esen, A. N., Duzgit, Z., Toy, A. Ö., & Günay, M. E. (2015). *An Overview of Energy Technologies for a Sustainable Future*. https://doi.org/10.1007/978-3-319-16024-5_1
- Firoz, S. (2017). *A review: Advantages and Disadvantages of Biodiesel*. <https://api.semanticscholar.org/CorpusID:212456041>
- Free Vector / Pollution concept background flat style*. (n.d.). Retrieved November 17, 2024, from https://www.freepik.com/free-vector/pollution-concept-background-flat-style_4946270.htm#fromView=keyword&page=1&position=34&uuid=a6d514c8-9972-468c-afc1-758b372ab034
- Gupta, J. G., De, S., Gautam, A., Dhar, A., & Pandey, A. (2018). Introduction to Sustainable Energy, Transportation Technologies, and Policy. In *Energy, Environment, and Sustainability*. https://doi.org/10.1007/978-981-10-7509-4_1
- Hasirci, H. Y., & Vural, A. M. (2022). Modeling and Simulation of PMSG based Wind-Solar Energy Based Hybrid Energy Conversion System. *2022 Global Energy Conference (GEC)*, 223–228. <https://api.semanticscholar.org/CorpusID:255267530>
- Hearps, P. J., & Mcconnell, D. (2011). *Renewable Energy Technology Cost Review*. <https://api.semanticscholar.org/CorpusID:134097175>
- Holechek, J. L., Geli, H. M. E., Sawalbah, M. N., & Valdez, R. (2022). A Global Assessment: Can Renewable Energy Replace Fossil Fuels by 2050? *Sustainability (Switzerland)*. <https://doi.org/10.3390/su14084792>
- Joskow, P. L. (2011). Comparing the Costs of Intermittent and Dispatchable Electricity Generating Technologies. *The American Economic Review*, 101, 238–241. <https://api.semanticscholar.org/CorpusID:12424015>
- Judd, J. D., Sarin, S. C., Cundiff, J. S., & Grisso, R. D. (2010). *An Optimal Storage and Transportation System for a Cellulosic Ethanol Bio-energy Plant*. <https://api.semanticscholar.org/CorpusID:111134027>
- Karaoglu, A., Ozcan, C., Pekince, A., & Yasa, Y. (2023). Numbering teeth in panoramic images: A novel method based on deep learning and heuristic algorithm. *Engineering Science and Technology, an International Journal*, 37, 101316. <https://doi.org/10.1016/J.JESTCH.2022.101316>
- Karaoğlu, A., Ozcan, C., Pekince, A., Yasa, Y., Meşeci, E., & Akdag, S. (2021). *SEGMENTATION OF BITEWING INTRAORAL X-RAY IMAGES WITH MASK R-CNN DEEP LEARNING MODEL*. <https://doi.org/10.13140/RG.2.2.19537.45921>
- Katrašnik Tomaž Trenc, Ferdinand Opresnik, S. R. (2007). Analysis of Energy Conversion Efficiency in Parallel and Series Hybrid Powertrains. *IEEE Transactions on Vehicular Technology*, 56, 3649–3659. <https://api.semanticscholar.org/CorpusID:44425994>
- Kaur, S., Kumar, R., Singh, K., & Huang, Y. (2024). Leveraging Artificial Intelligence for Enhanced Sustainable Energy Management. *Journal of Sustainability for Energy*. <https://doi.org/10.56578/jse030101>
- Kochtcheeva, L. V. (2020). *Renewable Energy: Global Challenges*. <https://api.semanticscholar.org/CorpusID:212411630>
- Kreps, B. H. (2020). The Rising Costs of Fossil-Fuel Extraction: An Energy Crisis That Will Not Go Away. *The American Journal of Economics and Sociology*, 79, 695–717. <https://api.semanticscholar.org/CorpusID:225927467>

- Li, G., Luo, T., Liu, R., Song, C., Zhao, C., Wu, S., & Liu, Z. (2024). Integration of Carbon Dioxide Removal (CDR) Technology and Artificial Intelligence (AI) in Energy System Optimization. In *Processes*. <https://doi.org/10.3390/pr12020402>
- Mane, O., Zagade, A., Sonpatki, S., Chavan, S., & Nimbalkar, K. (2024). Forecasting Renewable Energy Production Using AI-Based Weather Prediction Models. *International Journal For Multidisciplinary Research*. <https://api.semanticscholar.org/CorpusID:270326591>
- Maradin, D. (2021). ADVANTAGES AND DISADVANTAGES OF RENEWABLE ENERGY SOURCES UTILIZATION. *International Journal of Energy Economics and Policy*. <https://api.semanticscholar.org/CorpusID:234832070>
- Meena, M., Shubham, S., Paritosh, K., Pareek, N., & Vivekanand, V. (2021). Production of biofuels from biomass: Predicting the energy employing artificial intelligence modelling. *Bioresource Technology*, 340, 125642. <https://api.semanticscholar.org/CorpusID:236472744>
- Mohan, P. V. A., Suganya, G., & Sivanandhan, T. (2014). PV/BATTERY TO THE GRID INTEGRATION OF HYBRID ENERGY CONVERSION SYSTEM WITH POWER QUALITY IMPROVEMENT ISSUES. <https://api.semanticscholar.org/CorpusID:212597743>
- Navarra, D. (2023). Integrating artificial intelligence and sustainable technologies in strategic renewable energy and Power-to-X projects: A review of global best practices, risks and future prospects. *Society and Economy*. <https://doi.org/10.1556/204.2023.00012>
- Ploetz, R., Rusdianasari, R., & Eviliana, E. (2016). RENEWABLE ENERGY: ADVANTAGES AND DISADVANTAGES. <https://api.semanticscholar.org/CorpusID:114538278>
- Raju, L., Milton, R. S., & Amalraj Morais, A. (2016). Autonomous Energy Management of a Micro-Grid using Multi Agent System. *Indian Journal of Science and Technology*. <https://doi.org/10.17485/ijst/2016/v9i13/89294>
- Sabiri, Z., & Ailane, A. (2018). Smart and autonomous communication for hybrid energy management in smart grid. *3rd Renewable Energies, Power Systems and Green Inclusive Economy, REPS and GIE 2018*. <https://doi.org/10.1109/REPSGIE.2018.8488821>
- Saggar, A., & Nigam, B. (2023). Maximising Net Zero in Energy-Intensive Industries: An Overview of AI Applications for Greenhouse Gas Reduction. *Journal of Climate Change*. <https://doi.org/10.3233/jcc230003>
- Smith, E., Morris, J., Kheshgi, H. S., Teletzke, G., Herzog, H., & Paltsev, S. (2021). The Cost of CO2 Transport and Storage in Global Integrated Assessment Modeling. *SSRN Electronic Journal*. <https://api.semanticscholar.org/CorpusID:233683117>
- Sokołowski, M. M. (2021). Artificial intelligence and climate-energy policies of the EU and Japan 1. In *Regulating Artificial Intelligence in Industry*. <https://doi.org/10.4324/9781003246503-12>
- Stefanski, R. (2016). Into the Mire: A Closer Look at Fossil Fuel Subsidies. *DecisionSciRN: Climate Change \& Energy Decision-Making (Sub-Topic)*. <https://api.semanticscholar.org/CorpusID:55677086>
- Suboyin, A., Eldred, M., Thatcher, J., Rehman, A., Gee, I., & Anjum, H. (2023). Environomics Framework for Sustainable Business Practices: Industrial Case Studies on True Impact Reduction and Process Optimization Through AI. *Society of Petroleum Engineers - SPE Symposium: Leveraging Artificial Intelligence to Shape the Future of the Energy Industry, AIS 2023*. <https://doi.org/10.2118/214459-MS>
- Taseen, M., WangYongli, & Ali, E. (2023). Integration of Artificial Intelligence for Demand Forecasting and Resource Allocation in Renewable Energy Supply Chains. *2023 25th*

- International Multitopic Conference (INMIC)*, 1–7.
<https://api.semanticscholar.org/CorpusID:268548480>
- Tufail, M., Ibrahim, J. A., & Melan, M. Bin. (2018). *Conceptualizing energy security and the role of diversification as the key indicator against energy supply disruption*.
<https://api.semanticscholar.org/CorpusID:170025557>
- Uddin, N., Rashid, M. M., Mostafa, M. G., & others. (2016). Global Energy: Need, Present Status, Future Trend and Key Issues. *Global Journal of Research In Engineering*.
- Ugli, T. J. T. (2019). *The Importance of Alternative Solar Energy Sources and the Advantages and Disadvantages of Using Solar Panels in this Process*.
<https://api.semanticscholar.org/CorpusID:201608612>
- Vernon, N., Parry, I. W. H., & Black, S. (2021). Still Not Getting Energy Prices Right: A Global and Country Update of Fossil Fuel Subsidies. *IMF Working Papers*.
<https://api.semanticscholar.org/CorpusID:240242231>
- Yaren Tekin, B., Yasa, Y., Ozcan, C., Karaoglu, A., Pekince, A., Cilek, S., Ozdemir, D., & Meseci, E. (2021). Tooth Detection and Numbering with Instance Segmentation in Panoramic Radiographs. *1 St International Conference on Interdisciplinary Applications of Artificial Intelligence (ICIDAAI'21)*.
- Yin, H.-T., Wen, J., & Chang, C. (2023). Going green with artificial intelligence: The path of technological change towards the renewable energy transition. *Oeconomia Copernicana*. <https://api.semanticscholar.org/CorpusID:266888159>
- Zakizadeh, M., & Zand, M. (2024). Transforming the Energy Sector: Unleashing the Potential of AI-Driven Energy Intelligence, Energy Business Intelligence, and Energy Management System for Enhanced Efficiency and Sustainability. *2024 20th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP)*, 1–7.
<https://api.semanticscholar.org/CorpusID:268716119>

MÜHENDİSLİK ALANINDA YAPAY ZEKA-2

EDİTÖRLER

Prof. Dr. Murat SARIKAYA

Doç. Dr. Mustafa Kemal BALKİ

Öğr. Gör. Volkan ÇAVUŞ