

BİLGİSAYAR MÜHENDİSLİĞİ

ALANINDA ULUSLARARASI TEORİ,
ARAŞTIRMA VE DERLEMELER

Ekim 2023

EDİTÖRLER

DOÇ. DR. SELAHATTİN BARDAK
DR. ÖĞR. ÜYESİ MAHMUT KAYA

Genel Yayın Yönetmeni / Editor in Chief • C. Cansın Selin Temana

Kapak & İç Tasarım / Cover & Interior Design • Serüven Yayınevi

Birinci Basım / First Edition • © Ekim 2023

ISBN • 978-625-6760-15-8

© copyright

Bu kitabın yayın hakkı Serüven Yayınevi'ne aittir.

Kaynak gösterilmeden alıntı yapılamaz, izin almadan hiçbir yolla çoğaltılamaz.

The right to publish this book belongs to Serüven Publishing. Citation can not be shown without the source, reproduced in any way without permission.

Serüven Yayınevi / Serüven Publishing

Türkiye Adres / Turkey Address: Kızılay Mah. Fevzi Çakmak 1. Sokak

Ümit Apt No: 22/A Çankaya/ANKARA

Telefon / Phone: 05437675765

web: www.serüvenyayınevi.com

e-mail: serüvenyayınevi@gmail.com

Baskı & Cilt / Printing & Volume

Sertifika / Certificate No: 47083

BİLGİSAYAR MÜHENDİSLİĞİ ALANINDA ULUSLARARASI TEORİ, ARAŞTIRMA VE DERLEMELER

EKİM 2023

Editörler

Doç. Dr. Selahattin BARDAK

Dr. Öğr. Üyesi Mahmut KAYA

İÇİNDEKİLER

Bölüm 1

BÜYÜK VERİ VE DNA TABANLI VERİ DEPOLAMA ÇÖZÜMÜ

Esra ŞATIR 1

Bölüm 2

BİTKİ HASTALIKLARININ TESPİTİNDE DERİN ÖĞRENME

Yusuf BİLGEN, Mahmut KAYA 17

Bölüm 3

EVİRİMSEL HESAPLAMA

Ümit CAN 43

Bölüm 4

LİTYUM-İYON PİLLERDE DERİN SİNİR AĞLARIYLA BATARYA DURUMU TAHMİNİ VE YÖNETİMİ

Mehmet KURUCAN, Mete ÖZBALAN 59

Bölüm 5

HAVA KİRLİLİĞİ BİLİNCİNİN KARAR AĞACI MODELİ KULLANILARAK TAHMİN EDİLMESİ VE SİMÜLYONU: SİNOP İLİ ÖRNEĞİ

Mevlüt KILINÇ, Selahattin BARDAK 77

Bölüm 6

YAPAY ZEKA ALANINDA DİKKAT MEKANİZMASI MODELLERİ İLE GÖRSEL ALTYAZILAMA

İsa ATAŞ 103

Bölüm 7

COVID-19'UN YAYILIM TAHMİNİNE YÖNELİK LSTM TABANLI BİR TAHMİN MODELİ: G4 ÜLKELERİ İÇİN ÖRNEK BİR ÇALIŞMA

Anıl UTKU 117

Bölüm 1


BÜYÜK VERİ VE DNA TABANLI VERİ DEPOLAMA ÇÖZÜMÜ

Esra ŞATIR¹

1. Giriş

Dijital büyümede, veri patlaması, en önemli problemidir. Dijital platformlar, sosyal medya ortamları ile internetin yoğun kullanımı, verimli bir şekilde depolanıp işlenmesi gereken veri miktarını oldukça artırmaktadır (Dimopoulou ve Antonini, 2022).

Kısaca, dünya her dakika adeta veri üretimi ile boğulmaktadır. Üstelik bu üretim yavaşlamamaktadır. Yalnızca 2012 yılında üretilen veri miktarı yaklaşık 2.5 ZB olmuştur. Şekil 1' de görüldüğü gibi üretilen ticari verilerin miktarı ise her yıl artma eğilimindedir.



Şekil 1. Yıllara bağlı olarak üretilen veri miktarı eğilimi (https://www.atkearney.com/analytcs/ideas-insights/article/-/asset_publisher/hZFiG2E3WrIP/content/big-data-and-the-creative-destruction-of-today-s-businesmodels/10192?_101_INSTANCE_hZFiG2E3WrIP_redirect=%2Fanalytcs%2Fideas-insights, 27.07.2016)

Şekil 1' e göre, üretilen veri miktarının %40'lık yıllık bileşik büyüme oranına sahip olduğu söylenebilir (https://www.atkearney.com/analytcs/ideas-insights/article/-/asset_publisher/hZFiG2E3WrIP/content/big-data-and-the-creative-destruction-of-today-s-businesmodels/10192?_101_INSTANCE_hZFiG2E3WrIP_redirect=%2Fanalytcs%2Fideas-insights, 27.07.2016)

Dünyadaki toplam veri miktarının 2025 yılında 175 ZB' çıkacağı öngörülmektedir (Liu ve diğerleri, 2023). İstatistiklere dair daha ayrıntılı bir inceleme yapılacak olursa şu önemli maddeler listelenebilir:

- Her yıl, 2.5 kentilyon byte veri üretilmektedir.
- Dünyadaki verinin %90'lık kısmı yalnızca son iki yıl içerisinde üretilmiştir.
- 2020 yılındaki veri üretiminin, 2009 yılındaki veri üretimine nazaran 44 defa daha büyük olması öngörülmektedir.

- Dünya çapında üretilen ticari verinin her 1.2 yılda ikiye katlanması beklenmektedir.

- Muazzam miktardaki veri girişi, IT altyapılarını zorlamaktadır. Gerçekleştirilen son bir araştırmaya göre, yöneticilerin %55'i, bu verilerin IT sistemlerini yavaşlattığını söylemektedir.

Yetersiz veri yönetimi, işletmelerin hasılatlarının %35' ine mal olabilir (https://www.atkearney.com/analytics/ideas-insights/article/-/asset_publisher/hZFiG2E3WrIP/content/big-data-and-the-creative-destruction-of-today-s-businessmodels/10192?_101_INSTANCE_hZFiG2E3WrIP_redirect=%2Fanalytics%2Fideas-insights, 27.07.2016)

Bu koşullar neticesinde ortaya çıkan bilgi yükü yani “büyük veri”, verinin doğası, üzerinde çalışılacak süreç ve talebe bağlı olarak, büyük veri merkezlerinde bulunan server makinelerinde farklı teknolojiler kullanılarak organize edilir ve arşivlenir.

IDC (International Data Corporation)' ye göre veri depolama merkezleri ile ilgili önemli bazı istatistiksel bilgiler de şöyle maddelebilir:

- Global veri trafiği ile baş etmek için 2012 yılında 500.000 veri merkezi varken bu gün bu rakam 8 milyona ulaşmıştır.

- Veri depolama merkezlerinin yıllık ürettiği CO₂ emisyon miktarı, global hava yolu endüstri kuruluşlarının ürettiği miktara çok yaklaşmıştır.

- Her yıl, milyonlarca veri merkezi bir ülke büyüklüğünde elektrik enerjisi tüketmektedir. Hatta bazı modeller, kontrolsüz bırakılmaya devam edildikleri takdirde 2023 yılında bu veri merkezlerinin, dünya elektrik enerjisinden %10'un üzerinde tüketeceklerini öngörmektedir.

- Veri depolama merkezleri tarafından kullanılan elektrik enerjisi her 4 yılda bir 2 katına çıkmaktadır (Dimopoulou ve Antonini, 2022).

2040 yılına kadar üretilen verinin 3 yottabyte değerini aşacağı beklenmektedir. Bu devasa miktarda veriyi depolamak için 10⁹ kg' dan fazla yüksek saflıkta silisyum gerekmektedir. Ancak, 2040 yılında üretilen silisyum miktarı 10⁷-10⁸ kg civarında olacaktır (Ravil ve diğerleri, 2022). Bu problem ile birlikte yukarıda maddelenen hususlar, araştırmacıları veri depolamak amacı ile alternatif ve özellikle doğa dostu ortamları deneyimlemeye yönlendirmiştir.

Bu raporda, veri-büyük veri kavramları ve gereklilikleri yanında, günümüz koşulları altında gelecek zaman şartları da göz önünde bulundurularak gerekçeler ve önem anlatılacaktır. Bu bölümde büyük veri kavramına giriş yapılarak genel bir çerçeve içerisinde büyük verinin öneminden bahsedilmiştir. 2. Bölümde, büyük veriye dair global şirketlerin yaklaşımı ve dünya genelinde mevcut duruma yönelik öz bir bakış gerçekleştirilmiştir. 3. Bölümde,

veri depolama teknoloji ve çözümleri yanında belli başlı depolama kriterleri vurgulanmıştır. 4. Bölümde ise DNA tabanlı depolama üzerinde durulmuş, avantaj ve dezavantajları ile birlikte günümüz koşullarına uygulanabilirliği tartışılmıştır. 5. Bölümde ise sunulan rapora dair genel bir değerlendirme yapılmış ve geleceğe dair beklentiler ve yargı sunulmuştur.

2. Büyük Veri Üzerine Mevcut Durum

Birçok organizasyon, verinin karar verme sürecinin baş unsuru olduğu konusunda hemfikirdir. Bu nedenle büyük veriyi depolama konusu oldukça önem arz etmektedir (<http://www-03.ibm.com/systems/storage/big-data-storage/>, Son Erişim Tarihi: 27.07.2016). İşletmeler büyük veriyi, ticari modellerine yön vermek ve birçok alanda performans artışı sağlamak amacıyla kullanmaktadırlar. Geçtiğimiz iki yıl içinde işletmelerin %45'i iş zekası veya büyük veri konusunda girişimler gerçekleştirmişlerdir. Bu girişimlerin amacı, ürün ve hizmet tekliflerini büyütme, finans hizmeti veren bazı işletmelerde büyük veri, tamamıyla yeni iş modellerine olan güdüyü artırmıştır. Örneğin algoritmik ticarete büyük miktarda pazar verisi, değerleri anlık yakalamak için, fırsatları da tanımlayarak dakika dakika analiz edilir. Satış sektöründe ise büyük veri, gerçek zamanlı mevcut satın alma davranışlarının analizini kolaylaştırmaktadır. Bu tür hızlı talep manevraları ile mağazalar, satış seviyelerini yükseltmek için mal, stok seviyeleri ve fiyatları ayarlayabilmektedirler. Devletler de bu dönüşümün dışında kalmamaktadırlar. Bu kapsamda büyük veri, vatandaşlara götürülen hizmetleri geliştirme, vergi mükellefi bütçelerini optimize etme ve insansız araç ve uçak gibi gelişmiş silahlanma teknikleri ile ulusları daha iyi koruma amacıyla kullanılmaktadır

(https://www.atkearney.com/analytics/ideas-insights/article/-/asset_publisher/hZFiG2E3WrIP/content/big-data-and-the-creative-destruction-of-today-s-business-models/10192?_101_INSTANCE_hZFiG2E3WrIP_redirect=%2Fanalytics%2Fideas-insights, Son Erişim Tarihi: 27.07.2016).

Dünyada en geniş büyük veri şirketi Google' dır. Google işlemcileri günde 3.5 milyar sorgu gerçekleştirmektedirler. Ayrıca Google, 10 exabyte'lık (10 milyar gigabyte) veri depolamaktadır. Facebook, Microsoft ve Amazon bu konuda Google ile yarışmaktadırlar. Yalnızca Facebook 2.5 milyar içerik, 2.7 milyar "like" ve 300 milyon fotoğrafa sahiptir ve bunların tamamı 500 terabyte'lık veri etmektedir.

Veri depolamak amacıyla en fazla sunucuya sahip olan şirket ise Amazon'dur. Kendi tahminlerine göre 1.000.000.000 gigabyte'lık veriyi, 1.400.000'den fazla sunucu ile tutmaktadırlar. Google ve Microsoft'un ise 1.000.000 sunucuları olduğu düşünülmektedir (<http://cloudtweaks.com/2015/03/surprising-facts-and-stats-about-the-big-data-industry/>, Son Erişim Tarihi: 27.07.2016).

Büyük veri artışından yararlanan diğer bir sektör de bulut bilişimdir. İşleme gücü ve depolama miktarı büyük verinin kullanımını gerektirmiştir öyle ki birçok işletme kendi büyük veri kümelerini bulutta tutma ve işlemeye yönelik hizmet alımı gerçekleştirmektedir. Bir araştırmaya göre, katılımcıların %69' u şirketlerinin veri depolama ve yedekleme için bulut teknolojisini, % 56' sı ise veri çözümleme için bulut bilişimi kullandıklarını söylemektedirler (<http://www.statista.com/topics/1464/big-data/>, Son Erişim Tarihi: 27.07.2016).

Günümüzde ise büyük veri, iş dünyasının önceliğidir ve işletmelerin gelişimi için sayısız fırsat sunmaktadır. Bu konu ile ilgili gerçekleştirilen araştırmalara dair bazı önemli maddeler şunlardır:

- Yalnızca 2009 yılında, büyük veri üzerine projeler çok azdı ve toplam hasılat ise 100 milyon dolardı. 2012 senesinin sonunda ise, Fortune 500¹ listesindeki şirketlerin % 90' ı büyük veri konusunda en az bir kaç tane girişime sahiptirler.

- Avrupa' nın gelişmiş ekonomilerinde devlet yöneticileri, işletme verimliliği geliştirmede, büyük veriyi kullanarak 100 milyar Eurodan fazla meblağ biriktirebilmişlerdir (Bu kullanım, dolandırıcılık ve hatayı azaltmak ve vergi gelirlerini artırmak için büyük veriden yararlanma işlemlerini içermektedir.).

- Yetersiz veri, şirketlere işlevsel gelirlerinin %20-%35' i oranında kayba mal olabilmektedir.

- Yetersiz ya da kötü veri, birleşik devletleri şirketlerine yıllık 600 milyar dolara mal olmaktadır.

- Büyük verinin, depolama sistemleri sektöründe önemli etkilerinin olacağı beklenmektedir.

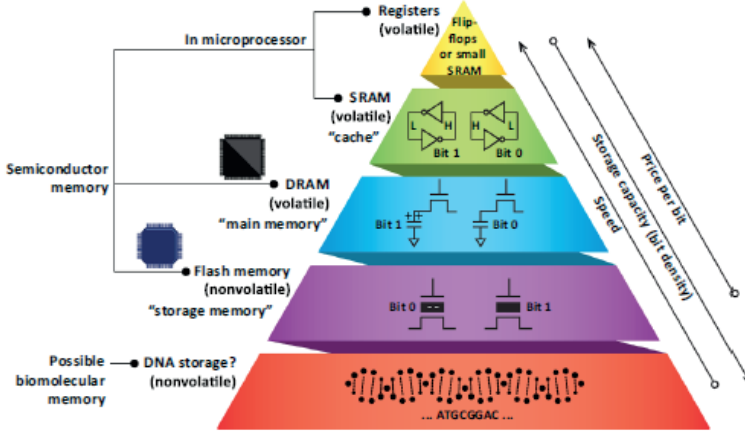
Global IT harcamalarındaki %5 büyümeye karşılık, her yıl üretilen global veride %40 planlanmış büyüme meydana gelmektedir (<http://wikibon.org/blog/big-data-statistics/> , Son Erişim Tarihi: 27.07.2016).

Büyük verinin depolanması üzerine yapılan bu kadar yatırımın amacı, şüphesiz ki hatasız bir şekilde saklanıp işlendiğinde büyük veri üzerinden gerçekleştirilecek işlem ve çözümlenmelerden elde edilen kazançtır.

3. Büyük Veri Depolama

Önceki bölümlerde büyük veri kavramı, günümüz teknolojisi ve pazarındaki yeri ve öneminden, mevcut durum da ele alınarak bahsedilmişti. Bu bölümde büyük veri ve büyük veri depolama konusundaki önemli özellik ve uyulması gereken kriterlerden bahsedilecektir.

Dijital bilgi işlemenin günlük hayatın vazgeçilmez bir parçası olduğu günümüz koşullarında, üretilen bilgiyi depolamak için yarı iletken teknolojisine dayalı bellekler kullanılmaktadır. Flash bellek ve rastgele erişimli bellekler (RAM), bu teknolojinin vazgeçilmez iki ögesidir. Şekil 2’ de bellek hiyerarşisi, hız, depolama kapasitesi ve bit başına maliyet karşılaştırması ile açıklanmaktadır. Ayrıca burada, kullanılan her bir teknolojiye dair ufak teknik detaylar da piramidin sol kısmında yer almaktadır (Kim ve diğerleri, 2023).



Şekil 2. Bellek hiyerarşisi (Kim ve diğerleri, 2023).

Şekil 2’ de sunulan hiyerarşiye göre piramidin sağ tarafı incelendiğinde, yukarıya çıkıldıkça erişim hızı (speed) artmakta, aşağıya inildikçe, depolama kapasitesi (storage capacity) artmakta ve yukarı çıkıldıkça bit başına depolama maliyeti (price per-bit) azalmaktadır (Kim ve diğerleri, 2023). Klasik bellek hiyerarşisi pramidinde yer almayan olası biyomoleküler depolama teknolojisi de artık günümüzde bu piramitteki yerini almıştır. Bu noktadan hareketle büyük veri depolama konusunun önemli bir problem olduğu anlaşılabilir. Büyük verinin dikkate alınması gereken dört ana özelliği (4V) şunlardır:

- Veri Ölçek Hacmi (Volume Scale of Data): Terabytes, records, transactions, tablolar, dosyalar
- Çeşitlilik (Variety): Farklı veri biçimleri
- Hız Analizi (Velocity Analysis): Yığın, dizi, yakın zamanlı, gerçek zamanlı

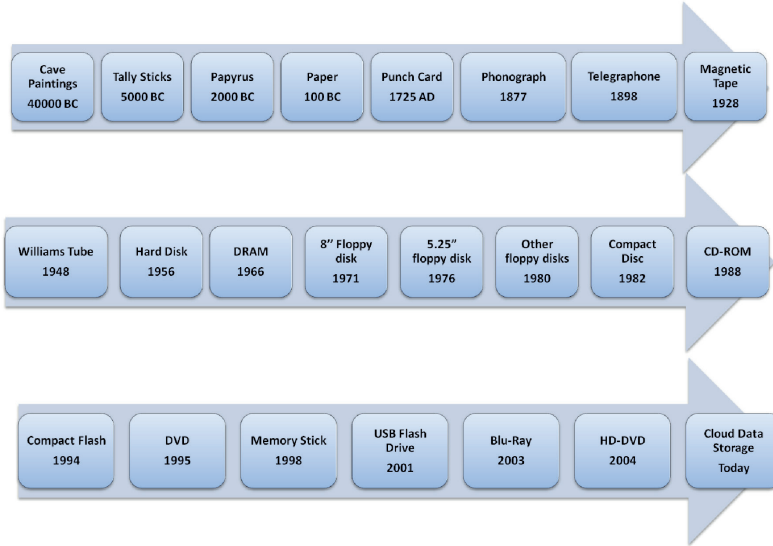
Doğruluk (Veracity): Verinin belirsizliği (http://www.snia.org/sites/default/files/Apurva_Vaidya_Big_Data_Storage_rev.pdf, Son Erişim Tarihi: 27.07.2016)

Şekil 2' de sunulan bellek hiyerarşi piramidinde vurgulanan kriterler ise, büyük veri depolamada talep edilen kriterler arasındadır:

a) Erişim: Depolama, veri biçimi, veri kaynağı ve konumdan bağımsız olarak, paylaşımına imkan vermeli, değerli tüm bilgiye erişimi güvence altına almalıdır.

b) Hız: Bir depolama alt yapısının, hızı maksimize etmek için, içerde ve dışarda düşük gecikme kapasitesi ve hızlı büyüme kabiliyeti olmalıdır. Çözümleme kaynağı, kayıt sistemine yakın olmalıdır.

Verimlilik: Otomatik karar motorları ve çözümleme odaklı veri yönetimi, veriyi doğru yerde tutmaktadır. Veri, analiz için en hızlı depolama birimine taşınmalı ve daha sonra kullanımda değilken daha düşük maliyetli depolama birimine geri çekilmelidir (<http://www-03.ibm.com/systems/storage/big-data-storage/>, Son Erişim Tarihi: 27.07.2016).



Şekil 3. Veri depolama ortamlarının kronolojik gelişimi (Limbachiya ve diğerleri,2022)

İnsanlar tarih boyunca ürettikleri bilgiyi saklamak için taş, kil, papirüs, tahta, kağıt vb. materyalleri kullanmışlardır. Şekil 3' de bu depolama ortamlarının kronolojik gelişimi yer almaktadır. Depolama amacı ile manyetik ortamlar 1920' lerin sonunda keşfedilmiş ve 1952 yılına kadar başı çekmiştir. Bu tarihten sonra ise silisyum teknolojisinin keşfi ile bilişim alanında devrşm yaşanmıştır. Ancak her yıl %50 oranında artış gösteren ve 2040 yılında 3 yottabyte' ı aşacağı öngörülen veri için 10^9 kg yüksek saflıkta silisyum üetilmesi gerekmektedir. Maalesef bu miktarın 2040 yılında bu miktarın 10^7 - 10^8 kg civarında sınırlı kalacağı öngörülmektedir (Ravil ve diğerleri, 2022). Bu ne-

denle biyolojik tabanlı depolama ortamlarına dayalı çözümler literatüre artık yerlerini almaya başlamaktadır. Microsoft şirketinin veri depolama amacı ile 10 milyon DNA zinciri satıl aldığı bilinmekte idi. Ayrıca, Microsoft araştırma ekibi lideri Karin Strauss' un orijinal bir alıntısı ve Türkçe çevirisi şu şekildedir:

“Demand for data storage has been growing at breakneck pace. Organizations and consumers who need to store a lot of data – for example, medical data or personal video footage – will benefit from a new long-term storage solution. We believe DNA may provide that answer.”

“Veri depolama talebi tehlikeli bir tempoda büyümektedir. Kişisel video kaydı, tıbbi veri gibi fazla miktarda veridi saklama ihtiyacı duyan şahıs ve şirketler, uzun süreli bir depolama çözümünden faydalanacaklardır. DNA' nın bu konuda cevap olacağına inanıyoruz.” (Limbachiya ve diğerleri, 2022)

Özetle, veri artış miktarı göz önünde bulundurulduğunda tarih boyunca geliştirilen fiziksel ortamların kapasite-yoğunluk dengeleri, fiziksel olarak yer işgal durumları ve çevre dostu olup olmadıkları konuları endişe uyandırmaktadır. Bütün bunların neticesinde, mevcut yöntemlere alternatif, kapasite-yoğunluk dengesi yüksek ve çevre dostu bir veri depolama ortamına ihtiyaç duyulmaktadır. DNA tabanlı veri depolama ortamının, ümit vadeden bir çözüm olduğuna inanılmaktadır. Bir sonraki bölümde DNA tabanlı depolama ortamı tüm hatları ile birlikte ele alınacaktır.

4. DNA Tabanlı Depolama

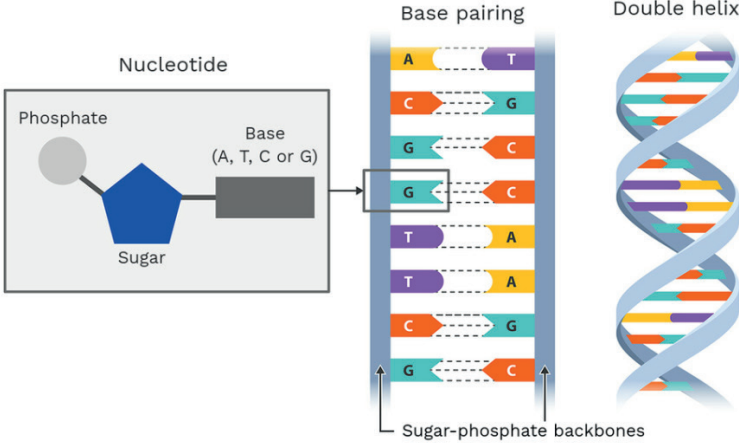
Günümüz verisinin çoğu manyetik ve optik ortamlarda depolanmaktadır. Bant teknolojisi son zamanlarda, 185 TB' a kadar geniş kartuşlarla, yoğunlukta önemli gelişmeler göstermiştir ve günümüzde ticari olarak mevcut en yoğun depolama 10GB/mm³ civarındadır. Bu gelişmelere rağmen, ZB boyutlarında veriyi depolama milyon birimlere mal olacaktır ve önemli ölçüde fiziksel alan işgal edecektir. Ancak depolama yoğunluğu önemli arşivsel konulardan yalnızca bir tanesidir; süreklilik de önemlidir. Diskler için 3-5 yıl, bantlar için ise 10-30 yıl kadar ömür biçilmiştir. Tüm dünyanın verisini muhafaza etmek istiyorsak, depolama kapasitesi ve sürekliliğine dair ciddi gelişimlere yönelmeye ihtiyacımız vardır.

Sentetik DNA dizileri dijital veri depolama amacıyla uzun zamandır potansiyel ortam olarak ele alınmaktadır. DNA, dikkat çekici bir seçenektir çünkü teorik olarak oldukça yoğundur (1 EB/mm³ üzerinde yoğunluğa sahiptir) ve uzun ömürlüdür; sert ve elverişsiz ortamlarda bile yarılanma ömrü 500 yılın üzerindedir. Ayrıca, DNA tabanlı depolama sonsuz geçerliliğe sahiptir. Hayat, DNA tabanlı olduğu müddetçe, DNA' yı işlemek ve okumak için güçlü sebepler vardır (<https://www.microsoft.com/en-us/research/publication/dna-based-archival-storage-system/> , Son Erişim Tarihi: 27.07.2016).

Bu bölümde DNA'nın yapısı, DNA tabanlı depolamada mevcut durum ve mevcut depolama teknolojileri ile karşılaştırılması yanında DNA tabanlı depolamanın nasıl uygulandığına dair yaygın yaklaşımlar ile literatürdeki somut örnekleri sunulacaktır.

4.1 DNA Yapısı

DNA (deoxyribonucleic acid), yaşayan organizmalarda kalıtımın temelidir. DNA yolu ile biyolojik bilgiler ebeveynlerden yavrulara aktarılır. Birbirine eş olan ve baz denilen 4 temel bileşenden oluşur; Adenine (A), Timin (T), Guanin (G), Sitozin (C) (Dimopoulou ve Antonini, 2022). Bu bazlar, her türü eşsiz yapan genetik bilgiyi içeren moleküllerdir. Bu bazlar vasıtası ile genetik bilgi ebeveynlerden yavrulara geçer. Bunun için DNA moleküllerinden, "replikasyon" denilen bu süreçte iki eşdeğer kopya oluşur. DNA aynı zamanda, bu genetik bilgiyi uzun süre tutacak kadar kararlı olmalıdır. İşte bu özelliği, DNA'yı veri depolama amacı ile cazip kılmaktadır (Lee ve diğerleri, 2020).



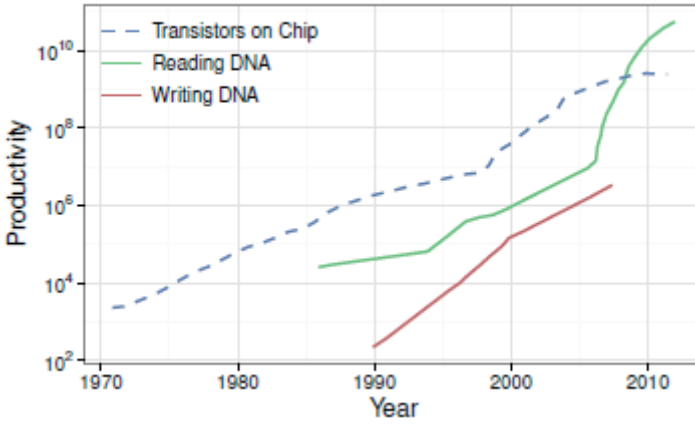
Şekil 4. DNA yapısı (<https://theory.labster.com/structure-dna/>) (Son erişim tarihi: 22.09.2023)

Şekil 4'te en solda DNA nükleotid yapısı görülmektedir. Bu yapı, fosfat, deoksiribo-şeker ve DNA bazlarının kimyasal olarak bağlanmaları ile oluşur. Her bir nükleotidi farklı yapan içerdiği bazdır. Şekil 4'te ortada ise bu bazların eşleşmeleri yer almaktadır. Adenin Timin ile, Guanin ise Sitozin ile eşleşerek baz çiftlerini oluşturmaktadır. En solda ise DNA replikasyonu sonucu oluşan sarmal yapı yer almaktadır (<https://theory.labster.com/structure-dna/>).

4.2. Mevcut Durum

DNA'da veri depolama için yazma işlemi aslında dijital veriyi DNA dizisine eşlemektir. Bu doğrultuda nükleotidlerden oluşan ilgili moleküller sentezlenir ve saklanır. Veri okuma ise DNA moleküllerini sekanslama ve

bilgiyi orijinal şekline geri getirmek için kod çözme işlemlerinden oluşmaktadır. Hem bu sentez hem de sekanslama yöntemleri, biyoteknoloji alanında standarttır. Bu nedenle günümüzde, sentezlenebilen veri hacmi çoğunlukla sentezleme ve sekanslama maliyetlerinden ötürü kısıtlıdır. Bir DNA depolama sisteminin aşması gereken belli başlı engeller vardır. İlk olarak DNA sentezleme ve sekanslama, nükleotid başına yaklaşık %1' lik hata ile mükemmellikten uzaktır. DNA dizileri depolama esnasında çözülebilmekte ve bu, veri bütünlüğünü tehlikeye atmaktadır. DNA depolamaya dair önemli bir nokta da, fazlalık bilgi ekleyerek, hataları tolere edebilecek kodlama metodları geliştirmektir (<https://www.microsoft.com/en-us/research/publication/dna-based-archival-storage-system/> , Son Erişim Tarihi: 27.07.2016).



Şekil 5. Carlson eğrileri: DNA sentez ve sekanslama teknolojilerinin Moore yasası ile karşılaştırılması

DNA üretimi, her gün, her kişiye düşen nükleotid sayısı ile ölçülmektedir. Günümüzde DNA sentezleme ve sekanslama, veri depolama bakımından uygulanabilir olmasa da, tarihsel gelişimi üssel bir şekilde gerçekleşmiştir. Moore yasasına karşı, maliyet azalması ve verimlilik bakımından bu gelişim Şekil 5' de gösterilmektedir. Sekanslama teknolojisindeki son gelişmelerin Moore yasasını gölgede bıraktığı, sekanslama üretiminin Moore yasasından daha hızlı büyüdüğü görülmektedir. Gen bilimi, akıllı ilaçların geliştirilmesi gibi biyoteknoloji alanındaki önemli uygulamaların bu ilerlemeleri teşvik ederek devam etmesi ve sonunda veri depolamayı elverişli bir hale getirmesi beklenmektedir (<https://www.microsoft.com/en-us/research/publication/dna-based-archival-storage-system/> , Son Erişim Tarihi: 27.07.2016).

Tablo1. DNA ve mevcut depolama çözümlerinin karşılaştırılması (Dimopoulou ve Antonini, 2022)

	Hard disk	Flash bellek	DNA
Okuma/yazma hızı ($\mu\text{s/bit}$)	$\sim 3,000-5,000$	~ 100	<100
Depolama ömrü (yıl)	>10	>10	>100
Güç tüketimi (watt/gigabyte)	~ 0.04	$\sim 0.01-0.04$	$<10^{-10}$
Veri yoğunluğu (bit/cm^3)	$\sim 10^{13}$	$\sim 10^{16}$	$\sim 10^{19}$

DNA depolamanın, depolama hiyerarşisinde en son seviye olduğu öngörülmektedir. Tablo 1' de DNA'nın diğer yaygın depolama ortamları ile okuma/yazma hızı (erişim zamanı), ömür, güç tüketimi ve yoğunluk bakımından karşılaştırılması görülmektedir. DNA, kapasite bakımından yoğun, elverişli ve uzun ömürlü bir ortam sunmaktadır. Öyle ki, tüm dünya tarafından üretilen dijital veriyi depolamak için teorik olarak 1kg DNA' nın yeterli olacağı bilim adamları tarafından öngörülmektedir (Dimopoulou ve Antonini, 2022). Bu son derece önemli avantajlarına rağmen DNA için erişim süresi saatler ile ölçülmektedir. Ancak bu problemi aşmak için DNA sentezleme ve sekanslama işlemleri, gerekli okuma ve yazma bant genişlikleri erişilebilir yapılarak, paralel bir şekilde gerçekleştirilebilir (<https://www.microsoft.com/en-us/research/publication/dna-based-archival-storage-system/> , Son Erişim Tarihi: 27.07.2016).

4.3. DNA Tabanlı Veri Depolama

Sentetik biyoloji alanındaki bazı gelişmeler, laboratuvar ortamında yapay DNA sentezlenmesini mümkün kılmıştır. Üretim aşaması yapay olasına rağmen, sentetik DNA gerçek DNA ile aynı özellikleri taşımaktadır. Tek fark, sentetik DNA' nın gen içererek kalıtsal aktarımdan sorumlu olma zorunluluğunun olmamasıdır. Bu da, herhangi bir dizilimde DNA sıralamasını mümkün kılmaktadır. Böylelikle herhangi bir bilgi, kodlama teknikleri kullanılarak DNA dizilerine dönüştürülebilir. Şekil 6' da DNA tabanlı veri depolama aşamaları şematik olarak yer almaktadır. Bilgi, DNA sekansına dönüştürüldükten sonra, yapay olarak laboratuvar ortamında sentezlenir. Sentezlenen yapay DNA ise, koruma ve depolama ömrünü uzatmak amacı ile özel küçük muhafaza (şişe, tüp vb.) saklanır. Depolanan DNA, ihtiyaç duyulduğunda özel sekanslama cihazları tarafından okunarak, bu DNA dizilerindeki bazlar dijital olarak elde edilir. Bu dijital bazlar kullanılarak ihtiyaç duyulduğunda saklanan bilgilere erişilebilir (Dimopoulou ve Antonini, 2022).



Şekil 6. DNA depolama adımları (Ravil ve diğerleri, 2022).

DNA' da veri depolama fikri ilk olarak 1950 yıllarının sonunda Neiman ve Wiener tarafından ortaya atılmış (Neiman 1965, Wiener 1964). ancak tam olarak Church ve ark. Tarafından 2012 yılında uygulanılmıştır. Çalışmalarında, 659 kbyte boyutunda bir kitabı, sıfırların Adenin veya Sitozine, birlerin ise Timin veya Guanine rastgele eşlendiği basit bir kodlama kullanmışlardır. Çalışmaları sonucunda ise kübik milimetre başına 700 terabyte' lık veri depolama yoğunluğu hesaplayarak DNA' nın depolama ortamı amacı ile oldukça cazip olduğunu kanıtlamışlardır (Church, 2012).

DNA depolama yöntemlerinde, kodlama adımının ele alınış biçimi depolama kapasitesi, erişim hızı ve veri yoğunluğunu etkileyen önemli bir mühendislik problemidir. En yaygın kullanılan yöntem Tablo 2 ' de gösterilmektedir.

Tablo 2. Bit-DNA baz dönüşümü (Blawat, 2016)

Bit	Baz
00	A
01	C
10	G
11	T

Günümüzde gerçekleştirilen çoğu çalışma temel olarak bu prensibi esas alır denilebilir. Laboratuvar ortamında tüpte sentetik ortamda (in vitro) gerçekleşen bu tür çalışmalarda rapor edilmiş en yüksek yoğunluk oranı baz/bit cinsinden yaklaşık 2 civarındadır (Raza ve diğerleri, 2023; Dimopoulou ve Antonini, 2022) . Literatürde yer alan bazı dikkat çekici örneklere aşağıdaki paragraflarda somut olarak yer verilmiştir.

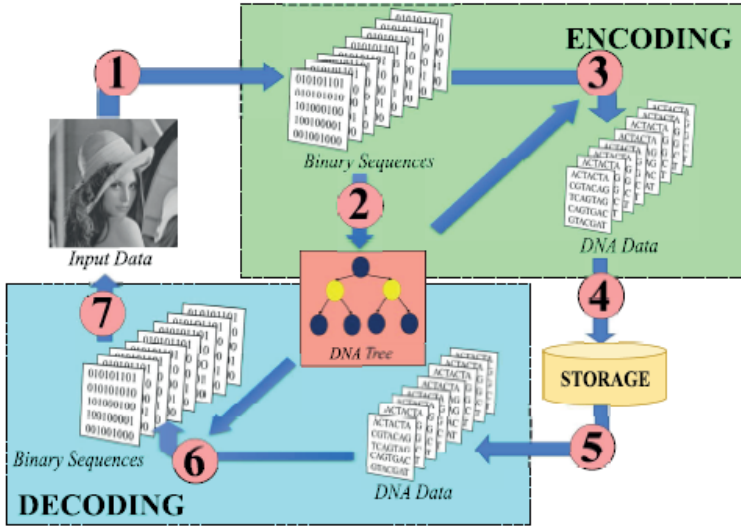
Tablo 3' de yer alan başka bir çalışmaya dair detaylar ise İngiliz alfabesi, rakamlar ve bazı imla işaretlerinin DNA bazlarına eşleşmesini göstermektedir. Bu çalışmasında, "JUNE 6 INVASION: NORMANDY" mesajını 109 nükleotide saklamayı başarmışlardır.

Tablo 3. İngiliz alfabesi, rakamlar ve imla işaretlerinin DNA baz karşılıkları (Clelland ve diğerleri, 1999).

A = CGA	K = AAG	U = CTG	0 = ACT
B = CCA	L = TGC	V = CCT	1 = ACC
C = GTT	M = TCC	W = CCG	2 = TAG
D = TTG	N = TCT	X = CTA	3 = GAC
E = GGC	O = GGA	Y = AAA	4 = GAG
F = GGT	P = GTG	Z = CTT	5 = AGA
G = TTT	Q = AAC	_ = ATA	6 = TTA
H = CGC	R = TCA	, = TCG	7 = ACA
I = ATG	S = ACG	. = GAT	8 = AGG
J = AGT	T = TTC	: = GCT	9 = GCG

2020 yılında Lee ve ark tarafından Perl (Practical Extraction and Report Language) dilinin esnekliğini kullanarak DNA tabanlı depolama yöntemi önermişlerdir. 2046 kelime içeren evrensel insan hakları bildirgesini, Perl dili tabanlı bir DNA kodlama tablosu oluşturarak 8148 baz çiftine eşleşmişlerdir (Lee ve diğerleri, 2020).

Mishra ve ark. Tarafından 2020 yılında Şekil 7' de sunulan yöntemi önermişlerdir. Bu çalışmada, dijital görüntüler Huffmann sıkıştırma algoritması geliştirilerek DNA ortamında depolanmıştır (Mishra, 2020).



Şekil 7. DNA ortamında görüntü depolama

Liu ve ark. ise 2023 yılında selüloz kağıdı kullanarak düşük maliyetli, güvenilir ve verimli bir DNA depolama yöntemi geliştirmişlerdir. Çalışmalarında mm³ başına 15 TB'lık bilgi yoğunluğu elde etmişlerdir (Liu ve diğerleri, 2023).

5. Sonuç

Üretilen veri miktarı her geçen yıl artmakta ve adeta bir “veri kirliliği” ne sebep olmaktadır. Ancak günümüz koşulları, veri ve bilgiye erişimin, veri destekli karar mekanizmalarının toplumların refah ve ekonomi düzeyi üzerindeki etkisi ve özellikle IOT platformunun yükselişi sonucu yine verinin önemi kritik hale gelmiş ve veriden “büyük veri” ye geçiş süreci oldukça hızlı ivmelenmiştir. Veri üretimi artmaya devam edecektir. Büyük verinin vurgulanan etkileri neticesinde kaybedilmesi bir yana hatasız bir biçimde saklanabilmesi kritik önem arz etmektedir.

Google, Amazon ve Microsoft, dünya çapında veri üretiminde başı çeken şirketlerdir. Bu şirketler bile veri üretimine devasa bütçe ve sarfiyat ayırmaktadırlar. Özellikle “bulut bilişim” büyük verinin depolanmasında önemli bir mihenk taşı olmuştur. Büyük verinin depolanması üzerine yapılan bu kadar yatırımın amacı, şüphesiz ki hatasız bir şekilde saklanıp işlendiğinde büyük veri üzerinden gerçekleştirilecek işlem ve çözümlerden elde edilen kazançtır. Dünya genelinde özellikle büyük ve ciddi şirketlerce de büyük veri üzerine bu kadar yaygın ve ciddi yatırımların yapılıyor olması, alternatif depolama çözümlerinin arayışını ivmelendirmiştir. Teknolojinin gelişmesi ile paralel olarak, veri ve depolama kriterleri de göz önünde bulundurularak, veriyi ve -günümüz olayı- büyük veriyi depolama amacıyla birçok depolama - erişim stratejisi ve medya ortamları geliştirilmiştir. Ancak veri artış miktarı göz önünde bulundurulduğunda geliştirilen bu fiziksel ortamların kapasite-yoğunluk dengeleri, fiziksel olarak yer işgal durumları ve çevre dostu olup olmadıkları konuları endişe uyandırmaktadır. Bütün bunların neticesinde, mevcut yöntemlere alternatif, kapasite-yoğunluk dengesi yüksek ve çevre dostu bir veri depolama ortamına ihtiyaç duyulmaktadır.

Biyolojik yapısı ve özellikleri bakımından DNA, bu ihtiyacı karşılamak için oldukça güçlü bir zemin sunmaktadır. Hayat devam ettiği müddetçe veri depolama amacıyla DNA moleküllerinin kullanılması son derece mantıklı ve etkilidir. Ayrıca DNA'nın oldukça verimli bir kapasite yoğunluk dengesi, uzun ömürlülüğü, zor koşullarda bile dayanıklı olması yanında çevre dostu ve yaşamın temeli olması tercih edilme sebebini güçlendirici unsurlardır. Ancak günümüz koşullarında DNA tabanlı veri depolama teknolojisi halen mükemmel değildir. Sentezleme ve sekanslama maliyeti, nükleotid başında düşen hata payı ve veriye DNA üzerindeki erişim zamanı gibi zorluklar mevcuttur. Maliyet ve hız gibi dezavantajlarına rağmen Moore yasası seyri ile DNA sentez ve sekanslama teknolojilerindeki gelişim karşılaştırıldığında, DNA ortamının veri depolama amacıyla kullanılabilirliği fikri oldukça ümit vericidir.

KAYNAKÇA

- https://www.atkearney.com/analytics/ideas-insights/article/-/asset_publisher/hZFiG2E3WrIP/content/big-data-and-the-creative-destruction-of-today-s-business-models/10192?_101_INSTANCE_hZFiG2E3WrIP_redirect=%2Fanalytics%2Fideas-insights, Son Erişim Tarihi: 27.07.2016
- Blawat, M., Gaedke, K., Hütter, I., Chen, X., Turczyk, B., Inverso, S., Pruitt, B.W., Church, G.M. (2016). Forward Error Correction for DNA Data Storage, *Procedia Computer Science*, 80: (1011-1022)
- Church, G.M., Gao, Y., Kosuri, S., (2012), Next-generation digital information storage in DNA. *Science*, 1226355
- Clelland, C.T., Risca, V., Bancroft, C., (1999). Hiding messages in DNA microdots. *Nature*, 399:(6736), 533–534. <https://doi.org/10.1038/21092>.
- <http://cloudtweaks.com/2015/03/surprising-facts-and-stats-about-the-big-data-industry/> , Son Erişim Tarihi: 27.07.2016
- Dimopoulou, M., Antonini, (2022). M. Data and image storage on synthetic DNA: existing solutions and challenges., *J Image Video Proc.*, 23 (2022). <https://doi.org/10.1186/s13640-022-00600-x>
- <http://www-03.ibm.com/systems/storage/big-data-storage/>, Son Erişim Tarihi: 27.07.2016
- Kim, S.J., Jung, W.B., Jung, H.S. et al., (2023). The bottom of the memory hierarchy: Semiconductor and DNA data storage, *MRS Bulletin* 48, 547–559, <https://doi.org/10.1557/s43577-023-00510-x>
- Lee, U.J., Hwang, S., Kim, K.E., (2020). DNA Data Storage in Perl. *Biotechnol Bioproc E* 25, 607–615, <https://doi.org/10.1007/s12257-020-0022-9>
- Limbachiya, D., Gupta, M. K., Aggarwal, V., (2022). 10 Years of Natural Data Storage, in *IEEE Transactions on Molecular, Biological and Multi-Scale Communications*, vol. 8, no. 4, pp. 263-275, Dec. 2022, doi: 10.1109/TMBMC.2022.3211446.
- Liu, Q., Wei, Y., Wang, Z., Song, D., Cui, J., Qi, H., (2023) Sustainable DNA Data Storage on Cellulose Paper, *Small Methods*, DOI:10.1002/smt.202201610
- <https://www.microsoft.com/en-us/research/publication/dna-based-archival-storage-system/> , Son Erişim Tarihi: 27.07.2016
- Mishra, P., Bhaya, C., A Pal, . K., Singh, A. K., (2020). Compressed DNA Coding Using Minimum Variance Huffman Tree, in *IEEE Communications Letters*, vol. 24, no. 8, pp. 1602-1606, Aug. 2020, doi: 10.1109/LCOMM.2020.2991461.
- Neiman M., (1965). On the molecular memory systems and the directed mutations. *Radiotekhnika* 6, 1–8
- Ravil, R. Garafutdinov, Dmitry A. Chemeris, Assol R. Sakhabutdinova, Olga Yu Kiryanova, Constantin I. Mikhaylenko, Alexey V. Chemeris, (2022). Enco-

ding of non-biological information for its long-term storage in DNA, *Biosystems*, 215–216, <https://doi.org/10.1016/j.biosystems.2022.104664>.

Raza, H.,M, Desai, S., Aravamudhan, .S. ZadeGANR., (2023). An outlook on the current challenges and opportunities in DNA data storage, *Biotechnology Advances*, 66, <https://doi.org/10.1016/j.biotechadv.2023.108155>.

http://www.snua.org/sites/default/files/Apurva_Vaidya_Big_Data_Storage_rev.pdf ,
Son Erişim Tarihi: 27.07.2016

<http://www.statista.com/topics/1464/big-data/> , Son Erişim Tarihi: 27.07.2016

<https://theory.labster.com/structure-dna/>, Son erişim tarihi: 22.09.2023

Wiener, N., (1964), Machines smarter than men? interview with dr. norbert wiener. noted scientist. *US News & World Report*, 84–86

<http://wikibon.org/blog/big-data-statistics/> , Son Erişim Tarihi: 27.07.2016

Bölüm 2

BITKİ HASTALIKLARININ TESPİTİNDE DERİN ÖĞRENME

Yusuf BİLGEN¹

Mahmut KAYA²

1 Siirt Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği,
ORCID ID: 0000-0001-6041-6129

2 Siirt Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği,
ORCID ID: 0000-0002-7846-1769

1. Giriş

Bitki ve hayvan kaynaklı ürünlerin üretim ve kalite artırımı faaliyeti tarım olarak nitelendirilir [1]. Türkiye tarımsal ekonomide ilk on ülke arasına girmekte ve Avrupa'da tarımsal üretimde ilk sırada yer almaktadır [2]. Dünyamızdaki kaynakların sınırlı olması ve bu kaynaklara olan talebin giderek artıyor olması yeni üretim stratejilerinin uygulanması ihtiyacını doğurmaktadır [3]. Dünya nüfusundaki artış kaynaklı olarak gıda üretimi, gıdaya erişim imkânları, gıda kalitesi, gıda kaynaklarının korunması ve kaynakların idamesi konularının önemi giderek artmaktadır [4]. Bu sorunların çözümünde teknolojiye gelişimlerden uzun süredir yararlanılmakta ve teknoloji tabanlı yeni çözüm arayışları devam etmektedir [3]. Bitkilerde hastalıklarının tespitinde geleneksel yöntemlerde uzman görüşlerine ihtiyaç duyulmaktadır. Bu açıdan geleneksel yöntemler zaman ve maliyet gerektirmektedir [5]. Bitki hastalıklarının erken teşhisi son derece önem arz etmektedir. Bitki hastalıklarının tespitinde yapay zekâ algoritmalarının kullanımı zaman ve maliyet etkin çözümler sunmanın yanında birçok avantaj sağlamaktadır. Son yıllarda yapay zekâ uygulamaları hayatımızın her alanında karşılık bulmaktadır. Bunlardan biri olan tarım teknolojilerinde de birçok yapay zekâ uygulamasına son zamanlarda sıklıkla rastlanılmaktadır. Özellikle yüksek başarıma sahip derin öğrenme temelli birçok çalışma ile karşılaşmamız mümkündür. Bu çalışmalar incelendiğinde bazı çalışmaların derin öğrenme modelleri geliştirme ve iyileştirme üzerine olduğu görülmektedir. Diğer bazı çalışmalarda ise elde edilen derin öğrenme modellerinin gömülü sistem ve robotik uygulamaları bulunmaktadır. Yine son zamanlarda artan bir şekilde tarımda insansız hava aracı, insansız kara aracı, mobil cihaz tabanlı uygulamalar ve nesnelerin interneti tabanlı uygulamalar ile karşılaşılmaktadır. Bütün bu uygulamalarda yapay zekâ ve derin öğrenmenin çok yoğun kullanımı görülmektedir.

2. Bitki Hastalıkları

Bitkisel hastalıklar maddi kaybın yanında zaman kaybına da yol açan ve mücadele edilmesi gereken önemli bir unsurdur [6]. Hastalık tespiti için zamanında doğru teşhis ve doğru yöntemlerin kullanılması zorunludur. Bitkisel hastalıklar birçok farklı nedenden kaynaklanabilir ve çevre koşulları oldukça önemli bir etkiye sahiptir. Bitki hastalıkları dallardan, gövdeden, çiçeklerden veya yapraklardan tespit edilebilmektedir. Ancak kök hastalıklarında hastalığın tespiti için kök incelenmeli veya toprak üstü belirtiler araştırılmalıdır. Bitkilerdeki hastalığın şiddetinin anlaşılması daha güçtür ve hastalıktan etkilenen dokunun oranını tahmin etmek gerekir [7]. Hastalık tespiti geleneksel yöntemlerde uzmanlar tarafından yapılırken artan nüfus ve diğer etmenlerden dolayı günümüzde sadece uzmana başvurma ciddi bir maliyet ve zaman kaybına yol açmaktadır. Uzmana başvurulmadan yapılan müdahaleler ise hatalı müdahale yanında hatalı zirai ilaç kullanımı ile sonuçlanmaktadır. Tüm bu nedenlerden dolayı doğrudan uzman görüşüne başvur-

mak yerine yine uzman görüşleri ile şekillenen yapay zekâ ve derin öğrenme algoritmalarının kullanımını günümüzde vazgeçilmez bir durum olarak karşımıza çıkarmaktadır. Günümüzde yaşanan gelişmeler neticesinde yapay zekâ ve derin öğrenme bitki hastalıklarının belirlenmesi, önlenmesi ve erken müdahale edilmesinde kullanılır olmuştur.

3. Derin Öğrenme

Yapay zekâ ve derin öğrenme temelli çalışmalar ön işlem, özellik çıkarımı ve sınıflandırma üç genel aşama barındırırlar. Derin öğrenmede kullanılan genel işlem adımları Şekil 1’de gösterilmiştir.



Şekil 1 Derin öğrenmede genel işlem basamakları.

3.1 Ön İşlemler

Ön işlemler verilerin ön elemenden geçilmesi, hatalı verilerin düzeltilmesi, eksik verilerin giderilmesi, şekil analizleri, görüntü iyileştirmeleri gibi birçok işlemi kapsamaktadır. Derin öğrenmede görüntü verilerini işlerken gri tonlama, eşikleme, aşındırma, genleşme, açma, kapama gibi ön işlemler kullanılır.

Eşikleme işlemi bir görüntüyü siyah ve beyazdan oluşan ikili bir görüntüye çevirmeyi ifade eder. Tekli eşikleme, çoklu eşikleme, otsu eşikleme olmak üzere üç farklı eşikleme işlemi yapmak mümkündür. Tekli eşiklemede gri tona dönüştürülmüş olan resim için belirlenen bir eşik değerinin altı 0, üstü ise 1 olarak alınarak görüntü siyah beyaza dönüştürülür. Böylece resimdeki nesne ve arka plan ayrıştırılmaya çalışılır. Tekli eşikleme yöntemi resimdeki parlaklıktan büyük ölçüde etkilenmektedir [8].

Çoklu eşiklemede farklı sınır değerler için farklı gri ölçeklemesi yapılır. Birinci sınır değerinin altı birinci bölge, birinci sınır ile ikincinin arası ikinci bölge, ikinci sınır değerinin üstü ise üçüncü bölge olarak alınır. Burada bir bölge arka planı, diğer bölgeler ise farklı nesnelere temsil etmektedir. Otsu tarafından geliştirilen eşiklemede arka plan ile nesneyi ayırmak için görüntüyü iki farklı gruba ayıracak şekilde kendi içinde minimum varyans grupları arasında maksimum varyans sağlayacak şekilde bir ayırma gidilir [9].

Siyah beyaz bir resimde genellikle sınırların aşındırılmasında ve resmin küçültülmesinde aşındırma işlemi uygulanır. Aşındırma sonucunda toplam piksel sayısı azalır, nesnelere küçülür ve ayrışır [10]. Aşındırma işlemi yapısal elemanlar kullanılarak yapılır. İkili (binary) bir resimdeki nesnenin

sınırlarını büyütme için genişleme işlemi kullanılabilir. Aşındırma işlemindeki gibi yapısal elemanlar ile bu işlem yapılır. Genleşme sonucunda piksel miktarı artar ve nesne büyür. İkili (binary) bir resimdeki nesnelere arasındaki boşlukları temizlemek veya birbirine yakın nesnelere ayırmak için açma işlemi uygulanabilir. Açma işlemi aşınma ve genişlemenin birlikte kullanılmasıyla yapılan bir işlemdir. Bir resmin daha belirginleşmesini sağlamak ve resimdeki noktaların arasındaki boşlukların kapanmasını kapama işlemi ile gerçekleştirebiliriz. Bu işlem için aşınma ve genişleme işlemleri birlikte kullanılır.

3.2 Özellik Çıkarma

Özellik çıkarımı birçok problemin çözümünde kullanılan ve nesne tanıma oldukça önemli olan bir işlemdir ve nesnenin ayrıştırıcı parametreler ile temsil edilmesidir. Özellik çıkarımı şekil tabanlı, doku tabanlı ve renk tabanlı geleneksel yöntemler ile evrimsel sinir ağları gibi derin öğrenme yöntemleri şeklinde iki gruba ayrılabilir. Geleneksel özellik çıkarım yöntemleri Tablo 1’de verilmiştir.

Tablo 1. Geleneksel özellik çıkarım yöntemleri.

Şekil Tabanlı	Renk Tabanlı	Doku Tabanlı
Morfolojik özellikler	Ortalama	Gri seviye eş oluşum matrisi
Hu değişmez momentleri	Varyans	Yönlü gradyan histogramı
Fourier tanımlayıcıları	Homojenlik	Yerel ikili örüntü
Shearlet dönüşümü	Heterojenlik	
Merkez kenar uzunlukları		
Damar özellikleri		

Hu ve arkadaşları yaptıkları bir çalışmada görüntüdeki nesneyi belirlemek için genellikle istatistik ve klasik mekanikte kullanılan ve verilerin ortalaması olarak ifade edebileceğimiz 7 farklı moment tanımlamışlardır [11]. Bu işlemde görüntüdeki nesne koordinatlarının ortalama değerleri elde edilir. Ardından bu değerler ile görüntü boyutlarına göre momentler normalize edilir. Normalize edilmiş momentlerden yedi değişmez Hu moment değeri hesaplanır. Bu moment değerleri parlaklık, dönme, büyütme, küçültme ve konum değişiminden etkilenmezler [8]. Merkez kenar uzunluğu bir nesnenin ağırlık merkezinin bu nesnenin sınırlarına uzaklığı ifa eder [12]. Merkez kenar uzunluğu hesaplanırken ağırlık merkezinden sınırlara $360/a$ adet nesnenin özniteliklerini ifade eden uzaklık değeri bulur. Matematikteki Fourier dönüşümleri kullanılarak görüntünün kontur denilen ana hatlarını belirleme işlemi Fourier tanımlayıcıları ifade eder. Bu işlem de sınır noktaları kullanılarak belirlenir [12]. Fourier tanımlayıcıları kullanılırken resim gri tonlamalı

resme dönüştürülür ve ardından daha önce bahsettiğimiz ön işlemlerden faydalanılarak ikili (binary) görüntü oluşturulur. Sınır koordinatlar belirlenir ve bu koordinatlar için Fourier dönüşümü hesaplanır. Sonuçta elde edilen Fourier tanımlayıcıları döndürme, büyütme ve küçültme işlemlerinden etkilenmezler. Damar (Vein) özellikleri uygulanırken gri tonlamadaki resim ele alınır. Disk şeklindeki yapısal elemanlar farklı çapta alınarak açma işlemi gerçekleştirilir. Otsu yöntemi ile binary resim elde edilir ve her çaptaki yapısal eleman için piksel sayısı hesaplanarak 5 özellik belirlenir [13]. Shearlet dönüşümü hedef ölçek ve yöndeki frekans bileşenleri kullanarak daha esnek analizler yapmamızı sağlayan bir yöntemdir [13]. Görüntü işlemede bu dönüşüm kartezyen koordinat sistemindeki şekli ile kullanılır. Shearlet dönüşümü yönden bağımsız olarak sonuç sağlar ve doku ile nesne tanımda başarılı sonuçlar verir [14].

Özellik çıkarımında renk tabanlı yöntemler ortalama, varyans, asimetriklik, simetriklik gibi istatistiksel işlemler kullanılarak uygulanmaktadır [15]. Bu yöntemler kullanılırken odaklanan nesne dışındaki kısımlar resimden çıkartılır. Kullanılan renk uzayındaki her bir renk kanalı için ayrı bir özellik çıkarımı yapılır. Resimde ele alınan nesnenin yüzey karakteristiklerini anlamak için doku tabanlı yöntemler kullanılır. Doku özellikleri, gri seviye eş oluşum matrisi, yönlü gradyan histogramı, yerel ikili örüntü yöntemleriyle yapılabilmektedir. Gri seviye oluşum matrisinde iki komşu piksel arasındaki ilişki istatistiksel olarak belirlenir [16]. Görüntünün pikselleri arasındaki mesafe ve açıya göre görüntünün gradyan yönelim dağılımlarının elde edilmesi amaçlanmaktadır. Haralick, yaptığı çalışmada 14 farklı doku özelliği kullanarak resimlerdeki dokusal özelliklerin belirlenebileceğini ifade etmiştir. Bu özelliklerden entropi, enerji, korelasyon ve kontrast en sık rastlananlarıdır. Kontrast bir piksel ile komşusu arasındaki yerel farktır ve netliği ifade eder [17]. Resimdeki iki komşu pikselin arasındaki ilişkisi korelasyon olarak isimlendirilir. Resimdeki griliğin homojenliği enerji değeri ile ifade edilir. Dokunun karmaşıklık derecesi entropi ile ifade edilmektedir. Resim desenindeki benzerlik ise homojenlik ile ifade edilir.

Shashua ve Dalal yaptığı bir çalışma sonucunda yönlü gradyan histogramı ortaya çıkmıştır [18]. Yönlü gradyan histogramı bölgesel olarak gradyan büyüklükleri sayısını içeren görüntü yerel histogram serilerinin grupları olarak tanımlanır. Yönlü gradyan histogramı hesaplanırken önce Sobel isimli bir filtre kullanılarak her bir piksel için tüm eksenlerde gradyanlar hesaplanır. Daha sonra gradyanın işareti ve açısına göre yönelimler belirlenir ve yönelim histogramları oluşturulur. En sonda tüm histogramlar birleştirilerek normalize edilir. He ve Wang yaptığı bir çalışmada merkez nokta ile komşularını karşılaştırarak her noktayı binary olarak etiketleyen yerel ikili örüntü algoritmasını önermişlerdir [15]. Binary etiketleme yapıldıktan sonra üstel toplamlardan oluşan özel bir fonksiyon kullanılarak bu değerler 8 bitlik

değerlere dönüştürülür ve buradan çeşitli dönüşümlerle öznelik vektörleri bulunur.

3.3 Evrişimsel Sinir Ağları

Derin öğrenme insan beyninden ilham alınarak tasarlanmış bir makine öğrenmesi algoritmasıdır. Başka bir ifade ile yapay sinir ağlarından daha karmaşık yapıda olan bir ağ modelidir. [19] Nesne tanıma işlemleri için derin öğrenmede birçok gizli katman bulunur ve diğer makine öğrenmesi algoritmalarından farklı olarak büyük boyuttaki veriler işlenir ve bu sebeple yüksek hesaplama gücüne ihtiyaç duyulur. Geleneksel makine öğrenmesi algoritmalarında ele alınacak özellikler insan müdahalesi ile belirlenirken derin öğrenmede ele alınacak özellikler algoritma tarafından öğrenilir. Nesne tanıma ve sınıflandırmada başarılı sonuçlar veren derin öğrenme yöntemlerinden biri evrişimsel sinir ağlarıdır (CNN). Bu yöntem ile arka plan silme ve bölütleme gibi bazı ön işlemler yapılmadan problemler çözülebilmektedir. Ayrıca CNN ile geliştirilen mimariler tek bir nesneye yönelik olmayıp birçok nesnenin tespitinde kullanılabilir. [19]

Evrişimsel sinir ağları genel olarak giriş, evrişim, havuzlama, normalizasyon, düzleştirme, tam bağlı, dropout ve sınıflandırmada katmanlarından oluşmaktadırlar. Bu katmanların farklı dizilimleri ile farklı ağ mimarileri elde edilir. Giriş katmanı verinin ham olarak ağa gönderildiği katmandır. Bu katmana girilen görüntü verisinin boyutu sonucu etkileyecektir. Evrişim katmanı ağız temel katmandır. Bu katmanda çeşitli filtreler ile görüntü taranarak görüntünün ayırt edici özelliklerine sahip yeni görüntüler elde edilir. Havuzlama katmanı boyutu küçültmek için kullanılan katmandır. Bu katmanda çeşitli boyuttaki filtreler ortalama, maksimumu bulma gibi işlemleri görüntü üzerinde gezdirilerek gerçekleştirir. Boyut küçültmek genelde bilgi kaybına neden olur [20]. Bununla birlikte havuzlama katmanı sayesinde ağız veriyi ezberlemesi ve hesaplama yükünün azalması gibi avantajlar sağladığı bilinmektedir.

Evrişim katmanından çıkan veriyi ölçeklendirerek performansı arttırmak için normalizasyon katmanı kullanılır. Normalizasyon katmanında veriler çeşitli normalizasyon fonksiyonları kullanılarak standart bir ölçektir verilere dönüştürülür. Düzleştirme katmanı, havuz katmanından çıkan iki boyutlu matris formundaki verileri uzun bir doğrusal vektöre dönüştürüldüğü katmandır. Bu vektör yoğun katman denen tek bir katmana tüm verileri bağlamak için kullanılır.

Tam bağlı katman, kendinden önce gelen katmanın çıkışlarına bir ağırlık matrisi aracılığıyla doğrusal bir dönüşümün yapan katmandır. Bu katmanda girişteki her değer çıkışa belirli bir etki yapar. Ağız aşırı öğrenmesinin veya ezberlemesinin önüne geçmek için kullanılan bir diğer etmen dropout katmanıdır. Bu katmanı uygularken belirli bir sınır değer veya rastgele seçim-

lerle katmanlar arasındaki bazı bağlantılar göz ardı edilir. Evrişimsel sinir ağlarında sınıflandırma yapılırken istenen sınıf sayısı kadar çıkışı bulunan bir katmana ihtiyaç duyulur. Softmax gibi bazı fonksiyonlar kullanılarak sınıflandırma işlemi sınıflandırma katmanında gerçekleştirilir.

Evrişimsel sinir ağları kullanılarak sınırsız sayıda farklı katman dizilimleri gerçekleştirmek mümkündür. Bununla birlikte yapılan birçok yarışma ve çalışmada başarısını ispatlamış mimariler mevcuttur. Bu mimariler ile çok farklı alanlardaki problemlere çözüm bulunabilmekte ve oluşturulan yeni mimarilerin başarısını test etmek için bu mimarilere başvurulabilmektedir. Bu mimariler çok büyük veri setleri ile eğitildiklerinden milyonlarca parametre içermektedirler. Mimari derinlikleri 8 ile 200 arasında değişmekte ve 224x224 piksel gibi küçük boyutlu resimleri girdi olarak kabul etmektedirler. LeNet [21], AlexNet [22], Inception [23], VGG16 [24], VGG19 [24], ResNet [25], SqueezeNet [26], MobileNet [27], DenseNet [28], ShuffleNet [29] ve EfficientNet [30] bu mimarilerden bazılarıdır. Tablo 2’de bazı evrişimsel sinir ağı mimarileri ve bunlara ait özet bilgiler görülmektedir.

Tablo 2. Evrişimsel Sinir Ağır Mimarileri

Mimariler	Katman Sayısı	Boyut	Parametre (Milyon)	Varsayılan Giriş Görüntü Boyutu
AlexNet	8	60 MB	61	227x227
DenseNet201	201	80 MB	20.2	224x224
EfficientNetB0	23	80 MB	20.2	224x224
GoogLeNet	22	28 MB	6.7	224x224
InceptionResNetv2	572	215 MB	55.8	299x299
Inceptionv1	22	41 MB	6.6	224x224
Inceptionv3	48	96 MB	23.9	299x299
LeNet-5	7	0.5 MB	0.06	32x32
MobileNetv2	53	14 MB	3.5	224x224
ResNet101	101	178 MB	44.6	224x224
ResNet152	152	232 MB	60.3	224x224
ResNet18	18	44 MB	11.7	224x224
ResNet50	50	98 MB	25.6	224x224
ShuffleNetV2x0.5	12	1.4 MB	1.4	224x224
ShuffleNetV2x1.0	20	2.3 MB	2.3	224x224
ShuffleNetV2x1.5	26	7.4 MB	7.4	224x224
SqueezeNet	23	5 MB	1.2	224x224
VGG16	16	138 MB	138	224x224
VGG19	19	143 MB	143	224x224

4. Bitki Hastalıklarının Tespitinde Derin Öğrenme Çalışmaları

Bitki hastalıklarının tespitinde yapay zekâ ve derin öğrenme algoritmalarının kullanıldığı birçok çalışma mevcuttur. Mevcut çalışmaların çoğunda açık kaynak veri tabanlarındaki fotoğraflar kullanılmıştır. Yapılan çalışmalar incelendiğinde bazı çalışmalarda geleneksel, bazı çalışmalarda ise derin öğrenmeye dayalı yöntemlerin kullanıldığı görülmektedir. Kullanılan yöntem ve modeller Tablo 3'te özet olarak gösterilmiştir.

Tablo 3. Bitki hastalıklarının sınıflandırılmasına yönelik literatür çalışmaları

Makale	Bitki	Veri Seti	Sınıflandırıcı	Başarı
[31]	Yonca	899	SVM, NB, LDA, lojistik regresyon analizi ve Regresyon ağacı.	Test doğruluğu %94,74
[32,33]	Muz, Fasulye, Limon, Gül	106	GA + SVM GA + MDC K-means + MDC	Doğruluk oranı K-means+MDC:%86,54 GA+MDC:%93,63 GA+SVM:%95,71
[34]	Pirinç	650	DNN, ANN, DAE	Doğruluk: %94,25 F1 puanı: %88,74 Kesinlik: %81,24
[35]	18 tür	94	SVM	Doğruluk oranı 95%
[36]	14 bitki	54306	AlexNet GoogleNet Transfer Öğrenme	F1 Score 99,35%
[37]	Çeltik	40	PNN	Doğruluk oranı 83%
[38]	Buğday	342	BPNN	Doğruluk oranı 84,8%
[39]	Pamuk	-	Yapay sinir ağı	Doğruluk oranı 98,1%
[40]	Mısır	580	PSO ve Yapay Sinir ağı	Doğruluk oranı %93,3 ve %87,8
[41]	Salatalık	-	MDC	Doğruluk oranı >%96
[42]	Soya fasulyesi	1200	SURE, HOG, PHOW	Doğruluk oranı 96.25%
[43]	Mısır	800	KNN, ANN	Doğruluk oranı ANN: 94.40% KNN: 82.50%
[44]	Mısır	750	Yapay Sinir Ağı SVM	Doğruluk oranı SVM : 83.83% ANN : 77.75%
[45]	Pirinç	5808	CNN Haar dalgacığı Yerel İkili Model SVM	Maksimum doğruluk oranı 95.83%
[46]	Pirinç	120	DenseNet inception	Doğruluk oranı 92.86%

[47]	Buğday, mısır, üzüm	611	Derin Siamese ağı	Doğruluk oranı 86%
[48]	Mısır	500	GoogleNet Cifar10	Ortalama doğruluk oranı GoogleNet: 98.9% Cifar10: 98.8%.
[49]	20 bitki	46513	VGG19, VGG16	Doğruluk oranı VGG 16: 83.95% VGG19: 79.2%
[50]	Mısır	3852	LeNet CNN, PCA	Ortalama doğruluk oranı 97.89%
[51]	Domates	54309	AlexNet, SqueezeNet.	Doğruluk oranı AlexNet: %95.65 SqueezeNet:%94.30
[52]	Domates	10000	T-LeafNet AlexNet MobileNetV2 VGG16	En yüksek sınıflandırma performansları T-LeafNet: %97,32 AlexNet: %98,32 MobileNetV2: %99,1 VGG16: %99,21
[53]	Domates	18160	GoogleNet AlexNet SqueezeNet ShuffleNet ResNet-18	Doğruluk oranları GoogleNet:%93,93 AlexNet: %95.18 SqueezeNet: %94.82 ShuffleNet: %94.29 ResNet-18: %81.79
[54]	Kayısı	886	Özgün Derin Evrişimsel Sinir Ağı	Maksimum Doğruluk: 98,2 Duyarlılık: 96,9 Özgüllük: 99,27 Kesinlik: 98,09 F1-skor: 97,24
[1]	Domates	18160	AlexNet DenseNet201 GoogleNet MobileNet ResNet101 ShuffleNet	Doğruluk oranları AlexNet: %93.5 DenseNet201: %97.1 GoogleNet: %91.0 MobileNet: %94.5 ResNet101: %97.4 ShuffleNet: %96.6
[55]	Mısır, Üzüm	1600	Özgün CNN Modeli	Doğruluk oranı %97
[56]	Şeftali	1965	AlexNet	Doğruluk oranı: 99,32 Duyarlılık: 98,41 Özgüllük: 100,00 Keskinlik: 100,00 F1 Skor: 99,20
[57]	Ceviz	726	Özgün CNN, (ReliefF, SVM)	Maksimum Doğruluk: 99.58 Kesinlik: 99.58 Duyarlılık: 99.58 Geometrik Ort. 99.58 F-Skor: 99.58

[58]	Elma	3171	AlexNet DenseNet-121 ResNet-34 VGG16-BN Squeezenet1_0	Maksimum ResNet-34'te Duyarlılık:%97,64 özgüllük:%99,54 doğruluk:%99,52 F-skor:%98,62
[59]	Narenciye	320	Özgün CNN VGG16 AlexNet	Doğruluk oranları Özgün CNN: %82 VGG16: %93 AlexNet: %92
[60]	Dolma biber, patates ve domates	20639	AlexNet VGG16 ResNet18 (KNN, SVM, ANN)	En yüksek doğruluk oranı SVM sınıflandırıcı ile AlexNet: %98.29 VGG16: %99.13 ResNet18: %98.71
[5]	Elma	1821	Özgün CNN	Doğruluk oranı %98.76

Tablo 3 incelendiğinde görsel sayısının az olduğu çalışmalarda geleneksel yöntemlerin tercih edildiği görülmektedir. CNN mimarilerinin kullanıldığı çalışmalarda ise görüntü sayısının çok daha yüksek olması gerekmektedir. Başarı oranlarına bakıldığında geleneksel yöntemler için de başarının çok düşük olmadığı görülmektedir. Ancak bu doğruluk oranları kullanılan veri seti dışındaki resimler için de aynı sonuçları vermeyebileceği unutulmamalıdır. Bu açıdan çok daha fazla görsel ile eğitilen CNN modellerinden daha kararlı sonuçlar beklenmektedir.

Bitki hastalıklarının tespitine yönelik çalışmalar incelendiğinde bir kısım çalışmaların model oluşturma ve var olan modelleri geliştirmeye dönük iken; bir kısım çalışmaların ise gömülü sistemler, robotik, mobil ve nesnelerin interneti gibi oluşturulan modellerden pratik uygulamalar şeklinde olduğu görülmektedir.

4.1 Model Oluşturma ve Geliştirme Çalışmaları

Bitki hastalıklarını konu alan bazı derin öğrenme çalışmalarında yeni modeller önerme veya mevcut modellerde transfer öğrenme yöntemleriyle geliştirmeler yapılması söz konusudur. Bu açıdan yapılan çalışmalar kullanılan veri setindeki görüntülerin içeriğine göre üçe ayırmak mümkündür. Bunlar yaprak tabanlı, meyve tabanlı ve dal tabanlı olarak karşımıza çıkmaktadır.

4.1.1 Derin Öğrenme Teknikleri ile Yaprak Tabanlı Bitkisel Hastalık Çalışmaları

Son yıllarda Evrişimli Sinir Ağları (CNN), ImageNet yarışması gibi görüntü tanıma görevlerinde özellik çıkarıcılar ve sınıflandırıcılar olarak olağanüstü performans göstermiştir. CNN, hastalık tanıma, haşere tanıma, yabancı ot tespiti, meyve ve çiçek sayımı, meyve sıralama ve derecelendirme gibi görevleri yerine getirmek için tarımsal uygulamalarda kullanılmıştır [5]. Özel-

likle 2015 yılından bu yana, Görüntü İşleme Dönüştürücüler (IPT) kullanılarak yaprak hastalığı tanıma konusunda yapılan araştırmaların çoğunda derin öğrenmeden yararlanmıştır [61]. LeCun ve arkadaşları derin öğrenmeyi, bir dizi optimizasyon yoluyla verileri en iyi şekilde temsil etmeyi öğrenme yöntemi olarak tanımlamıştır [62]. Bu öğrenme prosedürü ile özellikler otomatik olarak çıkarıldığı için özellik mühendisliği yapmaya gerek kalmamaktadır. Derin öğrenmenin, tarım endüstrisinde hastalık teşhisi, haşere tespiti, kalite yönetimi, pazarlama, otomasyon, robotik ve büyük veri alanlarında ilerlemeler sağlaması beklenmektedir. CNN'lerin eğitimi için binlerce görüntüden oluşan büyük veri kümeleri gereklidir. Ne yazık ki, bitki hastalığı tanıma alanında, henüz yeterince büyük ve çeşitli veri kümeleri bir araya getirilmemiştir. Mevcut çalışmalara bakıldığında transfer öğrenimi, bitki hastalığı tanıma için CNN sınıflandırıcılarını eğitmenin en etkili yoludur. Transfer öğrenimi, önceden eğitilmiş CNN'lerin, daha önce ağı sıfırdan eğitmek için kullanılan büyük veri kümesinden farklı dağılıma sahip daha küçük veri kümeleriyle yeniden eğitilerek yeni veriye uyarlanması işlemidir [63]. Mevcut çalışmalar, ImageNet veri kümesi üzerinde önceden eğitilmiş CNN modellerini kullanmanın ve ardından bunları yaprak hastalığı tanıma için yeniden eğitmenin daha iyi sonuçlar verdiğini göstermektedir [64,65].

Ecemiş ve İlhan çalışmasında domates yapraklarında hastalık tespiti için hafif evrişimli bir sinir ağı önermiş ve elde ettiği sonuçları önceden eğitilmiş ağların performansları ile karşılaştırmıştır. Domates bitkisinin yapraklarında meydana gelen dokuz hastalığı ve hastalık izi bulunmayan yaprakları tanıyabilen "T-LeafNet" evrişimsel sinir ağı (ESA-CNN) modeli önermiş ve bu ağ sınıftan eğitilerek başarısı belirlenmiştir. Daha sonra transfer öğrenme yöntemi ile MobileNetV2, AlexNet ve VGG16 mimarileri eğitilmiş ve sonuçları kıyaslamıştır. Ayrıca orijinal veri yanında arttırılmış veriler ve farklı öğrenme katsayıları ile eğitimler tekrarlanıp bunların sonuç üzerindeki etkileri araştırılmıştır. Çalışma sonucunda önerilen T-LeafNet ağının eğitim zamanı ve sınıflandırma performansı açısından daha iyi değerlere sahip olduğu görülmüştür. Yine mevcut mimarilerden elde edilen sonuçların %97.32 ile %99.21 aralığında olduğu ve en yüksek başarımın VGG16 mimarisi ile yapılan transfer öğrenme sonucunda elde edildiği görülmüştür [1].

Liu ve ark. yaptığı çalışmada üzüm yaprağındaki farklı hastalıkları tespit etmek için evrişimsel sinir ağı tabanlı bir yöntem önermişlerdir. Veri seti olarak 107336 üzüm yaprağı görüntüsü kullanmışlardır. Öncelikle veri ön işleme teknikleri kullanarak resimlerde iyileştirmeler yapılmış ve öznelikler çıkarılmıştır. Elde edilen öznelikler evrişimsel sinir ağı tabanlı modele sunulularak %97.11 doğruluk oranına ulaşmışlardır [66].

Atik, yaptığı çalışmada derin öğrenme yöntemleri kullanarak bitki yaprağındaki hastalıkların sınıflandırmasını gerçekleştirmiştir. Bu çalışmada 18bin'den fazla resimden oluşan ve dokuz farklı hastalıklı sınıf yanında bir de

sağlıklı domates yaprağı görsellerinin bulunduğu bir veri seti kullanılmıştır. Çalışmada GoogleNet, AlexNet, SqueezeNet, ShuffleNet ve ResNet-18 mimarileri kullanılmıştır. Eğitilen ağlar farklı performans ölçütleri açısından değerlendirilmiştir. Eğitilen modellerde en yüksek başarıyı GoogleNet %95.18 doğruluk oranı ile gösterirken en düşük doğruluk oranı %81.79 ile ResNet-18 için belirlenmiştir. Diğer ağlarda %90 üzerinde başarı göstermiştir [53].

Ertem ve Özbay yaptığı çalışmada sınıflandırma problemlerinde derin özellik birleştirme yaklaşımıyla domates yaprağı görüntülerinden hastalık tespiti gerçekleştirmiştir. Bu çalışmada da aynı veri setine Kaggle üzerinden erişilmiş ve kullanılmıştır. Çalışmada DenseNet, ResNet ve ShuffleNet mimarileri eğitilerek test edilmiştir. Çalışmada 3000 adet öznitelik çıkarılmış ve Temel Bileşen Analizi (PCA) kullanılarak öznitelik sayısı azaltılmıştır. Çalışma sonucunda en yüksek doğruluk oranı %97.4 ile ResNet mimarisinde elde edilmiştir. En düşük doğruluk oranı ise %91.0 ile GoogleNet mimarisinde görülmüştür. Daha sonra çalışmada doğruluk oranı en yüksek olan 3 mimari birleştirilmiş ve PCA ile boyut azaltılma işlemi yapılarak hibrit bir mimari oluşturulmuştur. Bu işlemler sonucunda en iyi performans Cubic SVM ile One vs All metodlarında %99.2'e varan doğruluk oranları ile elde edilmiştir [1].

Ensari ve ark., görüntü tabanlı dijital bitki fenotiplemesi için konvolüsyonel sinir ağları üzerine çalışma yapmıştır. Temelde mısır ve üzüm hastalıkları üzerine yapılan çalışmada üç farklı hastalık üzerinde durulmuştur. Sekiz farklı sınıflandırma yapılan çalışmada 1600 veriden oluşan bir veri seti kullanılarak yapılan çalışmada %97.03 oranında doğruluk elde edilmiştir. Evrimsel sinir ağlarının kullanıldığı çalışma konvolüsyonel, havuzlama ve tam bağlantı olmak üzere üç katmandan oluşmaktadır. En başta konvolüsyonel katman gelmekte ve filtreleme yapılmaktadır. Sonrasında gelen çeşitli konvolüsyon ve havuzlama katmanlarından sonra tam bağlı katmanlar gelmektedir. Bu katmanlardan sonra doğrusal olmayan bir fonksiyon ile aktivasyon hesaplanır. Çalışma bitki üreticilerine yardımcı olmak, sert iklimlere ve koşullara dayanıklı bitkilerin sahip olduğu genleri belirlemek ve yapılacak diğer çalışmalara kaynaklık etmek amaçlarını taşımaktadır [55].

Yaman ve Tuncer, çalışmasında bitkilerde yaprak hastalığı tespiti için derin özellik çıkarma ve makine öğrenmesi yöntemi üzerine çalışmıştır. Çalışmada ceviz yapraklarından oluşan 726 görüntü içeren bir veri seti hazırlanmıştır. Görüntüler sağlıklı ve hastalıklı olarak etiketlenmiştir. Çalışmada 17 derin öğrenme mimarisi için sonuçlar elde edilmiştir. DarkNet ve ResNet modelleri en iyi performansı sağlamışlardır. Hibrit bir model oluşturmak amacıyla DarkNet ve ResNet modelleri birleştirilmiş ve en ağırlıklı özellikleri seçebilmek için ReliefF algoritması kullanılmıştır. Seçilen özellikler Destek Vektör Makinesi algoritması ile sınıflandırılış ve bu yöntem sonucunda %99.58 düzeyinde doğruluk elde edilmiştir [67].

Aksoy ve ark., çalışmasında elma bitkisindeki hastalıkların yapay zeka yöntemleri ile tespiti ve yapay zeka yöntemlerinin performans karşılaştırmasını gerçekleştirmiştir. Bu çalışmada elmadaki 3 farklı hastalık durumunun yaprak görüntülerinden evrimsel sinir ağları mimarisi kullanılarak tespiti yapılmıştır. Çalışmada AlexNet, DenseNet, ResNet, VGG16-BN ve SqueezeNet mimarileri için eğitimler gerçekleştirilmiş karışıklık matrisi yanında çeşitli ölçeklerle başarı değerlendirmeleri yapılmıştır. Sonuçta en iyi doğruluk oranı ResNet için %99.52 olarak hesaplanmıştır [58].

Kılıç ve ark., çalışmasında narenciye ağaç yaprak hastalıklarının evrimsel sinir ağları ile sınıflandırmasını gerçekleştirmiştir. Çalışmada yaprak görüntülerinden hastalık tespiti için evrimsel sinir ağı modeli önerilmiştir. Ayrıca transfer öğrenme kullanılarak VGG16 ve AlexNet mimarileri için eğitim gerçekleştirilmiştir ve önerilen model ile başarıyı kıyaslaması yapılmıştır. Veri seti olarak dört farklı hastalık ve sağlıklı yaprak görüntülerinden oluşan görüntüler kullanılmıştır. Önerilen model %82 doğruluk oranı gösterirken VGG16 %93, AlexNet ise %92 doğruluk oranı göstermiştir [60].

Gündüz, çalışmasında topluluk derin öğrenmesini kullanarak bitki hastalıkları sınıflandırması gerçekleştirmiştir. 3096 görselden oluşan açık kaynak bir veri seti ile gerçekleştirilen çalışmada sağlıklı ve sağlıklı domates yaprağı resimleri kullanılmıştır. AlexNet, VGG16, ResNet mimarileri ile transfer öğrenme kullanılarak öznitelikler elde edilmiş daha sonra en yakın komşu, destek vektör makineleri, yapay sinir ağı ve torbalama (bagging) toplu öğrenme yöntemi kullanılarak sınıflandırma yapılmıştır. Test edilen her sınıflandırıcı için farklı başarı ölçeklerinde değerlendirmeler yapılmıştır. En yüksek doğruluk değeri torbalama yöntemi sonucunda elde edilmiştir. En başarılı öznitelik çıkarımı ise VGG16 ile elde edilmiştir [60].

Sevli, çalışmasında elma bitkisi hastalıklarının derin öğrenme ile tespitini yapmıştır. Çalışmada evrimsel yapay sinir ağları kullanılarak elma bitkisi yapraklarından oluşan görüntülerden 3 farklı hastalık türüne ait görüntüler yanında hastalık taşımayan elma görüntüleri için eğitim gerçekleştirilmiştir. Kullanılan veri setinde 4 grupta 1821 elma yaprağı resmi bulunmaktadır. Model başarısı ve modelin ezberlemesinin önüne geçmek için veri artırımı gerçekleştirilmiştir. Önerilen model %98.76 doğruluğa ulaşmıştır [6].

Bakr ve ark. yaptığı çalışmada DenseNet mimarisini transfer öğrenme yöntemlerinde kullanarak evrimsel sinir ağı sınıflandırıcı bir model geliştirmişlerdir. Çalışmada veri seti olarak domates, patates ve biber görüntüleri kullanılmıştır. Veri setinde hem farklı hastalıklara ait görüntüler hem de sağlıklı sınıf görüntülerinden oluşan 28310 yaprak fotoğrafı bulunmaktadır. VGG16, Inception V3, ResNet ve DenseNet derin öğrenme mimarilerini kullanarak transfer öğrenme yöntemleri ile farklı modeller oluşturdukları modelde sonuçları başarı kriterlerine göre karşılaştırmışlardır. Çalışma so-

nucunda en yüksek doğruluk oranı %98.7 ile DenseNet mimarisinin kullanıldığı modelde elde edilmiştir [68].

Hu ve ark. çalışmalarında çay yaprağı hastalıklarını tespit için derin evrişimsel sinir ağına dayal bir yöntem önermişlerdir. Çalışmada ortaya konan modelin parametre sayısı VGG16 ve AlexNet derin öğrenme mimarilerine göre önemli ölçüde azalmıştır. Yöntemin hastalık tanımlamada doğruluk oranı %92,5 ile geleneksel makine öğrenmeleri ve klasik derin öğrenme yöntemlerine göre önemli ölçüde yüksek çıkmıştır [69].

4.1.2 Derin Öğrenme Teknikleri ile Ağaç Dal ve Meyve Tabanlı Bitkisel Hastalık Çalışmaları

Literatürde derin öğrenme ile bitki hastalık tespiti çalışmaları genellikle yaprak hastalıkları üzerine yapılmış olmakla birlikte bazı çalışmalarda meyve ve resimleri kullanıldığı görülmektedir.

Türkoğlu ve ark. çalışmalarında derin evrişimsel sinir ağı kullanarak kayısı hastalıklarının sınıflandırılmasını gerçekleştirmiştir. Çalışmada kayısı meyvesi ve kayısı ağaçlarının resimleri alınarak oluşturulan veri setinden faydalanılmıştır. Türkoğlu ve ark. yaptıkları çalışmada meyve görüntülerinin yanı sıra ağaç ve dal görüntülerinden de oluşan bir veri setinden faydalanmıştır. Kayısı hastalıklarının tespiti için derin evrişimsel sinir ağlarına dayalı evrişim, relu, normalizasyon, havuzlama ve tam bağlı katmanlardan oluşan bir model önerilmiştir. Modelde evrişim katmanında çeşitli boyutlarda beş farklı filtre kullanılmıştır. Çalışma çoklu disiplinler arası olarak yürütülmüş ve farklı üniversitelerin farklı fakülteleri birlikte çalışarak özgün bir veri seti oluşturulmuştur. Yapılan çalışma sonucunda önerilen modelin geleneksel modellere göre daha yüksek başarı değerleri vermiştir [54].

Aslan çalışmasında derin öğrenme ile şeftali hastalıklarının tespitini gerçekleştirmiştir. Veri seti Malatya, Bingöl ve Elazığ illerinden elde edilen monilya ve koşnili hastalıklı ağaçların dal ve meyve görüntülerinden oluşan resimlerden oluşmaktadır. Aslan yaptığı çalışmada ağaç ve dal görüntüleri yanında hastalıklı meyve görüntülerinden de faydalanmıştır [56]. Çalışmada kullanılan özgün veri setinin hazırlanmasında Ziraat fakültesinden faydalanılmıştır. Çalışmada şeftali ağacı hastalıklarının tespiti için Alexnet ağ mimarisini temel alan bir evrişimli sinir ağı yöntemi kullanılmıştır. Çalışma sonucunda %99.30 doğrulukta hastalık tespiti yapabilen ve literatürdeki çalışmalardan daha başarıyı yüksek bir derin öğrenme ağı elde edilmiştir.

4.2 Derin Öğrenmede Uygulamaya Dönük Çalışmalar

Derin öğrenme kullanılarak yapılan bitki hastalıkları çalışmaları incelendiğinde bazı çalışmalarda model oluşturup geliştirmenin yanında saha uygulamalarına dönük çalışmaların olduğu görülmektedir. Bu çalışmalar, gömülü sistem ve robotik çalışmaları olabildiği gibi mobil uygulama ve nes-

nelerin interneti uygulamalarına dönük çalışmalar da olabilmektedir. Bu çalışmaları İnsansız hava aracı (İHA) tabanlı, İnsansız kara aracı (İKA) çalışmaları, Mobil uygulama çalışmaları, Nesnelerin interneti (IOT) şeklinde sınıflandırmak mümkündür.

Mattihalli ve ark. yaptıkları çalışmada gömülü sistemlere dayalı olarak yaprak hastalıklarının tespitini gerçekleştirmişlerdir. Çalışmada Raspberry pi isimli geliştirme kartı ve bu karta bağlı kamera modülü kullanılarak elde edilen görüntülerden yine aynı kart üzerinde işlenerek hatalık tespiti gerçekleştirilmiştir. Aynı zamanda kart üzerine yerleştirilen farklı sensör bileşenleri sayesinde elde edilen ortam değerlerine dayalı olarak otomatik sulama ve ilaçlama yapan otonom bir sistem geliştirmişlerdir [70]. Nalawade ve ark. yaptıkları çalışmada gömülü sistemler ve sensörlerden faydalanarak bitkilerdeki hastalıkları tespit edebilen ve %98.07 doğruluk oranlarına ulaşan bir akıllı tarım uygulaması geliştirmişlerdir [71].

4.2.1 İHA ve İKA Tabanlı Çalışmalar

Tarımda insansız hava araçlarının (İHA) kullanılması ile uzaktan tespit ve teşhisin yapılması tarımdaki gelişmeleri önemli oranda ilerletme potansiyeline sahiptir. Tarımda İHA'ların kullanılması verilerin maliyet etkin olarak hızlı bir şekilde elde edilmesini ve geleneksel yöntemlerle elde edilemeyecek görüntülerin elde edilebilmesini sağlamaktadır. İnsansız hava araçları ile birlikte nesnelerin interneti uygulamalarının harmanlanması tarımda meydana gelecek büyük değişikliklere işaret etmektedir. İHA ile elde edilen görüntüler yüksek zamansal ve uzamsal niteliklere sahiptirler [72]. Akkamış ve ark. göre İHA'nın kullanım alanlarına arasında fenotipleme çalışmaları, verim tahmini, bitki besleme ve sulama, bitki örtüsü tahmini, bitki sayımı, bitki koruma çalışmaları sayılabilir [73].

Mevcut çalışmalarda hastalık tespitinde İHA kullanımı pek görülmemektedir. Bunun ana sebebi İHA görüntülerinin uzaktan çekimler olması ve hastalık tespiti için daha yakın çekimlere ihtiyaç duyulmasıdır. Hasan ve ark. çalışmasından konvülsiyonel sinir ağı kullanarak çiftliklerdeki yüksek hastalık alanını etkili bir şekilde belirlemek amacıyla İHA tabanlı akıllı tarım sistemi geliştirmiştir [74]. Çalışmada İHA'lar infrared kameralarla çiftlik fotoğrafları çekmiş ve fotoğraflar ZigBee ağı ile işlem merkezine aktarılmıştır. Çalışmada belirlenen enfeksiyon seviyesine göre yine İHA'lar ile bölgeye pestisitler püskürtülerek müdahalede bulunması amaçlanmıştır. Çalışmada veri kümesi olarak 2100 adet domates yaprağı fotoğrafının yanında Hindistan'daki çiftliklerden elde edilen 500 adet İHA görüntü birlikte kullanılmıştır. Çalışmada Inception ağ mimarisi transfer öğrenme yöntemiyle eğitilmiştir. Türkoğlu ve ark. kayısı hastalıkları üzerine yaptığı çalışmalarında kayısı ağaç resimleri elde ederken İHA fotoğraflarından faydalanmıştır [54].

Akkamış ve ark. çalışmalarında insansız hava araçları ve tarımsal uy-

gulamalarda kullanımı konusunu ele almıştır. Çalışmada ilk olarak insansız hava araçları hakkında temel düzeyde bilgi verilmiş ve tarımdaki kullanımları ile potansiyel kullanımlarından bahsedilmiştir. Çalışmanın sonraki bölümlerinde İHA ile alınan görüntüler kullanılarak bitki hastalıklarındaki şiddet belirleme ve değerlendirmesini yapan derin öğrenme algoritmaları incelenerek geleneksel görsel değerlendirmeden daha başarılı sonuçlar elde edilmiştir [73].

Doğan ve ark. çalışmalarında İHA ile multispektral kameralardan sağlanan görüntüler yardımıyla bitki türlerini sınıflandırma çalışmasını gerçekleştirmiştir. Yonca ve soya bitkilerinin fotoğraflarını İHA kameraları ile edinmişlerdir ve geleneksel yapay zekâ algoritmaları ile sınıflandırması yapılmıştır. Derin öğrenmenin kullanılmadığı bu çalışmada türlerin sınıflandırma işlemi sınıflandırma klasik yöntemlerle gerçekleştirilmiştir [75].

T.C. Tarım ve Orman Bakanlığı ile İstanbul Teknik Üniversitesi ortaklığında yürütülen Tarımsal İzleme ve Bilgi Sistemi Projesi (TARBİL) projesi kapsamında desteklenen projelerin birçoğunda derin öğrenme algoritmalarının kullanıldığı ve eğitilen modellerin insansız araçlarda kullanıldığı görülmektedir. Durmuş ve ark., “Derin Öğrenmeyi Kullanarak Domates Bitkilerinin Yapraklarında Hastalık Tespiti” adlı TARBİL destekli çalışmasında domates bitkisinin hastalıklarını tespit için derin öğrenme algoritmaları kullanmıştır. Çalışmada AlexNet ve SqueezeNet derin öğrenme mimarileri kullanılarak açık kaynak veri setleri ile modeller eğitilmiştir. On farklı sınıftan oluşan veri seti Nvidia Jetson TX1 kartı üzerinde eğitilmiş ve test edilmiştir [5]. Aynı temeller üzerine yapılan bir başka çalışmada sera içerisinde otonom bir şekilde dolaşarak bilgi toplayan ve seranın haritasını çıkaran bir insansız kara aracı (İKA) tasarlanmıştır. İKA otonom veya manuel olarak sera içinde hareket edebilmekte ve RGB-D harita çıkarmanın yanında nem, sıcaklık ve ışık verilerini de toplamaktadır [76]. Durmuş ve ark. tarafından yürütülen TARBİL destekli bir başka projede gübrelemeden hastalık teşhisi ve müdahaleye kadar birçok işleve sahip bir insansız kara aracı geliştirilmiştir. Çalışmada sistemlerin yerlilik oranının da arttırılması hedeflenmiştir. Çalışma nesnelerin interneti uygulamalarını da içerisinde barındırmaktadır. İnsansız kara aracına ait görsel Şekil 2’de verilmiştir. [77].



Şekil 2. a) Otonom veri toplayan insansız kara aracı. b) Derin öğrenme destekli insansız kara aracı.

Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü (TAGEM) desteğinde gerçekleştirilen kendi yürü pülverizatör projesinde çiftçilerin ilaçlama konusunda yetersiz bilgi sahibi olması, gerekli yönlendirmeleri yapabilecek personel sayısının yetersiz oluşuna ve çiftçilerin doğrudan zirai ilaçlara maruz kalmasının meydana getireceği olumsuzluklara bir çözüm bulmak amacıyla uzakta kumanda edilebilen otomatik ilaç püskürtme kabiliyetine sahip bir insansız kara aracı geliştirilmiştir. Çalışmada henüz yapay zekâ ve derin öğrenme algoritmaları kullanılmamıştır. İmal edilen insansız kara aracına ait görüntü Şekil 3'te verilmiştir [2].



Şekil 3. Örtü altı kumandalı otomatik ilaçlama sistemli insansız kara aracı.

4.2.2 Mobil Uygulamalar ve Nesnelerin İnterneti Tabanlı Çalışmalar

Bitki hastalıklarında derin öğrenme üzerine yapılan çalışmalar incelendiğinde bu çalışmaların bazılarının mobil uygulama veya nesnelerin interneti (IoT) tabanlı yapıldığı görülmektedir. Mobil uygulamalar ile daha önceden eğitilmiş derin öğrenme algoritmaları gerçek ortamlarda uygulama alanı

bulabilmekte, çiftçiye yol gösterici mobil uygulamalar oluşturulabilmektedir. IoT tabanlı uygulamalar ise çitayı bir üste taşıyıp sensörlerden alınan verilerin sunuculara, mobil cihazlara, gömülü sistemlere, robotik ve otonom sistemlere ulaştırılmasını, buralarda derin öğrenme algoritmalarının devreye girerek destek ve karar mekanizmasına katılmasını sağlayabilmektedir.

Chouhan ve ark. çalışmalarında bulanık tabanlı fonksiyon ağı ile nesnelerin interneti etkileştirerek bitki yapraklarında hastalık tespiti yapan bir sistem geliştirmiştir. Çalışmada ağıın eğitim süreci Firefy algoritması kullanılarak daha verimli hale getirilmiştir. Kullanılan yöntem mevcut yöntemlerden daha yüksek başarı oranı sergilemiştir [78].

Ülkemizde yürütölen Hassas tarım projeleri kapsamında bitki hastalıklarının önleme ve zararlılarla mücadele etmek için kullanılan kimyasalların sensör ve derin öğrenme teknolojileri ile çevreye daha duyarlı bir şekilde uygulanmasına yönelik çalışmalar bulunmaktadır. Ülkemizde yürütölen diğeri bir yüksek teknoloji tarım projesi ise Merkezi Dane Kaybı İzleme ve Takip Sistemidir. Hasatta tahmini 1,77 milyon ton dane kaybı yaşanmaktadır. Projede bulut tabanlı IoT uygulamalar kullanılarak hasat yapan biçerdöverden gelen veriler anlık olarak merkeze aktarılarak hasat durum bilgisi ve biçerdöverin konum bilgisi üzerinden değerlendirme yapılmaktadır. Diğeri bir projede ise buğday zararlılarında süneyle mücadelede yapay zeka ve derin öğrenme algoritmaları kullanılarak tahmin ve uyarı sistemi oluşturulmuştur [2]. Kimi çalışmalarda ise mobil cihazlar sadece veri toplamak için kullanılmıştır. Sibiyaya ve ark., yaptıkları çalışmada mısır yaprağı görüntüleri mobil cihaz ile elde etmişlerdir. Elde edilen görüntüler ile evrişimsel sinir ağı eğitilerek %92.85 doğruluk oranına ulaşmışlardır [79].

T.C. Tarım ve Orman Bakanlığı ile İstanbul Teknik Üniversitesi ortaklığında yürütölen Tarımsal İzleme ve Bilgi Sistemi Projesi (TARBİL) projesi kapsamında uydulardan alınan gerçek zamanlı bilgiler derin öğrenme algoritmalarının da kullanımı ile faydalı bilgilere dönüştürölüp çiftçilere saatlik ve günlük bilgi mesajları gönderilmesini bu sayede gübre, ilaç ve su tasarrufu sağlamaktadır. Güneydoğu Anadolu bölgesinde sahada bulunan istasyonlardan alınan ve işlenerek yorumlanan veriler hassas rekolte hesabı yapma imkanı sağlamaktadır. Çiftçilere sağlanacak tabletler ile ilaç ve gübre gibi uygulamaların anlık kaydı ve takibini yapma ve çiftçinin kendi tarlasındaki durumu dijital ortamda görüntöleme imkânı sağlanmaktadır [51]. TARBİL projesinde IoT tabanlı uygulamaların da sistem içine dahil edildiği görölmektedir. Sistemdeki tüm cihazlar IoT tabanlı sistemler ile araştırma merkezine veri aktarmaktadır. Aynı zamanda çiftçilerin mobil cihazlarına merkez üzerinde anlık bilgiler gönderilmektedir [77].

5. Sonuç

Bitki hastalıklarının tespit ve teşhise yönelik yapılan mevcut çalışmalar incelendiğinde bu çalışmaların bir kısmının renk, doku şekil gibi temel özellikleri ele alarak geleneksel yapay zekâ yöntemleri ile problemi ele aldığı görülmektedir. Ancak bu yöntemlerin birçok uygulamasında ideal şartlarda çekilmiş fotoğrafların kullanıldığı görülmekte ve bu açıdan pratikte kullanılabilirliklerinin düşük olduğu anlaşılmaktadır. Bu sebeple birçok konuda olduğu gibi bitki hastalıklarının tespit ve teşhisine yönelik çalışmalarda da yapay zekada derin öğrenme uygulamalarının daha umut vadettiği söylenebilir.

Yapay zekada derin öğrenme uygulamalarında mevcut çalışmalar incelendiğinde çalışmaların büyük bir kısmının açık kaynak veri setleri ile yapıldığı ve daha çok model oluşturma ve bu modelleri mevcut derin öğrenme mimarilerinin sonuçları karşılaştırma şeklinde çalışmaların yapıldığı görülmektedir. Bazı çalışmalarda ise derin öğrenme algoritmaları gömülü sistemlere entegre edilerek insansız araçlar ve otomasyon sistemleri geliştirilmiştir. Geliştirilen sistemlerin bir kısmında IoT teknolojileri de entegre edilmiştir. Devlet veya şirket destekli projelerde ise uydu teknolojileri gibi daha yüksek maliyetli teknolojiler tüm bu sistemlerle birlikte kullanılmışlardır.

Tarım sektöründe dijitalleşme, mevcut potansiyelden en üst düzeye faydalanılabilmesi için son derece önemlidir. Bu nedenle, tarım sektöründe dijitalleşmeyi yaygınlaştırmak ve desteklemek gereklidir. Küçük çiftçilere destek sağlanmalı, arazi, teknoloji ve piyasalara eşit erişim imkânları sunulmalı ve sürdürülebilir tarım uygulamaları teşvik edilmelidir. Ayrıca, bitki hastalıklarıyla mücadelede derin öğrenme yöntemlerinin kullanılması da tarımda verimliliği artırmak için önemli bir adımdır.

Tarım sektöründeki verimliliği artırmak ve bitki hastalıklarının önlenmesi için altyapı ve teknolojiye yatırım yapılmalıdır. Tarım makineleri endüstrisinde yeterli ölçüde Ar-Ge çalışmaları yapılmamaktadır ve bu alanda daha fazla ürün geliştirme odaklı çalışmalara ihtiyaç vardır. Bununla birlikte, bitki hastalıklarının önlenmesi ve kontrol edilmesi için derin öğrenme tekniklerinin kullanılması da büyük önem taşır. Bitki hastalıkları tarımsal üretimi olumsuz etkileyebilir ve hasar verebilir. Derin öğrenme yöntemleri, bitki hastalıklarının erken teşhisinde ve tanımlanmasında etkili bir şekilde kullanılabilir. Bu teknikler, bitki hastalıklarının belirtilerini ve patojenlerini tanımak için büyük miktarda veriyi analiz edebilir ve böylece hastalıkların yayılmasını önleyebilir veya müdahale sürecini hızlandırabilir.

Tarım sektöründeki dijitalleşme ve derin öğrenme tekniklerinin birleşimi, daha verimli ve sürdürülebilir tarım uygulamalarının geliştirilmesine yardımcı olacaktır. Bu sayede rekabetçi bir üretim sağlanabilir ve bitki hastalıklarının kontrol altına alınması konusunda önemli adımlar atılabilir. Tarım sektöründe yapılan Ar-Ge çalışmaları ve teknolojiye yatırım, gelecekte tarım-

sal üretimde daha etkili ve güvenilir bir şekilde bitki hastalıklarıyla mücadele etmemize olanak sağlayacaktır.

Türkiye tarımında dijitalleşmenin mevcut durumunu tespit etmeyi, iyi uygulama örneklerini ortaya koymayı ve Ulusal E-Tarım Stratejisinin geliştirilmesini amaçlamaktadır. Bitki hastalıklarının derin öğrenme yöntemleriyle mücadelesinin de dâhil edildiği bu süreçte, tarım sektöründe dijitalleşme ve teknolojik gelişmelerin kullanımı, bitki hastalıklarıyla etkili bir şekilde mücadele etmemizi sağlaması beklenmektedir. Derin öğrenme teknikleri, bitki hastalıklarının erken teşhisini ve tanımlamasını destekleyerek tarım verimliliğini arttırması ve hastalıkların yayılmasını önlemesi beklenen bir durumdur. Türkiye'nin tarım sektöründe dijitalleşme ve derin öğrenme tekniklerini kullanarak ulusal bir strateji geliştirmesi, bitki hastalıklarıyla mücadelede etkili bir şekilde ilerlemesini sağlayacaktır.

KAYNAKÇA

- [1]. Ertem, S., & Özbay, E. (2022). Sınıflandırma Probleminde Derin Özellik Birleştirme Yaklaşımıyla Domates Yaprağı Görüntülerinde Hastalık Tespiti. *European Journal of Science and Technology*.
- [2]. Pakdemirli, B., Birişik, N., Aslan, İ., Sönmez, B., & Gezici, M. (2021). Türk Tarımında Dijital Teknolojilerin Kullanımı ve Tarım-Gıda Zincirinde Tarım 4.0. *Toprak Su Dergisi*, 10(1), 78-87.
- [3]. Kaya, M. (2021). Tarımda Yapay Zekâ Uygulamaları - II. İçinde Ş. Sağıroğlu & M. U. Demirezen (Ed.), *Yapay Zekâ Ve Büyük Veri Çalışmaları, Siber Güvenlik ve Mahremiyet* (1. bs, C. 1, ss. 393-424).
- [4]. Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70-90.
- [5]. Ngugi, L. C., Abelwahab, M., & Abo-Zahhad, M. (2021). Recent advances in image processing techniques for automated leaf pest and disease recognition – A review. *Information Processing in Agriculture*, 8(1), 27-51.
- [6]. Sevli, O. (2022). Elma Bitkisi Hastalıklarının Derin Öğrenme ile Tespiti. İçinde A. KARDAŞLAR & M. KIDIRYÜZ (Ed.), *INTERNATIONAL EUROASIA Congress on Scientific Researches and Recent Trends 9* (ss. 339-346).
- [7]. Momol, M. T. (1988). Bitki Hastalıklarının Ölçümü. *Ankara Üniversitesi Ziraat Fakültesi Dergisi*, 1(2), 67-74.
- [8]. Türkoğlu, M. (2013). Otomatik kan hücrelerinin tanınması ve sınıflandırılmasında değişmez momentlere dayalı görüntü işleme yöntemlerinin kullanılması [Yüksek Lisans Tezi]. *Fırat Üniversitesi. Fen Bilimleri Enstitüsü*.
- [9]. Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66.
- [10]. Karhan, M., Oktay, M. O., Karhan, Z., & Demir, H. (2011, May). Morfolojik görüntü işleme yöntemleri ile kayısılarda yaprak delen (çil) hastalığı sonucu oluşan lekelerin tespiti. In *6th International Advanced Technologies Symposium (IATS'11)* (Vol. 3, pp. 172-176).
- [11]. Ming-Kuei Hu. (1962). Visual pattern recognition by moment invariants. *IEEE Transactions on Information Theory*, 8(2), 179-187.
- [12]. Turkoglu, M., & Hanbay, D. (2019). Recognition of plant leaves: An approach with hybrid features produced by dividing leaf images into two and four parts. *Applied Mathematics and Computation*, 352, 1-14.
- [13]. Türkoğlu, M., & Hanbay, D. (2019). Shearlet dönüşüm ve yeni geometrik özellikler kullanılarak aşırı öğrenme makinesine dayalı bitki tanıma sistemi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 34(4), 2097-2112.
- [14]. Easley, G., Labate, D., & Lim, W.-Q. (2008). Sparse directional image representations using the discrete shearlet transform. *Applied and Computational Har-*

monic Analysis, 25(1), 25-46.

- [15]. Turkoglu, M., & Hanbay, D. (2019). Leaf-based plant species recognition based on improved local binary pattern and extreme learning machine. *Physica A: Statistical Mechanics and its Applications*, 527, 121297.
- [16]. Çalışkan, A., Acar, E., & Kaya, Y. (2012). GLCM Tabanlı K-NN Sınıflandırıcı Modeli ile Avuç İçi Tanıma Sistemi. *Batman Üniversitesi Yaşam Bilimleri Dergisi*, 1(2), 1-10.
- [17]. Wang, Z., Li, H., Zhu, Y., & Xu, T. (2017). Review of Plant Identification Based on Image Processing. *Archives of Computational Methods in Engineering*, 24(3), 637-654.
- [18]. Shashua, A., Gdalyahu, Y., & Hayun, G. (t.y.). Pedestrian detection for driving assistance systems: single-frame classification and system level performance. *IEEE Intelligent Vehicles Symposium*, 2004, 1-6.
- [19]. Şeker, A., Diri, B., & Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- [20]. Ayyüce Kızrak, M., & Bolat, B. (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286.
- [21]. Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [22]. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems 25 (NIPS 2012)*.
- [23]. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2014). Going Deeper with Convolutions. *arXiv:1409.4842*.
- [24]. Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition.
- [25]. He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep Residual Learning for Image Recognition.
- [26]. Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size.
- [27]. Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications.
- [28]. Huang, G., Liu, Z., van der Maaten, L., & Weinberger, K. Q. (2016). Densely Connected Convolutional Networks.
- [29]. Zhang, X., Zhou, X., Lin, M., & Sun, J. (2017). ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices.
- [30]. Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convo-

lutional Neural Networks.

- [31]. Qin, F., Liu, D., Sun, B., Ruan, L., Ma, Z., & Wang, H. (2016). Identification of Alfalfa Leaf Diseases Using Image Recognition Technology. *PLOS ONE*, 11(12), e0168274.
- [32]. Singh, V., Varsha, & Misra, A. K. (2015). Detection of Unhealthy Region of Plant Leaves Using Image Processing and Genetic Algorithm. 2015 International Conference on Advances in Computer Engineering and Applications, 1028-1032.
- [33]. Singh, V., & Misra, A. K. (2017). Detection of plant leaf diseases using image segmentation and soft computing techniques. *Information Processing in Agriculture*, 4(1), 41-49.
- [34]. Ramesh, S., & Vydeki, D. (2020). Recognition and classification of paddy leaf diseases using Optimized Deep Neural network with Jaya algorithm. *Information Processing in Agriculture*, 7(2), 249-260.
- [35]. Pantazi, X. E., Moshou, D., & Tamouridou, A. A. (2019). Automated leaf disease detection in different crop species through image features analysis and One Class Classifiers. *Computers and Electronics in Agriculture*, 156, 96-104.
- [36]. Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, 7.
- [37]. Asfarian, A., Herdiyeni, Y., Rauf, A., & Mutaqin, K. H. (2013). Paddy diseases identification with texture analysis using fractal descriptors based on fourier spectrum. 2013 International Conference on Computer, Control, Informatics and Its Applications (IC3INA), 77-81.
- [38]. Majumdar, D., Kole, D. K., Chakraborty, A., & Majumder, D. D. (2015). An Integrated Digital Image Analysis System for Detection, Recognition and Diagnosis of Disease in Wheat Leaves. *Proceedings of the Third International Symposium on Women in Computing and Informatics*, 400-405.
- [39]. Revathi, P., & Hemalatha, M. (2012). Classification of cotton leaf spot diseases using image processing edge detection techniques. 2012 International Conference on Emerging Trends in Science, Engineering and Technology (INCOSET), 169-173.
- [40]. Zhang, Z., Li, Y., Wang, F., & He, X. (2014). A Particle Swarm Optimization Algorithm for Neural Networks in Recognition of Maize Leaf Diseases. *Sensors & Transducers Journal*, 166(3), 181-189.
- [41]. Pixia, D., & Xiangdong, W. (2013). Recognition of Greenhouse Cucumber Disease Based on Image Processing Technology. *Open Journal of Applied Sciences*, 03(01), 27-31.
- [42]. Pires, R. D. L., Gonçalves, D. N., Oruê, J. P. M., Kanashiro, W. E. S., Rodrigues, J. F., Machado, B. B., & Gonçalves, W. N. (2016). Local descriptors for soybean disease recognition. *Computers and Electronics in Agriculture*, 125, 48-55.
- [43]. Alehegn, E. (2017). Maize Leaf Diseases Recognition And Classification Based

- On Imaging And Machine Learning Techniques. *International Journal of Innovative Research in Computer and Communication Engineering*, 5(12), 1-11.
- [44]. Pujari, J., Yakkundimath, R., & Byadgi, A. (2013). Classification of Fungal Disease Symptoms affected on Cereals using Color Texture Features. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 6(6), 321-330.
- [45]. Liang, W., Zhang, H., Zhang, G., & Cao, H. (2019). Rice Blast Disease Recognition Using a Deep Convolutional Neural Network. *Scientific Reports*, 9(1), 2869.
- [46]. Chen, J., Zhang, D., Nanekaran, Y. A., & Li, D. (2020). Detection of rice plant diseases based on deep transfer learning. *Journal of the Science of Food and Agriculture*, 100(7), 3246-3256.
- [47]. Goncharov, P., Uzhinskiy, A., Ososkov, G., Nechaevskiy, A., & Zudikhina, J. (2020). Deep Siamese Networks for Plant Disease Detection. *EPJ Web of Conferences*, 226, 03010.
- [48]. Zhang, X., Qiao, Y., Meng, F., Fan, C., & Zhang, M. (2018). Identification of Maize Leaf Diseases Using Improved Deep Convolutional Neural Networks. *IEEE Access*, 6, 30370-30377.
- [49]. Rezende, V., Costa, M., Santos, A., & de Oliveira, R. C. L. (2019). Image Processing with Convolutional Neural Networks for Classification of Plant Diseases. *2019 8th Brazilian Conference on Intelligent Systems (BRACIS)*, 705-710.
- [50]. Ahila Priyadharshini, R., Arivazhagan, S., Arun, M., & Mirnalini, A. (2019). Maize leaf disease classification using deep convolutional neural networks. *Neural Computing and Applications*, 31(12), 8887-8895.
- [51]. Durmus, H., Gunes, E. O., & Kirci, M. (2017). Disease detection on the leaves of the tomato plants by using deep learning. *2017 6th International Conference on Agro-Geoinformatics*, 1-5.
- [52]. Ecemiş, İ. N., & O. İlhan, H. (2022). Domates yapraklarında hastalık tespiti için önerilen hafif evrişimli sinir ağı ile önceden eğitilmiş ağların performans karşılaştırması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(2), 693-706.
- [53]. Atik, İ. (2022). Derin Öğrenme Yöntemi ile Bitki Yaprığı Hastalık Sınıflandırma Çalışması Performans Analizi. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 25(2), 126-137.
- [54]. Türkoğlu, M., Hanbay, K., Saraç Sivrikaya, I., & Hanbay, D. (2020). Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 334-345.
- [55]. Ensari, T., Armah, D. C., Balsever, A. E., & Dağtekin, M. (2020). Görüntü Tabanlı Dijital Bitki Fenotipleme için Konvolüsyonel Sinir Ağları. *European Journal of Science and Technology*, 338-342.
- [56]. Aslan, M. (2021). Derin Öğrenme ile Şeftali Hastalıklarının Tespiti. *European Journal of Science and Technology*, 23, 540-546.

- [57]. Yaman, O., & Tuncer, T. (2022). Bitkilerdeki Yaprak Hastalığı Tespiti için Derin Özellik Çıkarma ve Makine Öğrenmesi Yöntemi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 123-132.
- [58]. Aksoy, B., Halis, H. D., & Salman, O. K. M. (2020). Elma Bitkisindeki Hastalıkların Yapay Zekâ Yöntemleri ile Tespiti ve Yapay Zekâ Yöntemlerinin Performanslarının Karşılaştırılması. *International Journal of Engineering and Innovative Research*, 2(3), 194-210.
- [59]. Kilic, E., Ecemis, I. N., & Ilhan, H. O. (2021). Narenciye Ağaç Yaprak Hastalıklarının Evrişimli Sinir Ağları ile Sınıflandırılması. *2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, 452-456.
- [60]. Gunduz, H., & Yilmaz Gunduz, S. (2022). Plant Disease Classification using Ensemble Deep Learning. *2022 30th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- [61]. Barbedo, J. G. A. (2018). Factors influencing the use of deep learning for plant disease recognition. *Biosystems Engineering*, 172, 84-91.
- [62]. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- [63]. Cruz, A. C., Luvisi, A., De Bellis, L., & Ampatzidis, Y. (2017). X-FIDO: An Effective Application for Detecting Olive Quick Decline Syndrome with Deep Learning and Data Fusion. *Frontiers in Plant Science*, 8.
- [64]. Brahimi, M., Boukhalfa, K., & Moussaoui, A. (2017). Deep Learning for Tomato Diseases: Classification and Symptoms Visualization. *Applied Artificial Intelligence*, 31(4), 299-315.
- [65]. Tetila, E. C., Machado, B. B., Menezes, G. K., Da Silva Oliveira, A., Alvarez, M., Amorim, W. P., De Souza Belete, N. A., Da Silva, G. G., & Pistori, H. (2020). Automatic Recognition of Soybean Leaf Diseases Using UAV Images and Deep Convolutional Neural Networks. *IEEE Geoscience and Remote Sensing Letters*, 17(5), 903-907.
- [66]. Liu, B., Ding, Z., Tian, L., He, D., Li, S., & Wang, H. (2020). Grape Leaf Disease Identification Using Improved Deep Convolutional Neural Networks. *Frontiers in Plant Science*, 11.
- [67]. YAMAN, O., & TUNCER, T. (2022). Bitkilerdeki Yaprak Hastalığı Tespiti için Derin Özellik Çıkarma ve Makine Öğrenmesi Yöntemi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 123-132.
- [68]. Bakr, M., Abdel-Gaber, S., Nasr, M., & Hazman, M. (2022). DenseNet Based Model for Plant Diseases Diagnosis. *European Journal of Electrical Engineering and Computer Science*, 6(5), 1-9.
- [69]. Hu, G., Yang, X., Zhang, Y., & Wan, M. (2019). Identification of tea leaf diseases by using an improved deep convolutional neural network. *Sustainable Computing: Informatics and Systems*, 24, 100353.

- [70]. Mattihalli, C., Gedefaye, E., Endalamaw, F., & Necho, A. (2018). Plant leaf diseases detection and auto-medicine. *Internet of Things*, 1-2, 67-73.
- [71]. Nalawade, R., Nagap, A., Jindam, L., & Ugale, M. (2020). Agriculture Field Monitoring and Plant Leaf Disease Detection. *2020 3rd International Conference on Communication System, Computing and IT Applications (CSCITA)*, 226-231.
- [72]. Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A Review on UAV-Based Applications for Precision Agriculture. *Information*, 10(11), 349.
- [73]. AKKAMIŞ, M., & ÇALIŞKAN, S. (2020). İnsansız Hava Araçları ve Tarımsal Uygulamalarda Kullanımı. *Türkiye İnsansız Hava Araçları Dergisi*, 2(1), 8-16.
- [74]. Hasan, M., Tanawala, B., & Patel, K. J. (2019). Deep Learning Precision Farming: Tomato Leaf Disease Detection by Transfer Learning. *SSRN Electronic Journal*.
- [75]. Doğan, Y., & Yıldız, F. (2019). İHA ile Multispektral Kameralardan Sağlanan Görüntüler Yardımıyla Bitki Türlerinin Sınıflandırılması. *Türkiye İnsansız Hava Araçları Dergisi*, 1(1), 15-22.
- [76]. Durmus, H., Gunes, E. O., & Kirci, M. (2016). Data acquisition from greenhouses by using autonomous mobile robot. *2016 Fifth International Conference on Agro-Geoinformatics (Agro-Geoinformatics)*, 1-5.
- [77]. Durmus, H., Gunes, E. O., Kirci, M., & Ustundag, B. B. (2015). The design of general purpose autonomous agricultural mobile-robot: "AGROBOT" 2015 Fourth International Conference on Agro-Geoinformatics (Agro-geoinformatics), 49-53. *IEEE*
- [78]. Chouhan, S. S., Singh, U. P., & Jain, S. (2021). Automated Plant Leaf Disease Detection and Classification Using Fuzzy Based Function Network. *Wireless Personal Communications*, 121(3), 1757-1779.
- [79]. Sibiya, M., & Sumbwanyambe, M. (2019). A Computational Procedure for the Recognition and Classification of Maize Leaf Diseases Out of Healthy Leaves Using Convolutional Neural Networks. *AgriEngineering*, 1(1), 119-131.

Bölüm 3

EVİRİMSEL HESAPLAMA

Ümit CAN¹

1. Giriş

Evrimsel hesaplama bilgisayar bilimi içinde doğal evrim sürecinden esinlenen önemli bir araştırma alanıdır. Bazı bilgisayar bilimciler çeşitli karmaşık mühendislik problemlerin çözümünde etkili bir çözüm yöntemi oluşturmak için evrimin gücünden faydalanmak istemiş ve bundan dolayı ilham kaynağı olarak doğal evrimi seçmişlerdir. Evrimin gücü, ilk tek hücreli canlı organizmaların oluşumundan günümüze kadar dünyamızda birçok türün hayatta kalma sürecinde belirgin bir şekilde görülmektedir (Spear vd., 1993). Evrimsel hesaplamanın temel anlayışı, bu güçlü doğal evrimi belirli bir problem çözme tarzını inşa ederken kullanmasında ortaya çıkmaktadır. Doğal evrimde belirli bir çevrede, hayatta kalmak ve üremek için çabalayan bireylerden oluşan bir popülasyon bulunmaktadır. Bu bireylerin gelecek nesiller için uygunluğu çevre tarafından belirlenir ve bu uygunluk bireylerin o çevreyle ne kadar uyumlu oldukları ile doğru orantılıdır. Başka bir deyişle, bu uyum hayatta kalma ve çoğalma şanslarını temsil eder (Bäck vd., 1997).

Evrimsel hesaplama doğadaki evrim sürecinin başarısından esinlenerek evrimin bileşenlerini çeşitli mühendislik yöntemleri üretmek için kullanmıştır. Böylece evrimsel hesaplama yöntemleri diyeceğimiz yeni teknikler özellikle optimizasyon alanı başta olmak üzere birçok alanda başarı ile uygulanmıştır. Bu yöntemler günümüzde birçok farklı yapay zeka ve makine öğrenmesi problemlerinin çözümünde kullanılmaktadır. Bu başarılı yöntemler yumuşak hesaplama veya hesaplamalı zeka yöntemleri altında sınıflandırılmıştır. Evrimsel hesaplama sezgisel yöntemler arasında yer almakta ve bir problemin çözümü sırasında birçok deneme yaparak olası çözümler içerisinde en uygun çözümü bulmaya çalışmaktadır. Elde edilen çözümlerin beklenen çözüme ne kadar yakın olduğunu ölçerken bir hata denetimi yapılır. Bu hata oranı ile elde edilen çözümlerin yeni çözümler üretmede kullanılıp kullanılmayacağını belirlenir ve bu açıdan hatanın doğru bir şekilde hesaplanması yöntemim işleyişi açısından oldukça önemlidir. Burada dikkat edilmesi gereken husus hata oranı düşük olan çözüm adaylarının kullanılarak daha bir sonraki daha başarılı çözümlerin bulunmaya çalışılmasıdır. Böylelikle başarılı bir evrim süreci taklit edilerek en iyi çözümler bulunmaya çalışılmaktadır (Altenberg, 2016; Slowik and Kwasnicka, 2020).

1.1. Evrimsel Hesaplamanın Kısa Tarihçesi

Evrimsel hesaplama alanında evrimsel prensiplerin çeşitli problem çözme süreçlerine uygulanma fikri 1940'lı yıllara kadar uzanmaktadır. Bu dönemde, Turing 1948'de "genetik veya evrimsel arama" kavramını önermiştir (Sterrett, 2017). Evrimsel hesaplama alanı, 1950'ler ve 1960'larda bilgisayarlarda evrim sürecini kullanma amacıyla yapılan birkaç bağımsız girişimle başlamıştır. 1990'ların başlarından itibaren evrimsel hesaplama yöntemlerine genetik programlama (GP) olarak adlandırılan yeni bir yöntem eklenmiştir. Bu yak-

laşım, seçim yöntemi, izin verilen mutasyonlar ve genetik verilerin temsili bakımından farklılık gösterir.

Evrim ve rekombinasyon yoluyla optimizasyon üzerine bilgisayar deneyleri 1962 yılında Bremermann tarafından gerçekleştirilmiştir (Bremermann, 1962). Bu amaç için yaklaşık aynı zamanda ve üç farklı yerde üç yöntem geliştirilmiştir. Bu yöntemler arasında genetik algoritma (GA)'lar, evrimsel programlama (EP) ve evrimsel stratejileri (ES)' bulunmaktadır. 1960'ların başında Fogel, Owens ve Walsh bu kavramın Amerika Birleşik Devletleri'ndeki üç farklı uygulamasını EP olarak duyururken, Holland kendi yaklaşımını genetik algoritma olarak adlandırmıştır (Holland, 1962c). Rechenberg (1965) ve Schwefel (1968) bu dönemde Almanya'da EP'yi bulmuşlardır. Bu girişimler yaklaşık 15 yıl boyunca ayrı ayrı gelişmiştir ancak 1990'ların başlarından itibaren evrimsel hesaplama olarak bilinen bu teknoloji, bu alandaki tüm farklı yaklaşımları içeren bir alan olarak kabul edilmeye başlanmıştır.

1.2. Evrimsel algoritmalar

Doğal evrim süreci doğada karmaşık ve iyi adapte olmuş canlı organizmalarının ortaya çıkmasındaki ana süreçtir ve birçok evrimsel algoritma (EA) bu süreci taklit eder. Bu algoritmalar evrimin yeni genetik bilginin oluşturulması ile değerlendirilmesi ve seçilmesi arasındaki etkileşimin sonucudur. Bu algoritmaların çözmesi gereken her bir problem için problemin çözümü, arama uzayı denilen olası aday çözümlerin bir uzayında bulunur (Back vd., 1997).

Zaman içinde ortaya çıkan farklı özellikteki EA'ların dayandığı bir ana düşünce vardır. Bu düşünceye göre belirli bir çevrede kısıtlı miktarda besin bulunur ve bu besini elde etmek için o çevrede bulunan bireyler birbirleri ile rekabet ve mücadele içine girerler. Bu rekabet süreci sonucunda doğal bir seçim ortaya çıkar. Daha güçlü bireyleri seçmek gibi bir eğilim süreci oluşur (Vikha, 2016). EA birçok bireyden oluşan bir popülasyonda bireylerin seçilme uygunluğunu hesaplamak için bir uygunluk (kalite, amaç) fonksiyonu kullanırlar. Rastgele birçok bireyden oluşan bir popülasyonda bireylerin hesaplanan uygunluk fonksiyonu değerleri ne kadar yüksekse o bireylerin bir sonraki nesle aktarılma şansı o kadar yükselir. Böylece uygunluğu daha güçlü bireylerden oluşan yeni bir popülasyon oluşabilir (Goings ve Ofria, 2009).

Evrimsel algoritmalarda bir problemin daha iyi çözümlerini bulmak için aday çözümleri barındıran bir popülasyondaki birey çeşitliliğini artırarak daha güçlü bireylerin oluşturulması amaçlanır. Bu çeşitliliği sağlamak içinde mutasyon, rekombinasyon (çaprazlama) ve seçim gibi işlemler yapılır. Bu işlemler evrimsel operatörler olarak adlandırılır. Bu operatörlerden ilki olan rekombinasyon operatörü seçilmiş olan iki veya daha fazla bireyin belli kısımlarını alarak yeni bir birey oluşturmayı amaçlamaktadır (Kang, 2022). Bu birleştirme işlemi farklı şekillerde olabilir. Sonuç itibarıyla yeni bir birey olu-

şur. Mutasyon işlemi ise örneğin bir bit dizisinde belli sayıdaki ‘0’ olan bitlerin “1” ya da “1” olan bitlerin ise “0” olarak değiştirilmesi işlemidir. Bu bir tersine alma işlemi olarak düşünülebilir (Eiben, and Smith, 2015). Mutasyon sonucunda belli sayıdaki parametrenin veya değerin değiştirilmesi sonucunda yeni birey veya bireyler oluşur (Kora ve Yadlapalli, 2017). Sonuç itibariyle rekombinasyon ve mutasyon işlemlerinin peş peşe yapılması ile belli oranda yeni bireylerden oluşan bir popülasyon ortaya çıkar. Daha sonrada bu bireylerin uygunlukları hesaplanarak uygunluğu yüksek bireyler eskilerin (kendilerinden daha az uygunluğa sahip olanların) yerini alır. Bu süreç istenen uygunluk değerine sahip bireyler topluluğu oluşana kadar devam eder (Srinivas ve Patnaik, 1994). Rekombinasyon, mutasyon (varyasyon operatörleri olarak adlandırılırlar) ve seçim operatörlerinin ardı sıra uygulanması bir popülasyondaki bireylerin iterasyonlar sonucunda uygunluklarının artmasına neden olur (Eiben, and Smith, 2015). EA’larda kullanılan operatörler ilerleyen bölümlerde daha da ayrıntılı olarak anlatılacaktır.

Sezgisel yöntemler olarak adlandırılan evrimsel algoritmaların birçok bileşeni rastgeledir. Örneğin başlangıç popülasyonu oluşturulurken rastgele oluşturulur veya rekombinasyon işlemi sırasında ise seçilen ebeveynlerin hangi parçalarının seçileceği ve çaprazlanacağı rastgele yapılır. Seçim işlemi gerçekleştirilirken sadece uygunluğu yüksek bireyler alınmaz yapılan rastgele seçimde zayıf bireylerde seçilebilir. Aynı rastlantısallık mutasyon işlemi sırasında hangi parçaların değiştirileceğinin belirlenmesinde de devam eder. Bir evrimsel algoritmanın genel sözde kodu Şekil 1’de verilmiştir.

BEGIN

BAŞLAT rastgele aday çözümlerle popülasyonu;

DEĞERLENDİR her bir aday çözümü;

SONLARDIRMA KRİTERİ SAĞLANINCAYA KADAR DO

SEÇ ebeveynleri;

REKOMBİNE ebeveyn çiftlerini;

MUTASYON yeni yavrular oluştur;

DEĞERLENDİR yeni adaylar;

SEÇ sonraki nesiller için bireyleri;

OD END

Şekil 1. Bir evrimsel algoritmanın genel sözde kodu

Sezgisel çözüm bulma mantığına uygun olarak EA’lar daha iyi bireyleri seçmek için uygunluk fonksiyonunu kullanırlar ve bu bireyleri arama süreci, varyasyon ve seçim operatörleri yönetir. EA aşağıdaki genel özelliklere sahiptirler (Eiben ve Smith, 2015).

- EA’lar birçok aday çözümden (bireyden) oluşan popülasyon tabanlı yöntemlerdir.

- EA yöntemlerinin birçoğu rekombinasyon işlemini kullanarak yeni bir çözümler oluşturur.
- EA'lar stokastik yani rastgele yöntemlerdir.

Bir optimizasyon probleminin çözümünde öncelikle arama uzayının ve amaç fonksiyonunun açık olarak ifade edilmesi gerekmektedir. Arama uzayı ve amaç fonksiyonu kavramlarının daha iyi anlaşılması için bir örnek vermek gerekirse; örneğin, $f(x, y) = \sin(x^3 - 5x - 16) \tan(-15y + y^3 - 12)$ fonksiyonunun $-1 \leq x \leq 2$ ve $-2 \leq y \leq 2$ aralıklarında maksimum değeri bulunmaya çalışılırsa arama uzayı bu aralıklar arasındadır yani arama uzayı, x ve y değişkenlerinin bu aralıklarda alabileceği değerleri içerir ve amaç fonksiyonu $f(x, y)$ olarak ifade edilir. Amaç fonksiyonu, bu x ve y değerlerini alarak hesaplanan değerlerden oluşur ve optimize etmek istediğimiz değeri temsil eder. Yani, belirli x ve y değerlerini seçerek amaç fonksiyonunu hesaplanabilir ve bu değerleri optimize etmek için arama sürecini başlatabiliriz. Daha farklı bir örnek vermek gerekirse bir makine öğrenmesi algoritmasının başarılı olmasında önemli bir yere sahip hiper parametre optimizasyonu probleminde bir hiper parametre kümesi bir arama uzayını temsil eder (Altenberg, 2016).

Arama uzayını araştırmak için, daha önceden değerlendirilmiş noktalar dikkate alınarak oluşturulan yeni çözüm noktaları kullanılır. Rekombinasyon ve mutasyon operatörleri arama uzayındaki noktalarla temsil edilen veri yapılarını geliştiren ve değiştirerek arama uzayında yeni çözüm noktaları oluşmasını sağlar. Bu süreçte seçim operatörünün görevi, hangi aday çözümlerin varyasyon operatörlerine tabi tutulacağını belirlemektir. Varyasyon operatörleri kullanılarak ortaya çıkan popülasyonun uygunluk fonksiyonu değerleri hesaplanır ve daha iyi uygunluk fonksiyonu değerine sahip örnek, sonraki örneği oluşturmak için seçilir. Bu, iterasyonlar boyunca istenen sonuç elde edilene kadar devam eder.

2. Evrimsel Algoritmaların Genel Bileşenleri

Bu bölümde EA'ların temel bileşenleri daha ayrıntılı bir şekilde anlatılmıştır. EA'ları oluşturan bileşenler, belirli bir problemi çözmek için kullanılan popülasyon tabanlı bir optimizasyon yaklaşımını temsil eder. EA'lar, doğal seçim ve genetik varyasyon prensiplerine dayanarak çeşitli bileşenler içerir. EA'ların temel bileşenleri algoritmanın popülasyonu, uygunluk fonksiyonu, seçim operatörü, varyasyon operatörleri olarak bilinen rekombinasyon operatörü ve mutasyon operatörü, sonlandırma kriteri ve yeniden üretim stratejileri gibi bileşenlerdir. Bu bileşenler, evrimsel algoritmaların temel yapı taşlarını oluşturur. Bu bileşenlerin farklı varyasyonlarla birleştirilmeleri ve ayarlanmaları, çeşitli problemler için uyarlanabilen özelleştirilmiş evrimsel algoritmaların oluşturulmasına olanak tanır.

2.1. Bireylerin Temsili

EA'nın bir probleme bir çözüm yöntemi olarak uygulanmasındaki ilk aşama bireylerin yani aday çözümlerin doğru bir şekilde temsil edilmesidir. Burada ilk olarak bir gerçek dünya problemi ile EA arasında uygun bir bağlantı kurulmalıdır. Bunu gerçekleştirmek için, problemin bağlamı ile evrimin gerçekleştiği problem çözme ortamı arasında bir bağlantı kurulmalıdır. Farklı ve yönetilebilir bir problem ortamı sağlamak için, izlenmesi gereken adımlar gerçek dünyanın birkaç bileşeninin soyutlanmasını gerektirebilir.

Genel bir EA yapısında, genotip ve fenotip kavramları bireylerin temsili açısından önemli bir yer tutar. Bir EA'da mevcut çözümleri (bireyleri) temsil etmek için genotipler kullanılır. Fenotipler ise orijinal problem uzayındaki çözümleri ifade eder. Bilgisayar bilimlari açısından basit olarak genel bir problemi çözenin ilk adımı olası cevapları bilgisayarda işlenebilir bir format şeklinde kaydetmektir. Genotipler ile aday çözümler bilgisayar ortamında temsil edilebilecek formata uygun hale gelmektedir.

Bireylerin temsil aşamasında başlangıç olarak genotipler oluşturulur. Burada fenotipleri ve genotipleri daha net bir şekilde açıklamak için bir örnek verilirse; belli bir tam sayı kümesini içeren bir optimizasyon probleminde bu tam sayılar kümesi fenotipleri oluşturur. Bu tam sayıların ikili kodlanmış karşılıkları ise genotiplerdir. Örneğin 20 sayısı bir fenotip ise bu sayıya karşılık gelen 10100 ise genotiptir. Geçerli bir çözüm veya iyi bir fenotip, evrimsel süreç tamamlandıktan sonra en iyi genotipin çözümlenmesi ile elde edilir. Bu nedenle bir fenotipin belirli bir genotip uzayında temsil edilebilir olması esastır. Bu yöntemlerde tüm olası çözümleri genotipler olarak ifade edilmesi beklenir (Eiben, and Smith, 2015).

2.2. Popülasyonun Oluşturulması

Potansiyel çözüm adaylarını içeren bir popülasyon genotiplerden oluşan bir kümeyi ifade eder ve bu küme bir evrimsel algoritmanın ana bileşenidir. Algoritmanın her bir adımında, bu popülasyon işlenir, uygunluk fonksiyonları kullanılarak değerlendirilir ve yeni bir nesil oluşturulur. Bir EA'da her bir birey, problemin bir çözüm adayını temsil eder ve popülasyon olası çözümlerin temsilini içeren bireylerin koleksiyonudur (Fogel, 1995). Bir popülasyonda kaç birey olduğu o popülasyonun büyüklüğünü ifade eder ve algoritmanın uygulanması sırasında popülasyon büyüklüğü sabit kalır. Ayrıca bir EA uygulamasında bir popülasyonun tamamı değerlendirilir.

Popülasyonun özellikleri bir EA'nın araştıracağı çözüm uzayını ve EA'nın performansını etkileyeceğinden problemlerin çözümünde önemli bir rol oynar. Bu nedenle, EA'nın tasarımında popülasyonun boyutu ve özellikleri dikkatlice seçilmelidir. Örneğin bir popülasyonun büyüklüğü, belirli bir problemi çözmek için EA'nın performansını etkileyen önemli faktörlerden biridir. Bir

EA'da popülasyon ne kadar büyük olursa arama uzayında daha fazla çözüm noktası keşfedilebilir fakat bu aynı zamanda daha fazla hesaplama maliyeti anlamına gelmektedir. Öbür yandan küçük bir popülasyon kullanıldığında ise algoritma daha hızlı çalışır fakat optimal çözümü bulma olasılığı azalabilir. Bu sebeplerden popülasyon büyüklüğü dikkatli bir şekilde seçilmelidir.

2.3. Uygunluk Fonksiyonu

Bir uygunluk fonksiyonunu bir problemin aday çözümlerini girdi olarak alarak ve bu aday çözümlere ait uygunluk değerlerini hesaplayıp o probleme uygun olan en iyi çözümü bulmaya çalışan fonksiyondur. Bu fonksiyon ile bir popülasyondaki her bir bireyin (çözüm adayının) kalitesi ölçülür; ayrıca bir çözümün ne kadar iyi veya kötü olduğu sayısal bir değerle ifade edilir (Engelbrecht, 2014). Literatürdeki farklı kaynaklarda uygunluk fonksiyonu yerine kullanılan amaç fonksiyonu ifadesinde rastlanılır. Bu iki ifade genelde aynı anlama gelir, çünkü amaç, verilen amaç fonksiyonunu maksimize veya minimize etmektir. Ayrıca uygunluk fonksiyonları çözülen problemin türüne göre farklılaşabilir. Örneğin çok boyutlu karmaşık bir problem çoklu hedefe sahip olabilir bu da farklı bir uygunluk fonksiyonu yapısı gerektirir. Uygunluk fonksiyonunun rolü, popülasyonun uyum sağlaması gereken gereksinimleri temsil etmektir. Bu, seçimi temel alır ve böylece iyileştirmeleri kolaylaştırır (Abdullah ve Ahmed, 2019)

Evrimsel sürece uygun olarak bu fonksiyon bir problemin çözüm adaylarının çevreye adaptasyon yeteneğini ölçer. Teknik olarak kısaca açıklamak gerekirse, çözüm uzayında bulunan genotiplere bir kalite ölçüsü atayan bir fonksiyon veya prosedürdür. Genellikle bu fonksiyon, karşılık gelen fenotipi oluşturmak için ters temsil ve ardından fenotip uzayındaki bir kalite ölçümünü içerir.

Bu fonksiyonların genelde uygunluk fonksiyonu olarak isimlendirmesi ilk etapta bir optimizasyon problemi için maksimizasyon görevini akıllara getirdiğinden bu isimlendirme minimizasyon problemleri için kafa karışıklığına neden olabilir (Bottaci, 2001). Ancak matematiksel olarak, minimizasyon görevini maksimizasyona görevine döndürmek veya tam tersini yapmak kolay bir işlemdir. Bir EA tarafından çözülmek istenen orijinal problem genellikle bir optimizasyon problemidir. Bu durumda, orijinal problem bağlamında genellikle amaç fonksiyonu adını kullanmak daha doğru olacaktır.

2.4. Ebeveyn Seçim Mekanizması

Bu mekanizma bir popülasyondaki bireyler arasından gelecek nesillerin oluşturulması için uygun ebeveynleri seçmek için kullanılır. Daha iyi uyum gösteren bireylerin seçilme olasılığı daha yüksektir. Ebeveyn seçiminin veya çiftleşme seçiminin rolü, bireyler arasında kaliteye dayalı bir ayırım yapmak,

özellikle de daha iyi bireylerin bir sonraki neslin ebeveyni olmasına olanak tanımaktır (Hansen and Price, 1995). Bir sonraki nesildeki yavruların oluşturulması için belli bir yöntemle seçilen bireyler değişime uğrarlar ve bu seçilen bireyler ebeveyn olarak adlandırılırlar. Hayatta kalma seçim mekanizması ile birlikte, ebeveyn seçimi popülasyonun genel kalitesini iyileştirmeye ve arttırmaya yaramaktadır. Bu durumda hesaplanan uygunluk değerlerine göre düşük kalitedeki bireylerin yüksek kalitedeki bireylere göre daha az ebeveyn olarak seçilme şansları vardır. Ayrıca bu seçim sürecinde düşük kalitedeki bireylere küçük olmakla birlikte bir şans verilir. Aksi takdirde tüm arama çok açgözlü hale gelebilir ve popülasyon yerel optimum noktasına takılabilir (Eiben ve Smith, 2015).

2.5. Mutasyon ve Rekombinasyon

Bu operatörler varyasyon operatörleri olarak adlandırılır ve eski bireylerden yeni bireyler oluşturmayı amaçlar. Bu bölümde öncelikle mutasyon operatörü ele alınacaktır.

2.5.1. Mutasyon: Bu operatör daha önceden seçilmiş bireylerin yapısını farklı mutasyon yöntemleri kullanarak rastgele değiştirir. Böylece bu işlem sonucunda bir popülasyonun çeşitliliğini genişler ve yeni özelliklerin ortaya çıkması eğilimi artar. Mutasyon operatörü bir genotipe uygulandığında, değiştirilmiş yeni çocuklar yaratılır. Evrim sürecine uygun olarak rastgele seçim içeren bir dizi eylemi içerdiğinden, mutasyon stokastiktir ve bunun koşulsuz olması beklenir. Çeşitli evrimsel yaklaşımlar mutasyon için çeşitli niteliklere sahiptir. Bu duruma örnek vermek gerekirse mutasyon operatörü GP'de genel olarak hiç kullanılmazken, GA'larda ise genetik havuzları yeni genetik materyallerle çeşitlendirmek gibi bir işlev görür. Öbür yandan EP'de yeni bireyler üretebilen tek varyasyon operatörüdür.

Rekombinasyon ve mutasyon operatörleri geniş bir arama uzayındaki çözüm arama adımlarının evrimsel adımlarını oluşturur. Böylece yeni bir çocuk oluşturmak bu uzayda yeni bir çözüm noktasına sıçrama anlamına gelir. Bazı araştırmacılara göre bir EA'ya bir problemi çözmek için yeterli zaman verildiğinde bu EA'nın belirli bir problemin global optimumunu keşfedeceği düşünülür. Bu düşünce çözümü temsil eden genotipin varyasyon operatörleri tarafından ulaşılabileceği bağlantılılık özelliğine dayanır (Eiben ve Smith, 2015).

2.5.2. Rekombinasyon

Mutasyondan farklı olarak bu operatör seçilen ebeveynlerin farklı genetik özelliklerinin alınarak yeni bireyler oluşturulmak üzere birleştirilmesi işlemlerini yapar. Böylece bir veya iki yavru genotip oluşturur. Rekombinasyon birbirine benzemeyen özelliklere sahip bireyler çiftleştirilirse, ortaya çıkacak bir çocuk bu farklı özellikleri miras alabilir ilkesine dayanır. Modern tarih bo-

yunca bitki ve hayvan yetiştiricileri bu ilkesel fikri daha fazla üretkenliğe veya diğer arzu edilen niteliklere sahip türler yaratmak için etkili bir şekilde kullanmışlardır (Otto, ve Payseur, 2019).

Rekombinasyon, mutasyona benzer şekilde, iki ebeveynin birleştirilecek kısımlarına rastgele karar verilen stokastik bir süreçtir (Vikhar, 2016). Ayrıca, farklı EA'lar rekombinasyon operatörünü farklı şekillerde kullanır. Örneğin EP'de bu operatör kullanılmazken GP'de genellikle tek başına bir varyasyon operatörü olarak kullanılır ve genetik algoritmalarında ana arama operatörü olarak işlev görür.

Rasgele rekombinasyonlarla elde edilen yavruların çoğu ebeveynlerine benzer olabilir ancak bazıları ise istenmeyen özellik kombinasyonlarını miras alabilir. Sonuç itibarıyla farklı rekombinasyon yöntemleri ile elde edilmek istenen sonuç bazı yavruların gelişmiş özelliklere sahip olmasıdır.

Varyasyon operatörlerinin öne çıkan bir özelliği ise bu operatörlerin farklı türdeki verilerin temsil biçimlerine bağlı olduklarıdır. Bu durumdan dolayı her bir temsil için varyasyon operatörlerinin özel olarak oluşturulması gerekmektedir. Bu duruma mutasyon operatörü üzerinden örnek vermek gerekirse bu operatör ağaç yapısına sahip bir çözüm kümesinde farklı, bit dizilerinden oluşan genotipler de ise farklı olarak tanımlanmalıdır (Eiben ve Smith, 2015).

2.6. Hayatta Kalan Seçim Mekanizması

Bir EA'da evrim sürecine uygun olarak bir popülasyondaki bireylerden hangilerinin hayatta kalıp genetik özelliklerini bir sonraki nesle aktaracağı veya hangilerinin yok olacağına seçilmesini sağlayan hayatta kalan seçim mekanizmasıdır. Bu seçim sırasında uygun bireylerin popülasyondan atılmaması ve aynı zamanda popülasyonda çeşitliliğin korunmasının sağlanması gerektiğinden bu mekanizma çok önemlidir. Genellikle popülasyonun belirli bir yüzdesini veya bir kısmını korurken geri kalan bireyleri değiştirme stratejisine dayanır (Haasdijk vd., 2014). Bu mekanizma evrimsel döngünün farklı bir aşamasında kullanılır ve seçilmiş ebeveynlerden oluşturulan yavruların oluşturulmasından sonra gerçekleştirilir. "2.2 Popülasyonun Oluşturulması" bölümünde bahsedildiği üzere EA'larda popülasyon boyutu neredeyse her zaman sabittir. Bu, bir sonraki nesile hangi bireylerin alınacağına dair bir seçim yapılmasını gerektirir. Genellikle kullanılan iki çeşit seçim yöntemi vardır. Bunlar yaşa dayalı seçim yöntemi ve uygunluk temelli seçim yöntemidir. Yaşa Dayalı Seçim'de uygunluk diye bir kavram kullanılmaz. Bu yaklaşım, her bireyin popülasyonda belirli bir nesil boyunca kalmasına izin verildiği ve bu süre sonunda, uygunluk değeri ne kadar iyi olursa olsun popülasyondan çıkarıldığı varsayımına dayanmaktadır. Uygunluk tabanlı seçimde ise çocuklar genellikle popülasyondaki en az uyumlu bireylerin yerine geçer. Tipik olarak stokastik olan ebeveyn seçimiyle karşılaştırıldığında, hayatta kalan seçimi genellikle be-

lirli bir düzeni izler. Hayatta kalan seçimi aynı zamanda değiştirme stratejisi olarak da adlandırılır.

2.7. Sonlandırma Kriteri

Algoritmanın ne zaman duracağını belirleyen kriterlerdir. Örneğin, belirli bir uygunluk değerine ulaşma, belirli bir iterasyon sayısına ulaşma veya belirli bir süre geçme gibi kriterler olabilir.

3. Evrimsel Algoritma Çeşitleri

3.1. Genetik Algoritmalar

Genetik algoritma, biyolojik evrimin hesaplamalı bir modelidir ve evrimsel algoritmalar içinde en yaygın kullanılanlarındandır. Bu yöntem ilk defa Holland tarafından tanıtılmıştır (Holland, 1975) Bir evrimsel süreci bir çözüm arama yöntemi olarak gerçek dünya problemlerine etkili bir şekilde uyarlamak için GA'lar oldukça kullanışlı yöntemlerdir. Gerçek evrimsel sürece göre daha basitleştirilmiş bir yapısı olan GA'lar kompleks problemleri çözebilirler (Forrest, 1996). GA'lar esnek bir şekilde popülasyon genetiği fikirlerine dayanır. İlk olarak, bireylerden oluşan bir popülasyon rastgele oluşturulur. Popülasyonu oluşturan her bir birey bir bit dizisidir ve bu bireyler çözülmek istenen her bir problem için aday bir çözüm olarak düşünülebilir. Bir popülasyon birbirinden farklı bireylerden olduğundan doğal sürece uygun olarak bunlardan bazılarının diğerlerine göre daha uygun olması durumu ortaya çıkar. Yalnız bireyler arasındaki farklılıklar aday çözümlerin seçilme sürecini belirler. Seçim sırasında, daha başarılı bireylerin kopyaları oluşturularak ve daha az başarılı olanlar silinerek yeni bir popülasyon oluşturulur (Reeves, 2010).

GA'nın seçim aşamasında düşük başarıya (uygunluk değerine) sahip bireyler popülasyondan çıkartılırken yüksek uygunluğa sahip bireylerin birbirinin aynı olmayan kopyaları oluşturulur. Çoğaltma süreci boyunca mutasyon, çaprazlama veya diğer değişikliklerin gerçekleşme potansiyeli vardır. Bir önceki popülasyondaki uygunluğu yüksek bireylerin oluşturduğu aday çözümler varyasyon operatörleri kullanılarak daha yüksek uygunluğa sahip yeni aday çözümler oluşturulur. Bu değerlendirme, seçim ve genetik işlem döngüsü birkaç nesil boyunca yinelenirken, popülasyonun genel uygunluğu genellikle iyileşir ve bireyler uygunluk fonksiyonunda özetlenen soruna yönelik gelişmiş çözümleri somutlaştırır (Katoch vd., 2021).

3.2. Evrim Stratejileri ve Evrimsel Programlama

ES ve EP biyolojik evrim ilkelerinden esinlenen arama paradigmalarıdır. ES, 1960'lara kadar uzanan ve genellikle sürekli arama alanlarında karşılaşılan siyah kutu optimizasyon problemlerine uygulanan evrimsel algoritmalar

olarak bilinir. ES diğer birçok EA'da olduğu gibi mutasyon, rekombinasyon ve seçim operatörlerinin uygulanması üzerine kuruludur (Beyer ve Schwefel, 2002). ES algoritmik açıdan bakıldığında genellikle çok değişkenli normal olasılık dağılımından rastgele yeni aday çözümler üreten optimizasyon yöntemleridir. Bu algoritmalar, tekrarlanan stokastik varyasyonlar ve ardından seçim sürecini uygulayarak optimizasyon problemlerini ele alan EA ailesine aittir. Her yeni nesilde ebeveynlerinden yeni yavrular üretilir, uygunlukları değerlendirilir ve daha iyi yavrular bir sonraki nesil için ebeveyn olmak üzere seçilir (Hansen vd., 2015).

3.3. Genetik Programlama

Kromozom yapısını temsil ederken ağaçları kullanan GP hemen hemen aynı dönemlerde ortaya çıkan diğer evrimsel yöntemlere göre farklı alanlara uygulanır. GP yöntemi ile diğer evrimsel algoritmalar arasında önemli bir fark bulunur. GP genellikle makine öğrenmesi problemlerinin çözülmesi için kullanılırken diğer EA'lar ise optimizasyon alanında uygun çözümler bulmak için kullanılır. Yani GP yöntemi daha çok farklı yapay zeka ve makine öğrenmesi problemlerine uyarlanmaya çalışılarak en uygun model ortaya çıkarılır. Burada uygun modeli arama süreci bir optimizasyon probleminin özel bir alanı olarak düşünülebilir. Diğer EA'lar ise bir optimizasyon probleminde en uygun uygunluk değerini verecek parametreleri ve değerleri hesaplamaya çalışmaktadır. Bir GP yönteminde bir model oluşturulurken temelde ayrıştırma ağaçları kullanılır ve bu ağaçlar kullanılarak oluşturulan modeller doğadaki evrim sürecine uygun oluşturulur. Bu modeller bir optimizasyon probleminde uygunluk değerlerini maksimize etmeye çalışır (Eiben ve Smith, 2015).

3.4. Öğrenen Sınıflandırıcı Sistemler

1975 yılında John Holland (Holland(a) 1975) tarafından icat edilmiştir. GA'lar başlangıçta Öğrenen Sınıflandırıcı Sistemler (ÖSS)'in bir alt parçası olmasına rağmen bu sistemler GA'dan daha az bilinmektedir. ÖSS'lerin ortak özelliği, işledikleri kural kümesini otomatik olarak oluşturabilen kural tabanlı sistemlere sahip olmalarıdır (Sigaud ve Wilson, 2007).

ÖSS problemleri çözmek için denetimli öğrenmeyi genetik algoritma ile birleştiren bir makine öğrenimi paradigmasıdır. Bu sistemler koşul-eylem-tahmin olarak adlandırılan kurallar kümesini oluştururlar ve bu kurallar ile bir sınıflandırıcı yapısı elde edilir. Bu sınıflandırıcı ise bir problemin farklı çözümlerini içerir. Sınıflandırıcı koşulu, problem alanının bir bölümünü tanımlar. Sınıflandırıcı eylemi, sınıflandırıcı koşulu tarafından tanımlanan alt probleme ilişkin bir kararı temsil eder. Tahmin, sınıflandırıcının problem çözümü açısından ne kadar değerli olduğunu tahmin eder. Bu sistemlerde genetik algoritma, hedef problemin bir dizi alt probleme uygun bir şekilde ayrıştırılmasını sağlayan sınıflandırıcı koşulları üzerinde çalışır (Lanzi, 2008).

3.5. Diferansiyel Evrim

Diferansiyel Evrim (DE), sürekli verilerin ele alındığı global optimizasyon problemlerini çözmek için kullanılan etkili bir evrimsel algoritmadır. 1995 yılında Price ve Storn tarafından önerilmiş ve o zamandan beri çeşitli problemlerin çözümünde yaygın bir şekilde kullanılmıştır (Storn ve Price, 1995). Diğer EA yöntemlerine göre kodlanması ve uygulanması daha basittir. Bir DE'de bir popülasyondaki aday çözümler parametre vektörleri veya genomlar olarak adlandırılır. DE, standart bir EA tarafından kullanılan benzer hesaplama adımlarıyla çalışır. Öbür yandan bir DE algoritmasının diğer EA algoritmalarından farklarını söylemek gerekirse bir DE algoritması uygunluk fonksiyonunu oluştururken diğer yöntemlerden farklı olarak parametre vektörlerinin farkını kullanır ve yeni aday çözümler üretirken açık olasılıksal dağılımları kullanmaz. Oysa geleneksel EA'lar yeni aday çözümler oluştururken (yavrular) genellikle olasılık dağılımları kullanılır. Çaprazlama noktaları veya mutasyon oranları olasılıksal olarak belirlenir ve bu da stokastik bir arama sürecine yol açar (Das ve Suganthan, 2010). DE ise yavru oluşturmak için ayrı olasılık dağılımları gerektirmez. Bunun yerine, arama uzayını keşfetmek için rastgele seçilen bireyler arasındaki fark vektörlerini kullanır ve bu da algoritmanın önceden tanımlanmış olasılıklara daha az bağımlı hale gelmesini sağlar. DE'nin bir diğer farkı ise küresel popülasyon pertürbasyon yaklaşımını kullanmasıdır. Tüm bu özellikler DE'yi özellikle yüksek boyutlu ve karmaşık arama uzaylarında sağlam ve verimli bir optimizasyon algoritması haline getirmektedir (Opara ve Arabas, 2019).

3.6. Parçacık Sürü Optimizasyonu

Parçacık Sürü Optimizasyonu (PSO) algoritması sürekli ve doğrusal olmayan fonksiyonların optimizasyonu için Eberhart ve Kennedy tarafından 1995 yılında önerilmiştir (Song ve Gu, 2004). Bu yöntem kuş, balık ve hayvan sürüsündeki bireylerin etkileşimini simüle etmek için önerilen basit denklemlerden oluşan bir sezgisel yöntemdir. Bu yöntem ile sürü elemanlarının çevrelerine adapte olabilmeye, yiyecek arama ve avcılardan kaçma davranışları taklit edilebilir. Her biri çözüm uzayında bir çözümü temsil eden ve belli hızlara sahip sürü elemanları parçacık olarak adlandırılır PSO popülasyon tabanlı bir yöntemdir ve her bir bireyin çok boyutlu arama uzayında arama yapmasını sağlar. Algoritma, parçacıkları çözüm uzayında hareket ettirerek optimum çözümü bulmaya çalışır. Bu parçacıklar bu hareketleri sırasında kendi geçmiş en iyi pozisyon bilgilerini ve bir sürüdeki en bireyin bilgilerini kullanır. Parçacık ve komşuları tarafından çözüme yakın en iyi konumlar, diğer PSO parametreleri ile birlikte parçacık yörüngesini belirler. Bir PSO'da görünüşe göre evrim yok gibi gözükse de, algoritmik olarak genel bir evrimsel algoritma yapısına uyum sağlar. Bu özellikleriyle diğer evrimsel algoritmalarından biraz farklıdır (Eiben ve Smith, 2015). PSO yöntemi yerel ve küresel arama yöntemlerini birleştirerek küresel arama-keşfetme dengesini sağlamaya çalışır. Bu açıdan PSO, modern GA'lara benzemektedir denilebilir (Ozcan ve Mohan, 1998).

PSO, evrimsel hesaplama tekniklerine ve yöntemlerine bir dereceye kadar benzerlik gösteren bazı özelliklere sahip olsa da algoritmanın tanımlanması ve uygulanması daha basittir (Freitas vd., 2020).

3.7. Tahmini Dağılım Algoritmaları

Tahmini Dağılım Algoritmaları (TDA) algoritmaları ilk olarak Mühlhenn and PaaB (1996) tarafından evrimsel hesaplama alanında tanıtılmışlardır. TDA algoritmalarını diğer yöntemlerden ayıran en önemli özelliklerden biri mutasyon ve çaprazlama operatörlerinin bulunmamasıdır. Bunun yerine yeni bir popülasyon oluşturulmak istenirse bir olasılıksal dağılımdan faydalanılır. EA'larda bir popülasyondaki bireylere ait farklı özellikler arasındaki bağlar bellekte tutulurken TDA'da ise bunlar her iterasyonda seçilen bireylerle ilişkilendirilen ortak olasılık dağılımı aracılığıyla ortaya konur (Larranaga, 2002). Bu yöntemde bir arama uzayında çözümlerin olduğu bir bölgenin veya bölgelerin bir modelinin oluşturulabileceği düşünülür. Bu model ile birlikte optimum noktalar bulunabilir. Bir TDA seçilen çözümlerin çeşitli özelliklerinin bir temsilinden ortaya çıkan bir olasılıksal grafik model oluşturularak gerçekleştirilir. Bu tür bir model, problem değişkenlerinin alt kümeleri arasındaki farklı etkileşim desenlerini yakalayabilir ve bu bilgiyi yeni çözümler örnekleme için kullanabilir (Armañanzas vd., 2008). Bu yöntem, genetik algoritmaların geleneksel varyasyon yöntemlerine alternatif bir yaklaşım sunar.

4. Sonuç

Evrimsel hesaplama yöntemleri, biyolojik evrimin doğal süreçlerdeki başarısından ilham almışlardır. Bunlar hesaplamalı zeka veya yumuşak hesaplama alanları altında sınıflandırılan etkili sezgisel yöntemlerdir. Bu yöntemler, bilgisayar tabanlı problem çözme modellerinin tasarımında ve uygulanmasında temel unsur olarak evrimsel süreçlerin hesaplamalı modellerini kullanır. Geleneksel algoritmalar için modellenmesi oldukça zor ve çok fazla değişkene sahip karmaşık optimizasyon problemlerinde ve sürekli optimizasyonda etkili çözümler üretirler. Evrimsel hesaplama yöntemleri, geniş bir problem yelpazesinde son derece optimize edilmiş çözümler üretebilir, bu da onları bilgisayar biliminde popüler hale getirmiştir. Literatürde farklı veri türlerini kullanan ve belli problemlere uygulanan birçok çeşidi bulunmaktadır.

Bu bölümde doğadaki evrimsel süreçten esinlenen evrimsel hesaplama alanına ve bu alan kapsamında önerilmiş evrimsel hesaplama algoritmalarına genel bir bakış sunulmuştur. Evrimsel hesaplama alanı çok geniş ve detaylı bir alan olduğundan burada sadece evrimsel hesaplamanın ne olduğundan, kısa tarihçesinden, bu algoritmaların genel bileşenlerinden ve literatürde kullanılan evrimsel algoritma yöntemlerinden bahsedilmiştir. Böylece bu alana yani başlayan araştırmacılar için genel bir çerçeve çizilmiştir.

KAYNAKLAR

- Abdullah, J. M., & Ahmed, T. (2019). Fitness dependent optimizer: inspired by the bee swarming reproductive process. *IEEE Access*, 7, 43473-43486.
- Altenberg, L. Evolutionary Computation. In *Encyclopedia of Evolutionary Biology*; Klíman, R.M., Ed.; Elsevier: Amsterdam, The Netherlands, 2016; pp. 40–47.
- Armañanzas, R., Inza, I., Santana, R., Saeys, Y., Flores, J. L., Lozano, J. A., ... & Larrañaga, P. (2008). A review of estimation of distribution algorithms in bioinformatics. *BioData mining*, 1, 1-12.
- Bäck, T., Fogel, D. B., & Michalewicz, Z. (1997). *Handbook of evolutionary computation*. Release, 97(1), B1.
- Back, T., Hammel, U., & Schwefel, H. P. (1997). Evolutionary computation: Comments on the history and current state. *IEEE transactions on Evolutionary Computation*, 1(1), 3-17.
- Beyer, H. G., & Schwefel, H. P. (2002). Evolution strategies—a comprehensive introduction. *Natural computing*, 1, 3-52.
- Bottaci, L. (2001, May). A genetic algorithm fitness function for mutation testing. In *Proceedings of the SEMINALL-workshop at the 23rd international conference on software engineering*, Toronto, Canada.
- Bremermann, H. J. (1962) “Optimization through evolution and recombination,” in *Self-Organizing Systems*, M. C. Yovits et al., Eds. Washington, DC: Spartan, 1962.
- Das, S., & Suganthan, P. N. (2010). Differential evolution: A survey of the state-of-the-art. *IEEE transactions on evolutionary computation*, 15(1), 4-31.
- Eberhart, R., Kennedy, J. (1995). A new optimizer using particle swarm theory. In *1995 Proceedings of the sixth international symposium on micro machine and human science, MHS'95* (pp. 39–43). IEEE.
- Eiben, A. E., & Smith, J. E. (2015). *Introduction to evolutionary computing*. Springer-Verlag Berlin Heidelberg.
- Engelbrecht, A. P. (2014, December). Fitness function evaluations: A fair stopping condition?. In *2014 IEEE symposium on swarm intelligence* (pp. 1-8). IEEE.
- Fogel, D. B. (1995, December). Phenotypes, genotypes, and operators in evolutionary computation. In *Proc. 1995 IEEE Int. Conf. Evolutionary Computation (ICEC'95)* (pp. 193-198).
- Freitas, D., Lopes, L. G., & Morgado-Dias, F. (2020). Particle swarm optimisation: a historical review up to the current developments. *Entropy*, 22(3), 362.
- Forrest, S. (1996). Genetic algorithms. *ACM computing surveys (CSUR)*, 28(1), 77-80.
- Goings, S., & Ofria, C. (2009, March). Ecological approaches to diversity maintenance in evolutionary algorithms. In *2009 IEEE Symposium on Artificial Life* (pp. 124-130). IEEE.

- Haasdijk, E., Bredeche, N., & Eiben, A. E. (2014). Combining environment-driven adaptation and task-driven optimisation in evolutionary robotics. *PloS one*, 9(6), e98466.
- Hansen, N., Arnold, D. V., & Auger, A. (2015). Evolution strategies. *Springer handbook of computational intelligence*, 871-898.
- Hansen, T. F., & Price, D. K. (1995). Good genes and old age: do old mates provide superior genes?. *Journal of Evolutionary Biology*, 8(6), 759-778.
- Holland JH (1975a). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, artificial intelligence*. University of Michigan Press, Ann Arbor
- Holland, J.H. (1975b). *Adaptation in Natural and Artificial Systems*. The University of Michigan Press, Ann Arbor, MI.
- Holland, J. H. (1962c). Outline for a logical theory of adaptive systems. *Journal of the ACM (JACM)*, 9(3), 297-314.
- Kang, M., & Wang, M. (2022). New genetic operators for developing S-boxes with low boomerang uniformity. *IEEE Access*, 10, 10898-10906.
- Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm: past, present, and future. *Multimedia tools and applications*, 80, 8091-8126..
- Kora, P., & Yadlapalli, P. (2017). Crossover operators in genetic algorithms: A review. *International Journal of Computer Applications*, 162(10).
- Lanzi, P.L. Learning classifier systems: then and now. *Evol. Intel.* 1, 63–82 (2008).
- Larranaga, P. (2002). A Review on Estimation of Distribution Algorithms: 3. Estimation of distribution algorithms: a new tool for evolutionary computation, 57-100.
- Mühlenbein, H. and PaaB, G. (1996). From recombination of genes to the estimation of distributions 1. Binary parameters. In *Lecture Notes in Computer 1411: Parallel Problem Solving from Nature - PPSN IV*, pages 178-187.
- Opara, K. R., & Arabas, J. (2019). Differential Evolution: A survey of theoretical analyses. *Swarm and evolutionary computation*, 44, 546-558.
- Ozcan, E., & Mohan, C. K. (1998). Analysis of a simple particle swarm optimization system. *Intelligent engineering systems through artificial neural networks*, 8, 253-258.
- Reeves, C.R. (2010). Genetic Algorithms. In: Gendreau, M., Potvin, JY. (eds) *Handbook of Metaheuristics*. International Series in Operations Research & Management Science, vol 146. Springer, Boston, MA.
- Rechenberg, I. (1965) "Cybernetic solution path of an experimental problem," Royal Aircraft Establishment, Library translation No. 1122, Farnborough, Hants., U.K., Aug.
- Sigaud, O., Wilson, S.W. (2007). Learning classifier systems: a survey. *Soft Comput* 11, 1065–1078

- Spears, W. M., De Jong, K. A., Bäck, T., Fogel, D. B., & De Garis, H. (1993, April). An overview of evolutionary computation. In *European conference on machine learning* (pp. 442-459). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Sterrett, S. G. (2017). Turing on the integration of human and machine intelligence. *Philosophical Explorations of the Legacy of Alan Turing: Turing 100*, 323-338.
- Storn, R., and Price, K. V., *Differential evolution: A simple and efficient adaptive scheme for global optimization over continuous spaces*, 1995.
- Srinivas, M., & Patnaik, L. M. (1994). Genetic algorithms: A survey. *computer*, 27(6), 17-26.
- Slowik, A., & Kwasnicka, H. (2020). Evolutionary algorithms and their applications to engineering problems. *Neural Computing and Applications*, 32, 12363-12379.
- Schwefel, H.-P. (1968) "Projekt MHD-Staustahlrohr: Experimentelle Optimierung einer Zweiphasenduse, Teil I," *Technischer Bericht 11.034/68*, " 35, AEG Forschungsinstitut, Berlin, Germany, Oct. 1968
- Otto, S. P., & Payseur, B. A. (2019). Crossover interference: shedding light on the evolution of recombination. *Annual review of genetics*, 53, 19-44.
- Vikhar, P. A. (2016, December). Evolutionary algorithms: A critical review and its future prospects. In *2016 International conference on global trends in signal processing, information computing and communication (ICGTSPICCC)* (pp. 261-265). IEEE.

Bölüm 4

LİTYUM-İYON PİLLERDE DERİN SİNİR AĞLARIYLA BATARYA DURUMU TAHMİNİ VE YÖNETİMİ

Mehmet KURUCAN¹

Mete ÖZBALTAN²

1 Öğr. Gör. Dr.; Ardahan Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü. mehmetkurucan@ardahan.edu.tr ORCID No: 0000-0003-4359-3726

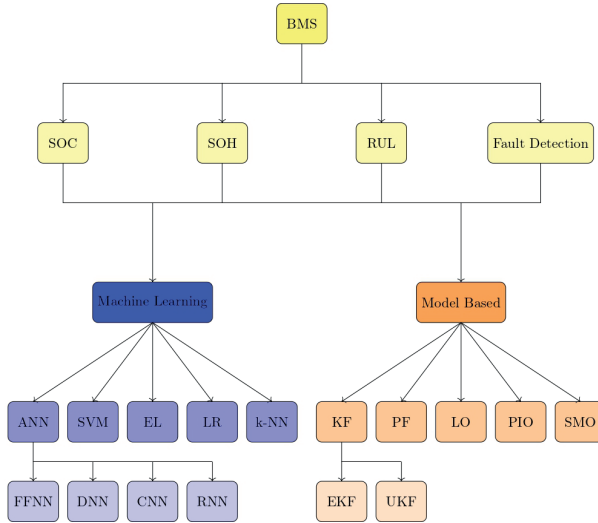
2 Dr. Öğr. Üyesi; Erzurum Teknik Üniversitesi Mühendislik ve Mimarlık Fakültesi Bilgisayar Mühendisliği Bölümü. mete.ozbaltan@erzurum.edu.tr ORCID No: 0000-0002-3215-6363

GİRİŞ

Bu çalışma, küresel enerji talebinin artması ve geleneksel petrol tabanlı enerji kaynaklarının sınırlı ve çevreye zarar veren yan etkilerinin artması nedeniyle, sürdürülebilir ve yenilenebilir enerji kaynaklarının önemini vurgulamaktadır. Bu doğrultuda, elektrikli araçların ve lityum iyon pillerin, çevre dostu ve sera gazı emisyonunu azaltan alternatifler olarak önem kazandığı belirtilmektedir.

Çalışma, pil teknolojisinin elektrikli araçlar ve enerji depolama sistemleri için temel unsurlardan biri olduğunu vurgulamakta ve lityum iyon pillerin yüksek enerji yoğunluğu, verimliliği ve uzun ömürlülükleri nedeniyle tercih edildiğini ifade etmektedir. Bu bağlamda BMS, pil sağlık durumu, şarj durumu, kullanım ömrü ve hataların tespiti gibi önemli parametreleri doğru bir şekilde tahmin etmek için kritik bir rol oynamaktadır.

Farklı yaklaşımların incelendiği çalışmalarda, BMS için öne çıkan iki ana yaklaşım model temelli ve makine öğrenimi tabanlı yöntemler olarak belirtilmektedir. Model temelli yöntemler, pilin elektrokimyasal dinamiklerini içeren detaylı pil modellerine dayanmaktadır. Diğer taraftan, makine öğrenimi tabanlı yaklaşımlar çeşitli modellerin veri kümeleri üzerinde eğitilerek tahminlerde bulunduğu yöntemleri ifade eder. Bu bağlamda, makine öğrenimi tabanlı yaklaşımlar büyük veri kümelerinden öğrenme yetenekleri sayesinde daha verimli sonuçlar sunabilirken, model temelli yöntemler daha fazla özelleştirme ve geliştirme süreci gerektiren bir yaklaşım olarak öne çıkmaktadır.



Şekil 1: ANN: Artificial Neural Network, FFNN: Feed Forward Neural Network, DNN: Deep Neural Network, CNN: Convolutional Neural Network, RNN: Recurrent Neural Network, SVM: Support Vector Machine, EL: Ensemble learning, LR: Linear Regression, k-NN: k-Nearest Neighbors ; KF: Kalman Filter, EKF: Extended Kalman Filter, UKF: Uncented Kalman Filter, PF: Partical Filter, LO: Luenberger Observer, PIO: Proportional Integral Observer, SMO: Sliding Mode Observer

BMS üzerine yapılan her iki yaklaşımın avantaj ve dezavantajları Tablo 1’de gösterilmiştir. Ancak son dönemlerde, ML tabanlı çalışmaların Model tabanlı çalışmalardan daha fazla olduğu ve özellikle hesaplama süresinin daha kısa olması gibi avantajları nedeniyle ML tabanlı yaklaşımların daha fazla tercih edildiği gözlemlenmektedir. Bu tercih, bilgisayar ortamında (sanal ortamda) gerçekleştirilen deneylerin artmasından kaynaklanmaktadır. Bu durum da ML tabanlı çalışmaların popülaritesini artırmıştır (Sui vd., 2021). Bu bağlamda, BMS ile ilgili yapılan ML tabanlı çalışmaların şematik diyagramı Şekil 1’de gösterildiği gibi daha fazla model içermektedir. Bu yöntemlerin büyük bir kısmı, yüksek doğruluklu BMS tahminlerini LIB’lerin içeren senaryolarda elde etmek amacıyla kullanılmaktadır.

Yöntem	Avantaj	Dezavantaj
Model-tabanlı	<ul style="list-style-type: none"> Güvenilir ve doğru Evrensel geçerlilik 	<ul style="list-style-type: none"> Kapsamlı alan bilgisi Kapsamlı alan bilgisi gerektirdiğinden, bu zaman alıcı ve ulaşılması zor olabilecek bir durumdur.
Data-driven	<ul style="list-style-type: none"> Kapsamlı alan bilgisi gerektirmez Kapsamlı alan bilgisi gerektirmediği için büyük bir veri setinden hızlı bir şekilde öğrenmek mümkündür, bu da geliştirme süresi açısından daha verimli olabilir. 	<ul style="list-style-type: none"> Tahmin edilemeyen karaku kutu modeli Büyük miktarda veri; bu nedenle büyük veri kümeleri aracılığıyla yüksek kalitede veri elde etmek zaman alıcı bir iştir.

Tablo 1: Model ve Makine Öğrenmesi Tabanlı Yöntemlerin Avantaj ve Dezavantajları

Makine Öğrenimi tabanlı bir model olan Yapay Sinir Ağları (ANN), özellikle lityum-iyon batarya tabanlı karmaşık sistemlerin davranışlarını ve etkileşimlerini modelleme yeteneği ile Batarya Yönetim Sistemleri (BMS) gibi kritik alanlarda önemli avantajlar sunmaktadır. Bu avantajlar, bataryaların performansını tahmin etme, şarj durumunu (SOC), sağlık durumunu (SOH) ve kullanım ömrünü (RUL) tahmin etme gibi temel BMS hedeflerini doğru bir şekilde gerçekleştirmeyi mümkün kılar. Bilindiği üzere, iyi bir BMS, bu tür tahminlerin doğru bir şekilde yapılmasıyla ortaya çıkar. Bu bağlamda, geniş veri setlerini işleyerek, BMS’deki önemli parametrelerin tahmininde ANN’in kullanılması son dönemlerde yaygınlaşmıştır (Sui vd., 2021). Ayrıca, ANN tabanlı BMS çözümleri, farklı batarya tipleri ve uygulama alanları için özelleştirilebilir ve uyarlanabilir esnek çözümler sunma yeteneği ile dikkat çeker. Bu nedenle, ANN’ler enerji depolama sistemlerinin etkin yönetimi için güvenilir ve etkili bir araç olarak kabul edilmektedir.

Derin Sinir Ağları (DNN) ise Yapay Sinir Ağı (ANN) alanında önemli bir gelişmedir ve çeşitli avantajlar sunmaktadır. Karmaşık ve yüksek düzeyli

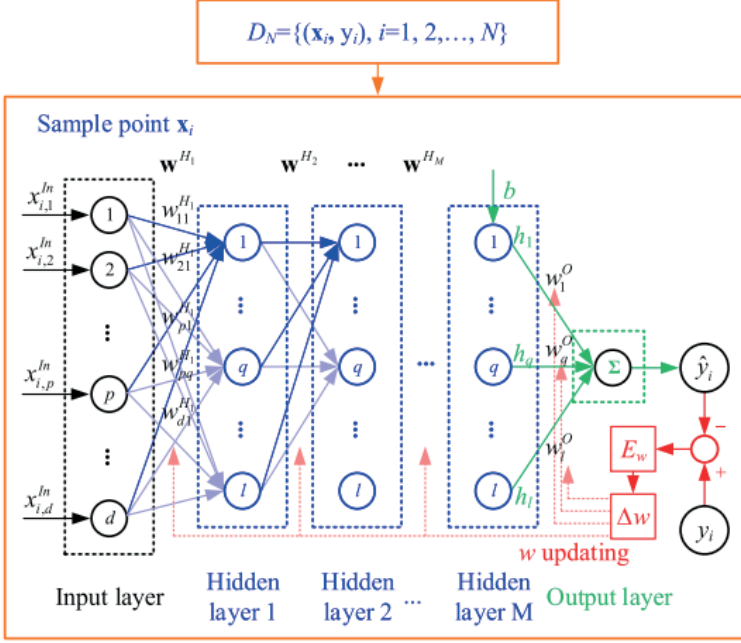
özellikleri öğrenme yeteneği, DNN'leri büyük ve karmaşık veri setleri üzerinde etkili desen tanıma ve analiz yapma yeteneği ile öne çıkarır. Bu özellikler sayesinde, Batarya Yönetim Sistemleri'nde (BMS) hassas, doğru ve güvenilir tahminler yapabilme kabiliyeti artar. Hem ANN'lerin enerji depolama sistemlerinin yönetiminde geniş bir kullanım alanına sahip olması hem de DNN'lerin daha derin ve karmaşık analiz yetenekleri, BMS'lerin performansını ve güvenliğini artırmada kritik bir rol oynar.

Sonuç olarak, bu çalışma, lityum iyon piller ve elektrikli araçlar gibi enerji depolama alanındaki önemin arttığı bir dönemde, makine öğrenimi tabanlı tahmin yöntemlerinin, özellikle BMS alanında, doğru ve etkin çalışmayı sağlama potansiyeline işaret etmektedir. Bu tür yöntemlerin, gelecekte pil teknolojileri ve enerji depolama çözümleri üzerinde belirleyici bir etkiye sahip olması beklenmektedir. Ancak, daha fazla veri kalitesi ve doğruluğu, uygun parametre seçimi ve pil kimyası gibi zorlukların da ele alınması gerektiği vurgulanmaktadır.

Bu çalışmada, diğer bölümler aşağıdaki gibi düzenlenmiştir: Bölüm 2, DNN yapısını ve temel bileşenlerinin neler olduğunu basit ve anlaşılır bir özetini sunar. Bölüm 3, DNN modelini kullanarak yapılan güncel SOH tahminlerini ele alırken, Bölüm 4 DNN tabanlı SOC tahminlerine odaklanır. Pilin RUL tahminleri ise Bölüm 5'te incelenir. Bölüm 6, tüm çalışmaları ayrıntılı bir şekilde analiz eder ve sınıflandırma sonuçlarını detaylı bir rehber niteliğinde değerlendirir. Son olarak, Bölüm 7, bu çalışmanın sonuçlarını sunmaktadır.

DERİN SİNİR AĞLARI

Derin sinir ağları (DNN), ANN'nin bir alt kümesidir ve genellikle çok katmanlı yapıları ifade eder. ANN, insan beyninin çalışma biçiminden esinlenerek oluşturulmuş matematiksel modellerdir. Bir sinir ağı, sinir hücrelerini (nöronlar) ve bu nöronlar arasındaki bağlantıları temsil eden ağırlıkları içerir. Derin sinir ağları, bu yapının daha karmaşık hale getirilmiş hali olarak düşünülebilir (Ivakhnenko, 1971).



Şekil 2: Derin Sinir Ağı Modeli

Bu tür ağlar, veri analizi, desen tanıma, sınıflandırma, tahmin ve diğer karmaşık görevler için kullanılır. Her bir katmanda, girdi verileri işlenir ve ardışık katmanlardan geçerken daha yüksek seviyeli özellikler çıkarılır. Yani her katman, önceki katmandan gelen bilgileri alır ve bunları işledikten sonra sonraki katmana iletir. DNN'ler, temelde çoklu gizli katmanlara sahip Düzlemsel İleri Beslemeli Sinir Ağlarıdır (FFNN). Bilgi, gizli katmanlardan geçerken bir veya daha fazla aktivasyon fonksiyonu da eklenerek, verilerden karmaşık özelliklerin çıkarılması için güçlü bir araç oluşturur.

Derin sinir ağlarının çalışma prensibi, temelde girdi verilerini işleyerek çıktı üretme sürecine dayanır. Bu süreç, katmanlar arasındaki ağırlıkların ve aktivasyon fonksiyonlarının işbirliğiyle Şekil 2'de gösterildiği gibi gerçekleşir. İşte derin sinir ağlarının temel çalışma prensibi:

Girdi Katmanı (Input Layer): İşlem başlangıcında, veriler girdi katmanına girer. Girdi katmanı, ham veriyi alır ve bir sonraki katmana iletmek üzere işler.

Gizli Katmanlar (Hidden Layers): Derin sinir ağları genellikle bir veya daha fazla gizli katman içerir. Bu katmanlar, özelliklerin hiyerarşik olarak çıkarılmasını sağlar. Her bir gizli katman, önceki katmanın çıktılarını alır, bu çıktıları ağırlıklar (w) ve aktivasyon fonksiyonları (f) kullanarak dönüştürür

ve ardından bir sonraki katmana ileilmek üzere çıktıları oluşturur.

Çıkış Katmanı (Output Layer): En son gizli katmandan elde edilen çıktılar, çıkış katmanına ileildiğinde, son tahmin veya sonuç üretilir. Çıkış katmanı, genellikle problemin türüne göre farklı aktivasyon fonksiyonları kullanılır.

Derin sinir ağlarının matematiksel notasyonu, aşağıdaki şekilde gösterilebilir:

$$H = f(W * X + b)$$

Bu denklemde, H, nöron ağının çıkışını temsil ederken, W, ağırlık matrisini temsil eder. Giriş matrisi ise X ile temsil edilir. b, bias matrisidir ve son olarak f, nöron fonksiyonunu temsil eder.

Nöron fonksiyonu, nöronun girişlerini işleyip çıkışını üreten bir fonksiyondur. Nöron fonksiyonu, genellikle sigmoid fonksiyonu olarak kullanılır. Sigmoid fonksiyonu, aşağıdaki şekilde gösterilebilir:

$$\sigma(x) = 1/(1 + \exp(-x))$$

Sigmoid fonksiyonu, bir giriş değerinin 0 ile 1 arasında bir değer üretmesini sağlar. Bu, nöronların çıkışlarının sınıflandırma görevleri için uygun olmasını sağlar.

Derin sinir ağları, çok büyük miktarda veriye maruz bırakılarak eğitilir. Bu eğitim sayesinde, nöronlar, giriş verileri ile çıkış verileri arasındaki ilişkiyi öğrenebilirler. Eğitim tamamlandıktan sonra, nöronlar, yeni giriş verileri verildiğinde, bu verileri işleyip çıkış verileri üretebilirler.

Batarya yönetim sistemlerinde DNN, bataryaların performansını izlemek, öngörmek ve yönetmek için kullanılabilir. Bu sistemler, bataryaların ömrünü uzatmak, enerji verimliliğini artırmak ve güvenliği sağlamak gibi amaçlarla kullanılır. DNN, bataryaların gerçek zamanlı durumunu izleyerek ve karmaşık özellikleri analiz ederek, bataryaların ne zaman bakım gerektirebileceğini veya ne zaman bir sorun yaşanabileceğini tahmin edebilir.

BMS, gerçek zamanlı verileri işleyen ve DNN'nin tahmin yeteneklerini kullanarak batarya performansını optimize eden bir kontrol mekanizması içerebilir. Bu tür bir sistem, batarya ömrünü uzatmak ve enerji depolama teknolojilerinin verimliliğini artırmak için büyük önem taşır.

Sonuç olarak, DNN yapay sinir ağlarının bir alt kategorisidir ve özellikle derin öğrenme uygulamalarında kullanılır. BMS'de ise DNN, bataryaların performansını izlemek ve optimize etmek için kullanılabilir.

PİLİN SAĞLIK DURUMU

Lityum-iyon bataryaların SOH (Kalan Sağlık Durumu) tahmini için diğer makine öğrenmesi tabanlı hesaplamalarla DNN (Derin Sinir Ağları) arasındaki ilişki, (Khumprom ve Yodo, 2019) çalışmasında NASA Ames Prognostics Center of Excellence (PCoE) veritabanını kullanarak incelenmiştir. (Park vd., 2020) çalışmasında önerilen yöntem, SOC ve 2C temel alınarak kapasite tahmini için kullanılmakta ve aynı zamanda DNN içinde çekirdek fonksiyonunu düzelten bir yöntemdir. Bu teknik, farklı başlangıç SOC ve C-hızı akımı ile bataryanın SOH'unu doğru bir şekilde değerlendirebilmektedir. (Kim vd., 2018) çalışmasında ise SOH tahmini için DNN algoritması önerilmektedir. Bu çalışmada SOH, %100'den %80'e kadar olan beş aralığa bölünmektedir.

(Wu vd., 2016) çalışmasında önerilen yapı, seçilen bir polinom fonksiyonu ile DNN algoritmasını kullanarak hesaplamayı basitleştirir. Ayrıca, (Song vd., 2020) çalışmasında, çeşitli sürüş modlarına sahip 700 farklı araçtan elde edilen bir yıllık veri seti kullanılarak DNN tarafından akıllı SOH tahmini yapılmıştır.

(Wei vd., 2022) çalışmasında, DNN kullanarak echelon kullanımlı piller için yeni bir SOH tahmin stratejisi önerilmiştir. Ayrıca, DNN tahminlerinin doğruluğunu daha da artırmak için Markov zinciri hata düzeltmesi kullanılmıştır. (Lee vd., 2019) çalışmasında ise DNN durum sınıflandırıcısını kullanarak batarya hücresinin arızasını teşhis ederek SOH tahmini gerçekleştirilmiştir.

Potansiyel olarak bozulmuş bir batarya kullanımının getirebileceği riskleri önlemek amacıyla (Lee vd., 2021), DNN kullanarak SOH teşhisi için bir yöntem önermektedir. Bu yöntem, SOH teşhis modeli için dört farklı DNN modeli içerir ve bu modellerin çıktuları, deneysel süreçlerde SOC tahmini ile karşılaştırılır.

(Shi vd., 2021) çalışmasında, bataryaların SOH tahmininde, devre modeli tabanlı bir yöntem olan genişletilmiş Kalman filtresi ve veri tabanlı bir model olan tamamen bağlı DNN'nin birleştirildiği hibrit bir yaklaşım önerilmiştir. (Hsu vd., 2022) çalışmasında ise, bir bataryanın kalan ömrünü tahmin etmek için DNN tabanlı bir mimari geliştirilmiştir ve tek bir döngü ile %6.46 hata oranı elde edilmiştir.

(Xia ve Abu Qahouq, 2021) çalışmasında, DNN kullanılarak SOH göstergeleri ile SOH değerleri arasındaki karmaşık ilişkiler çıkarılmış ve SOH için çoklu DNN tabanlı tahmin modelleri geliştirilmiştir. Diğer yandan, (Venugopal vd., 2021) çalışmasında, sabit simülasyonlar ve donanım platformları kullanılarak batarya yaşlanması değerlendirilmiş ve gerçek zamanlı deney sonuçları, DNN tabanlı ML kullanılarak SOH tahmini ve çeşitli batarya istatistikleri oluşturulmuştur.

Bir bataryanın performansını doğru bir şekilde tahmin etmek için hassas metrikler önemlidir. (Lin ve Chen, 2022) çalışmasında, daha önceki çalışmalarda SOH hesaplamasında kullanılan deşarj voltajı yerine deşarj eğrisinin birinci dereceden türevidi olan dQ/dV parametresi kullanılmış ve DNN, optimizasyon algoritması olarak kullanılmıştır.

Bu çalışmalardan anlaşılacağı gibi, DNN tabanlı yaklaşımlar, lityum-iyon bataryaların SOH tahmininde çeşitli yöntemler ve tekniklerin kullanıldığı verimli ve başarılı bir şekilde uygulandığı gözlemlenmektedir. Bu tür çalışmalar, batarya sağlığının ve performansının daha iyi anlaşılması ve yönetilmesi için önemli bir adım olup, gelecekteki enerji depolama ve elektrikli araç teknolojilerinde sürdürülebilir ve güvenilir bir enerji yönetimi için katkı sağlamaktadır.

PİLİN ŞARJ DURUMU

Lityum-iyon batarya yönetimi alanında, (How vd., 2020) çalışması, SOC (Şarj Durumu) tahminini iyileştirmek için çeşitli DNN modelleri ve öğrenme algoritmaları önermiştir. Bu modeller farklı sayıda gizli katman içermektedir ve sonuçlar, daha fazla katman eklemenin hata oranını azalttığını ve elektrikli araç uygulamaları için daha iyi SOC tahminleri sağladığını göstermektedir. Ayrıca, SOC tahmini için başka bir DNN tabanlı yaklaşım, (Chemali vd., 2018) tarafından geliştirilmiştir. Bu yaklaşımda, lityum-iyon bataryadan eğitim verileri, çeşitli ortam sıcaklıklarında sürüş döngüsü yükleri uygulanarak elde edilir. Bu yöntem, farklı sıcaklık koşullarında daha doğru tahminler sunar.

Lityum-iyon bataryaların aşırı şarj ve aşırı deşarjdan korunması için, (Zhao vd., 2019) çalışmasında DNN tabanlı bir SOC gözlemci tasarımı sunulmuştur. Bu yaklaşım, SOC tahmini için orijinal modele göre daha hızlı yakınsama hızları ve daha yüksek hassasiyet sağlar. Ayrıca, sadece 10 dakikalık şarj voltajı ve akım verilerini giriş olarak kullanan başka bir DNN tabanlı SOC tahmin yöntemi de (Tian vd., 2021) tarafından incelenmiştir. Bu yöntem, daha az hata oranıyla hızlı ve doğru SOC tahminleri sunar ve SOC tahmini kalibrasyonunda amper-saat sayım yöntemi için iyi bir adaydır.

(Hu vd., 2022) çalışması, DNN'i $LiFePO_4$ bataryaların şarj süreci sırasında SOC tahmini için uygulamıştır. Eğitim verileri, beş son teknoloji şarj protokolünden elde edilmiş ve sonuçlar, %2.5 hata oranı ve 0.8 RMS hata ile başarılı bir SOC tahmini göstermiştir.

Lityum-iyon batarya yönetimi alanındaki başka bir çalışma, (Mu ve Wang, 2021) tarafından yapılmıştır ve bu çalışmada DNN modelleri, lineer regresyon ve backpropagation sinir ağı modelleri ile SOC tahmininde bir araya getirilmiştir. Eğitim verileri, Gelişmiş Enerji Depolama ve Uygulamalar Grubu'ndan elde edilmiş ve sonuçlar, şarj ve deşarj dönemleri boyunca

sıradan BPNN modeline göre daha düşük kök ortalama kare hatası, ortalama mutlak oransal hata ve SOC tahmin hatası göstermiştir.

Ayrıca, (Ma vd., 2021) çalışması, LSTM DNN kullanarak SOC ve enerji durumu (SOE) için tahmin algoritmasını aynı anda geliştirmiştir. Bu yaklaşım, destek vektör regresyon, rastgele orman ve basit tekrarlayan sinir ağı ile karşılaştırıldığında daha yüksek doğruluk ve sağlamlık elde etmiştir. (Ee vd., 2021) tarafından yapılan çalışmada ise SOC tahmini için DNN kullanılarak elektriksel olmayan parametreler de dikkate alınmış ve bu sayede SOC tahmin performansını etkileyen FBG sinyal kalitesinin arttığı gösterilmiştir.

Bunun yanı sıra, (Savargaonkar ve Chehade, 2020, Savargaonkar vd., 2020) çalışmalarında, DNN kullanarak geçmiş döngü bilgilerini kullanan adaptif bir model önerilmiştir ve bu sayede doğru SOC tahmini sağlanmıştır. (Tian vd., 2021) tarafından geliştirilen bir DNN modeli ise şarj eğrilerini tamamlamak için eğrinin küçük bölümlerini giriş olarak kullanır ve bu sayede farklı koşullar altında çalışan piller için eğri tahmini geliştirilmiştir. Son olarak, (Messing vd., 2020) çalışmasında DNN, Elektrokimyasal Empedans Spektroskopisi ile birleştirilerek batarya SOC tahmini için kullanılmış ve her iki ağı da SOC için kök ortalama kare hatası %5'in altında olmuştur.

Bu tür çalışmalar, DNN tabanlı SOC tahmininin lityum-iyon bataryaların yönetimindeki etkinliğini ve doğruluğunu artırmak için çeşitli yöntemlerin başarıyla uygulandığını göstermektedir. SOC tahmini, enerji depolama ve elektrikli araç gibi uygulamalarda önemli bir rol oynamaktadır ve bu tür araştırmalar, daha sürdürülebilir ve verimli enerji sistemlerinin geliştirilmesine katkı sağlamaktadır. Gelecekteki çalışmalar, DNN tabanlı SOC tahmininde daha gelişmiş yöntemlerin ve daha kapsamlı veri setlerinin kullanılmasını ve bu alanda yapılan araştırmaların uygulama düzeyindeki etkisini artırmayı amaçlayabilir.

PİLİN KALAN KULLANIM ÖMRÜ

DNN algoritmaları, son yıllarda RUL (Kalan Ömür Tahmini) ve Kalan Kapasite Tahmini gibi önemli alanlarda büyük ilgi çekmiş ve umut verici sonuçlar elde edilmiştir. RUL tahmini, özellikle endüstriyel makineler, elektrikli araçlar ve bataryalar gibi uzun ömürlü ürünlerin bakım ve kullanım yönetiminde kritik bir rol oynamaktadır. Bu nedenle, bu alanlarda daha doğru ve güvenilir RUL tahmin yöntemleri geliştirme çabaları önem kazanmıştır.

Birçok araştırma, DNN algoritmalarının RUL tahmini için etkili bir yöntem olduğunu ortaya koymuştur. Bu bağlamda, (Ren vd., 2018) çalışması, otomatik kodlayıcıların kullanımını içeren özgün bir yöntem sunmaktadır. Otomatik kodlayıcı, veri kümesini otomatik olarak kodlar ve anlamlı özellikler çıkarır. Ardından, bu kodlanmış veriler kullanılarak DNN, sistemin kalan ömrünü tahmin etmek için eğitilir. Böylece, elde edilen çok boyutlu özellik-

ler, RUL tahminlerinin doğruluğunu ve hassasiyetini artırabilir.

RUL tahmininde DNN algoritmalarının etkinliğini değerlendiren bir diğer çalışma ise (Khumprom ve Yodo, 2019) tarafından yapılmıştır. Bu çalışmada, DNN, SVM, k-NN, ANN ve LR gibi farklı makine öğrenmesi algoritmalarıyla karşılaştırılmıştır. Sonuçlar, DNN'nin diğer algoritmalarla karşılaştırıldığında daha iyi performans gösterdiğini ve RUL tahmininde daha doğru sonuçlar verdiğini göstermiştir.

Bataryalar gibi enerji depolama sistemlerinin ömrünü tahmin etmek de büyük önem taşır. Bu bağlamda, (Venugopal vd., 2021) çalışması, aynı donanım platformunda SOH tahmini ve RUL tahmini için uzun kısa dönem bellekli sinir ağı (LSTM) modeli kullanarak gerçek zamanlı RUL tahmini yapmaktadır. Bu yaklaşım, enerji depolama sistemlerinin etkin bir şekilde yönetilmesine ve bakım süreçlerinin optimize edilmesine katkı sağlayabilir.

Geleneksel DNN yaklaşımlarının yanı sıra, hibrit DNN tekniklerinin de RUL tahmininde başarıyla kullanıldığı görülmektedir. Örneğin, (Kara, 2021) çalışması, CNN, LSTM ve geleneksel sinir ağlarını birleştiren yeni bir hibrit DNN yaklaşımı önermektedir. Bu yaklaşım, farklı özellik türlerini bir araya getirerek daha kapsamlı ve kapsayıcı bir RUL tahmini elde etmeyi hedeflemektedir.

Bir diğer önemli çalışma, (Lee vd., 2021) tarafından yapılmıştır. Bu çalışma, bataryaların ömrü boyunca uzun şarj/deşarj döngüleri nedeniyle kapasite azalmasının istatistiksel olarak analizini yapmış ve bu bilgileri kullanarak DNN algoritmasını RUL tahmini için kullanmıştır. Bu şekilde, bataryaların ömrü boyunca meydana gelen kapasite azalmasının etkili bir şekilde tahmin edilmesi sağlanabilir.

Ayrıca, (Qiao vd., 2020) çalışması, empirik mod ayrıştırma yöntemini kullanarak bataryanındeşarj edilebilir kapasitesini iki kategoriye ayırmıştır: global bozulma trendi ve kapasite yenileme. DNN, global bozulma trendini tahmin etmek için kullanılırken, LSTM diğer ayrıştırmayı ele almak için kullanılmaktadır. Böylece, bataryanın RUL tahmini,deşarj edilebilir kapasitesinin bu iki ayrı bileşenin birleştirilmesiyle elde edilir.

Son zamanlardaki çalışmalarda, DNN algoritmalarının lityum-iyon pillerin RUL tahminindeki potansiyeli dikkat çekmektedir. (Ma vd., 2020) çalışmasında önerilen bir yöntem, RUL tahmini için DNN tabanlı transfer öğrenmeyi kullanır. Bu yöntem, hedef bataryaya en yakın geçmiş test verilerine sahip referans bir pil seçerken ortalama Öklidyen mesafesini (AED) kullanarak, hedef bataryanın performansının en yakın olduğu pili belirler. Ardından, bu seçilen veri kullanılarak yığılmış gürültü giderici otomatik kodlayıcıya (SDA) dayalı tahmin modeli eğitilir ve hedef bataryanın RUL'ünü tahmin etmek için kullanılır.

Geliştirilen bu DNN tabanlı RUL tahmini yöntemi, lityum-iyon pillerin kullanım ömrü boyunca performans degradasyonunu tahmin etmek için oldukça etkili ve verimli bir yaklaşım sunmaktadır. DNN algoritmaları, büyük miktarda veri üzerinde karmaşık ve yüksek boyutlu özellikleri etkin bir şekilde öğrenme yeteneğine sahip olduğu için, bu tür pil tahmin problemlerinin çözümünde özellikle avantajlıdır.

Transfer öğrenme yaklaşımı, daha fazla etiketli veriye ihtiyaç duyulan geleneksel derin öğrenme yöntemlerine göre, daha sınırlı miktarda etiketli veriyle de iyi sonuçlar elde etmeyi mümkün kılar. AED kullanarak uygun bir referans pilin seçilmesi, tahmin modelinin doğruluğunu artırır ve hedef bataryanın benzer geçmiş performans verilerini kullanarak daha güvenilir RUL tahminleri yapılmasını sağlar.

Bu tür ileri düzey DNN tabanlı RUL tahmin yöntemleri, endüstriyel uygulamalarda bakım süreçlerini optimize etmeye, enerji depolama sistemlerinin verimliliğini artırmaya ve aynı zamanda ekonomik ve çevresel açıdan sürdürülebilir bir enerji yönetimi stratejisi geliştirmeye yönelik önemli bir adım sunmaktadır.

Gelecekteki çalışmalar, DNN algoritmalarının RUL tahminindeki performansını daha da geliştirmek için farklı mimari ve özellik çıkarım tekniklerinin incelenmesine odaklanabilir. Aynı zamanda, farklı pil tipleri, çevresel koşullar ve kullanım senaryolarına göre bu yöntemlerin genelleştirilebilirliğini artırmak için daha çeşitli veri kümeleri kullanılabilir. Bu sayede, lityum-iyon pillerin güvenilir ve doğru RUL tahminleriyle daha uzun ömürlü ve verimli kullanımı desteklenerek, ileri teknolojiyle donatılmış uygulamalarda daha sürdürülebilir bir geleceğe katkı sağlanabilir.

LIB RUL tahmininde DNN tabanlı daha birçok farklı çalışma bulunmaktadır. Bu çalışmalardan biri olan (Hong vd., 2020) tarafından yapılan araştırma, kısa vadeli veriler kullanarak LIB'lerin RUL tahminini gerçekleştirmek için DNN tabanlı bir end-to-end derin öğrenme sistemi sunmaktadır. Bu yaklaşım, LIB'lerin ömrünü tahmin etmek için gereken bilgileri tamamen DNN üzerinden öğrenir ve bu sayede daha etkili ve hızlı bir RUL tahmini sağlar.

Benzer şekilde, (Lee vd., 2021) çalışmasında ise iki farklı DNN kullanılarak LIB'lerin RUL tahmini yapılmaktadır. Bu iki DNN'den biri, kapasite zayıflamasına neden olan empedans zayıflamasındaki istatistiksel analizi gerçekleştirir. Özellikle, bozulma derecesinin artmasıyla ortaya çıkan empedans zayıflamasını inceleyerek, bataryanın kapasitesindeki azalmayı tahmin eder. Diğer DNN ise kapasite zayıflama trendini tahmin ederek RUL tahmininin doğruluğunu artırmayı hedefler.

Bu tür DNN tabanlı RUL tahmini yöntemleri, LIB'lerin yaşlanma süreçlerinin daha iyi anlaşılmasına ve bakım süreçlerinin daha etkili bir şe-

kilde yönetilmesine olanak tanır. DNN algoritmalarının derin ve karmaşık öğrenme yetenekleri sayesinde, bataryanın performansı ile ilgili çok çeşitli faktörlerin analiz edilmesi ve RUL tahminine katkı sağlayan önemli bilgilerin çıkarılması mümkün olur.

Bu tür çalışmaların amacı, özellikle uzun ömürlü ve güvenilir enerji depolama sistemlerine olan ihtiyacın arttığı günümüzde, LIB'lerin daha etkin bir şekilde kullanılmasını sağlamaktır. RUL tahmininin doğruluğu, enerji depolama sistemlerinin bakım maliyetlerini azaltabilir ve performanslarını artırabilir. Ayrıca, enerji yönetimi ve sürdürülebilirlik alanında da büyük önem taşıyan bu çalışmalar, gelecekteki yenilikçi enerji teknolojilerinin geliştirilmesine katkıda bulunarak, daha temiz ve verimli enerji kaynaklarının kullanımını teşvik edebilir.

Sonuç olarak, DNN tabanlı RUL tahmini çalışmaları, lityum iyon bataryaların daha iyi anlaşılması ve performanslarının artırılması için önemli bir adım olarak öne çıkmaktadır. DNN algoritmaları, RUL tahmininde büyük potansiyele sahip olan etkili bir yaklaşım olarak ön plana çıkmaktadır. Hem geleneksel DNN yöntemleri hem de hibrit DNN teknikleri, çok boyutlu ve non-lineer özellikleri yakalayıp daha doğru ve güvenilir RUL tahminleri sağlamada önemli bir rol oynamaktadır. Bu çalışmalar, endüstriyel ekipmanların bakımını optimize etmek ve enerji depolama sistemlerinin verimliliğini artırmak gibi önemli uygulamalarda kullanılacak daha gelişmiş RUL tahmin yöntemlerinin geliştirilmesine katkıda bulunmaktadır.

TARTIŞMALAR VE BULGULAR

Bu bölümde DNN tabanlı BMS durum tahminleri için yapılan çalışmaların genel bir özetini sunuyoruz. Bölüm 3, 4 ve 5'te sunulan çalışmalarda kullanılan pil yapısını, kullanılan veritabanlarını, kullanılan sinyalleri, pil şarj-deşarj döngülerini, test metodlarını ve hata metrik tipini ve değerlerini Tablo 2'de oranlayarak sunmaktayız.

Tablo incelendiğinde tahminler kısmında bilindik batarya durum tahminlerini (SOH, SOC ve RUL) yukarıda saydığımız kategorilerde ayırarak derin bir inceleme yaptık. Her üç batarya durum tahminlerinde NMC tipli bataryaların yoğun olarak kullanıldığı gözlemlenmiştir. Bunun en büyük nedenlerinden birisi tabii de ulaşımın kolay olması ve piyasada yaygın olarak kullanılıyor olmasıdır. Kullanılan veritabanı olarak ise açık kaynak olma özelliğinden dolayı NASA veritabanı kullanımının yaygın olduğu görülüyor. Çalışmalarda kullanılan "ölçüm sinyalleri" olarak adlandırılan parametrede her ne kadar çeşitlilik gösterse de voltaj (V), akım (I) ve sıcaklık (T) çoğunlukla kullanılan parametrelerdir.

Şarj-deşarj döngüleri çalışmalarının kullanım amacına göre farklılık gösterebilir. Genel bir aralık verdiğimiz de ise minimum 90 cycle ve maximum

2000 cycle yapan çalışmalar batarya durum tahminine göre değişebiliyor. Test metodlarında ağırlıklı olarak validation method kullanılırken RUL tahminlerinde cross-validation kullanan çalışmalar da iyi bir orana sahip olduğu gözlemlendi. Çalışmalarda kullanılan hata hesaplama için çok farklı ölçümler kullanılmıştır. Bunlardan RMSE her üç tahmin durumlarında da ortak olarak kullanılan hata ölçümü olarak görünmektedir.

Tablo 2: BMS durumlarının tahmini için DNN tabanlı yöntemlerin analizinin karşılaştırılması

Estimation	Density of Using the Battery	Density of Using the Database	Measurement Signal	Cycles [min – max]	Test Method	Error Metric & Min-Error
SOH	<ul style="list-style-type: none"> • %68 NMC • %32 LFP 	<ul style="list-style-type: none"> • %55 CCCV • %40 NASA • %5 SHEVDC 	<ul style="list-style-type: none"> • %40 V,I,T,t • %25 V • %20 V,I,T,C • %10 V,I,t • %5 V,I,t, SOC curve 	[100-2000]	<ul style="list-style-type: none"> • %90 validation • %10 cross-validation 	<ul style="list-style-type: none"> • RMSE=% <3.247 • MAE=%0.39 • MaxE=% <0.3
SOC	<ul style="list-style-type: none"> • %64 NMC • %36 LFP 	<ul style="list-style-type: none"> • %40 NASA • %40 UDDS • %20 CCCV 	<ul style="list-style-type: none"> • %50 V,I • %20 V,I,T • %17 V,t • %7 V,I,T,t • %6 V 	[100-165]	<ul style="list-style-type: none"> • %100 validation 	<ul style="list-style-type: none"> • EE=% 0.8 • RMSE=%0.312 • MAE=%0.01 • MAPE=%0.08 • MaxE=%5 • MSE=%0.12
RUL	<ul style="list-style-type: none"> • %86 NMC • %14 LFP 	<ul style="list-style-type: none"> • %78 NASA • %11 MIT-Stanford • %11 CATL 	<ul style="list-style-type: none"> • %50 V,I,T • %13 V,I,T,t • %13 V,I • %12 V,T • %12 V 	[90-175]	<ul style="list-style-type: none"> • %67 validation • %33 cross-validation 	<ul style="list-style-type: none"> • EE=%3.59 • RMSE=%0.16

SONUÇ

Bu çalışmanın sonuçları, lityum-iyon piller için DNN temelli yöntemlerin, BMS için güçlü ve etkili bir yaklaşım olduğunu göstermektedir. SOH, SOC, RUL ve FOD gibi önemli pil parametrelerinin doğru tahmin edilmesi, lityum-iyon pillerin güvenli ve verimli bir şekilde kullanılmasını sağlamada kritik bir rol oynamaktadır.

Çalışmanın detaylı analizi, farklı DNN yöntemlerinin performansını ve etkinliğini karşılaştırmalı olarak ortaya koymaktadır. Bu, gelecekteki araştırmacılara ve endüstri uzmanlarına, daha ileri düzeyde BMS teknolojileri ve pil yönetimi stratejileri geliştirme konusunda yol gösterici olacaktır.

Özellikle enerji depolama, elektrikli araçlar ve taşınabilir elektronik cihazlar gibi çeşitli sektörlerdeki kullanımıyla lityum-iyon pillerin güvenlik sorunlarına karşı dikkatli bir yönetim gereklidir. Bu çalışmanın sağladığı kapsamlı analiz, BMS uygulamalarındaki eksiklikleri belirleyerek bu alanlardaki potansiyel riskleri azaltmaya yardımcı olacaktır.

Sonuç olarak, bu çalışma, lityum-iyon pillerin durumunu tahmin etmek için DNN tabanlı yöntemlerin önemini vurgulamakta ve bu alandaki ileri

arařtırmaların önünü açmaktadır. Bu çalıřma, lityum-iyon piller için güvenli ve verimli bir pil yönetimi stratejileri geliřtirmeye yönelik arařtırmacılara deđerli bilgiler sunmaktadır. Bu sayede, lityum-iyon pillerin yaygın kullanıldıđı sektörlerde daha güvenli ve etkili enerji depolama çözümleri sađlanabilir.

KAYNAKÇA

- Chemali, E., Kollmeyer, P. J., Preindl, M., and Emadi, A. (2018). State-of-charge estimation of li-ion batteries using deep neural networks: A machine learning approach. *Journal of Power Sources*, 400:242–255.
- Ee, Y.-J., Tey, K.-S., Lim, K.-S., Shrivastava, P., Adnan, S., and Ahmad, H. (2021). Lithium-ion battery state of charge (soc) estimation with non-electrical parameter using uniform fiber bragg grating (fbg). *Journal of Energy Storage*, 40:102704.
- Hong, J., Lee, D., Jeong, E.-R., and Yi, Y. (2020). Towards the swift prediction of the remaining useful life of lithium-ion batteries with end-to-end deep learning. *Applied Energy*, 278:115646.
- How, D. N., Hannan, M. A., Lipu, M. S. H., Sahari, K. S., Ker, P. J., and Muttaqi, K. M. (2020). State-of-charge estimation of li-ion battery in electric vehicles: A deep neural network approach. *IEEE Transactions on Industry Applications*, 56(5):5565–5574.
- Hsu, C.-W., Xiong, R., Chen, N.-Y., Li, J., and Tsou, N.-T. (2022). Deep neural network battery life and voltage prediction by using data of one cycle only. *APPLIED ENERGY*, 306(B).
- Hu, C., Ma, L., Guo, S., Guo, G., and Han, Z. (2022). Deep learning enabled state-of-charge estimation of lifepo4 batteries: A systematic validation on state-of-the-art charging protocols. *Energy*, 246:123404.
- Ivakhnenko, A. G. (1971). Polynomial theory of complex systems. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-1(4):364–378.
- Kara, A. (2021). A data-driven approach based on deep neural networks for lithium-ion battery prognostics. *NEURAL COMPUTING & APPLICATIONS*, 33(20):13525–13538.
- Khumprom, P. and Yodo, N. (2019). A data- driven predictive prognostic model for lithium-ion batteries based on a deep learning algorithm. *Energies*, 12(4).
- Kim, J., Yu, J., Kim, M., Kim, K., and Han, S. (2018). Estimation of li-ion battery state of health based on multilayer perceptron: as an ev application. *IFAC-PapersOnLine*, 51(28):392–397. 10th IFAC Symposium on Control of Power and Energy Systems CPES 2018.
- Lee, C.-J., Kim, B.-K., Kwon, M.-K., Nam, K., and Kang, S.-W. (2021a). Real-time prediction of capacity fade and remaining useful life of lithium-ion batteries based on charge/discharge characteristics. *ELECTRONICS*, 10(7).
- Lee, J.-H., Kim, H.-S., and Lee, I.-S. (2019). Deep neural network based soh monitoring of battery module. In Meen, T., editor, *PROCEEDINGS OF THE 2019 IEEE EURASIA CONFERENCE ON IOT, COMMUNICATION AND ENGINEERING (ECICE)*, pages 14–16. Inst Elect & Elect Engineers; Int Inst Knowledge Innovat & Invent; MDPI; Bur Foreign Trade; Minist Sci & Technol.

- Lee, J.-H., Kim, H.-S., and Lee, I.-S. (2021b). State of charge estimation and state of health diagnostic method using multilayer neural networks. In 2021 INTERNATIONAL CONFERENCE ON ELECTRONICS, INFORMATION, AND COMMUNICATION (ICEIC).
- Lin, W.-J. and Chen, K.-C. (2022). Evolution of parameters in the doyle-fuller-newman model of cycling lithium ion batteries by multi-objective optimization. *APPLIED ENERGY*, 314.
- Ma, J., Shang, P., Zou, X., Ma, N., Ding, Y., Su, Y., Chong, J., Jin, H., and Lin, Y. (2020). Remaining useful life transfer prediction and cycle life test optimization for different formula li-ion power batteries using a robust deep learning method. *IFAC-PapersOnLine*, 53(3):54–59.
- Ma, L., Hu, C., and Cheng, F. (2021). State of charge and state of energy estimation for lithium-ion batteries based on a long short-term memory neural network. *Journal of Energy Storage*, 37:102440.
- Messing, M., Shoa, T., Ahmed, R., and Habibi, S. (2020). Battery soc estimation from eis using neural nets. In 2020 IEEE Transportation Electrification Conference & Expo (ITEC), pages 588–593. IEEE.
- Mu, D. and Wang, S. (2021). Estimation of state of charge of lithium-ion batteries based on wide and deep neural network model. *Mathematical Problems in Engineering*, 2021.
- Park, M., Seo, M., Song, Y., and Kim, S. W. (2020). Capacity estimation of li-ion batteries using constant current charging voltage with multilayer perceptron. *IEEE Access*, 8:180762–180772.
- Qiao, J., Liu, X., and Chen, Z. (2020). Prediction of the remaining useful life of lithium-ion batteries based on empirical mode decomposition and deep neural networks. *IEEE ACCESS*, 8:42760–42767.
- Ren, L., Zhao, L., Hong, S., Zhao, S., Wang, H., and Zhang, L. (2018). Remaining useful life prediction for lithium-ion battery: A deep learning approach. *IEEE ACCESS*, 6:50587–50598.
- Savargaonkar, M. and Chehade, A. (2020). An adaptive deep neural network with transfer learning for state-of-charge estimations of battery cells. In 2020 IEEE Transportation Electrification Conference & Expo (ITEC), pages 598–602. IEEE.
- Savargaonkar, M., Chehade, A., Shi, Z., and Hussein, A. A. (2020). A cycle-based recurrent neural network for state-of-charge estimation of li-ion battery cells. In 2020 IEEE Transportation Electrification Conference & Expo (ITEC), pages 584–587. IEEE.
- Shi, Y., Ahmad, S., Tong, Q., Lim, T. M., Wei, Z., Ji, D., Eze, C. M., and Zhao, J. (2021). The optimization of state of charge and state of health estimation for lithium-ions battery using combined deep learning and kalman filter methods. *INTERNATIONAL JOURNAL OF ENERGY RESEARCH*, 45(7):11206–11230.

- Song, L., Zhang, K., Liang, T., Han, X., and Zhang, Y. (2020). Intelligent state of health estimation for lithium-ion battery pack based on big data analysis. *Journal of Energy Storage*, 32:101836.
- Sui, X., He, S., Vilsen, S. B., Meng, J., Teodorescu, R., and Stroe, D.-I. (2021). A review of non-probabilistic machine learning-based state of health estimation techniques for lithium-ion battery. *Applied Energy*, 300:117346.
- Tian, J., Xiong, R., Shen, W., and Lu, J. (2021a). State-of-charge estimation of lifepo4 batteries in electric vehicles: A deep-learning enabled approach. *Applied Energy*, 291:116812.
- Tian, J., Xiong, R., Shen, W., Lu, J., and Yang, X.-G. (2021b). Deep neural network battery charging curve prediction using 30 points collected in 10 min. *Joule*, 5(6):1521–1534.
- Venugopal, P., Shankar, S. S., Jebakumar, C. P., Agarwal, R., Alhelou, H. H., Reka, S. S., and Golshan, M. E. H. (2021). Analysis of optimal machine learning approach for battery life estimation of li-ion cell. *IEEE ACCESS*, 9:159616–159626.
- Wei, Z., Han, X., and Li, J. (2022). State of health assessment for echelon utilization batteries based on deep neural network learning with error correction. *JOURNAL OF ENERGY STORAGE*, 51.
- Wu, J., Wang, Y., Zhang, X., and Chen, Z. (2016). A novel state of health estimation method of li-ion battery using group method of data handling. *Journal of Power Sources*, 327:457–464.
- Xia, Z. and Abu Qahouq, J. A. (2021). Lithium-ion battery ageing behavior pattern characterization and state-of-health estimation using data-driven method. *IEEE ACCESS*, 9:98287–98304.
- Zhao, F., Li, P., Li, Y., and Li, Y. (2019). The li-ion battery state of charge prediction of electric vehicle using deep neural network. In 2019 Chinese Control And Decision Conference (CCDC), pages 773–777. IEEE.

Bölüm 5

HAVA KİRLİLİĞİ BİLİNCİNİN KARAR AĞACI MODELİ KULLANILARAK TAHMİN EDİLMESİ VE SİMÜLASYONU: SİNOP İLİ ÖRNEĞİ¹

Mevlüt KILINÇ²

Selahattin BARDAK³

1 Bu çalışma Doç. Dr. Selahattin BARDAK danışmanlığında Mevlüt KILINÇ'ın "Hava Kirliliği Bilincinin Veri Madenciliğine Dayalı Olarak Değerlendirilmesi: Sinop İli Örneği" adlı Yüksek Lisans Tezinden üretilmiştir.

2 Mevlüt KILINÇ, Karamanoğlu Mehmetbey Üniversitesi, Karaman Türkiye, ORCID ID: 0000-0002-7549-2869

3 Doçent Doktor Selahattin BARDAK, Sinop Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Sinop, Türkiye, ORCID ID: 0000-0001-9724-4762,
E-mail: sbardak@sinop.edu.tr

1. GİRİŞ

İnsanlar varoluşundan bu tarafa içerisinde yaşadıkları çevreyi kendi isteklerine göre şekillendirmek için çalışmaktadır. Bu şekillendirme çalışması içerisinde doğal döngüye ve yaşadıkları çevreye zarar vermektedir. 20. yy' da sanayileşme ile fosil yakıt kullanımını artmıştır. Fosil yakıt kullanımının artması çevreye çok ciddi zararlar vermiş, ciddi çevresel sorunlar ortaya çıkartmıştır. Genel olarak bu sorunlar; orman alanlarının yok olması, çölleşmelerin ortaya çıkması, plansız kentleşmenin yaygınlaşması, iklimsek değişiklikler, asit yağmurlarının oluşması, biyolojik çeşitliliğin azalması veya biyolojik çeşitliliğin yok olması gibi en temel sorunlara neden olmaktadır. Ekolojik dengede meydana gelen bu bozulmalar insan sağlığını ciddi şekilde tehdit etmektedir. Ekolojik dengenin bozulmasına neden olan temel faktör insandır. Bu bozulmadan en çok etkilenende yine insandır. Sebep sonuç ilişkisine bakıldığı zaman bunu azaltacak veya engelleyecek olan temel unsur yine insandır.

Günümüzde çevre ile ilgili sorunlar çeşitlenerek sürekli olarak artmakta doğaya ve insan sağlığına olumsuz etki etmektedir. Özellikle canlı hayatının devamı için vazgeçilmez ve alternatifi olmayan en temel kaynak olan havanın kirlenmesi nedeni ile oluşan hava kirliliği, kitlesel olarak canlı hayatının olumsuz etki meydana getiren çok ciddi küresel sonuçlar oluşturmaktadır. Hava kirliliği bölgesel veya ulusal sınırlar içerisinde kalmayıp küresel anlamda etki oluşturur. İnsanların hayatlarını kaybetmesi, hastalıkların ortaya çıkması, yaşam kalitesinin standartlarının düşmesi gibi insan sağlığını tehdit eden sonuçlar ortaya çıkarmaktadır. Çevre kirliliğinin sonuçları oluşumu açısından bölgesel olsa bile sonuçlarına bakıldığı zaman tam anlamıyla küresel bir sorundur.

Veri madenciliği, disiplinler arası bir alandır ve ham veriden kullanışlı olabilecek bilgiyi çıkarmak için gerekli yöntemleri kullanmaktadır. İstatistiksel yöntemler ile çeşitli bilgisayar algoritmalarını kullanarak veri tabanlarındaki veriden, anlamlı ve işe yarar bilginin çıkarımını ifade eden bir süreçtir (Çelik, 2019; Kılınç ve ark., 2022).

Çevre sorunlarının kaynağı insan davranışları olduğu temelinden hareket edilerek Sinop ilinde yaşayan katılımcıların hava kirliliği bilincinin veri

madenciligi yöntemlerinden biri olan karar ağacı modeli kullanılarak tahmin edilmesi ve simülasyonu üzerine bir çalışma gerçekleştirilmiştir.

2. HAVA KİRLİLİĞİ

Hava kirliliği, insan sağlığı, canlı hayatına zarar verecek, eşya ve malzemelerin bozulmalarına, ekolojik dengenin bozulmasına neden olabilecek düzeyde katı, sıvı veya gaz formundaki kirleticilerin atmosferde bulunmasıdır. Hava kirliliği, volkanik aktiviteler, orman yangınları, depremler ve bataklıklar gibi doğal nedenlerle oluşabileceği gibi, sanayileşme, ısınma, ulaşım ve enerji üretimi gibi insan aktivitelerine bağlı olarak da oluşabilmektedir. Nüfus artışı ve buna bağlı olarak artan şehirleşme ve sanayileşme eğilimi hava kirliliği sorununu beraberinde getirmektedir. Kuraklık, topoğrafik koşullar ve iklimsel özellikler de hava kirliliğinin düzeyini etkilemektedir. Endüstriler ve enerji santralleri, yüksek miktarda partikül madde, azot oksitler, kükürt oksitler, karbon monoksit, hidrokarbon, organik bileşik ve diğer kimyasalların atmosfere salınmasına ve hava kalitesinin azalmasına neden olur. Bu tesisler sadece yerel düzeyde insan ve çevre sağlığına zarar vermekle kalmaz, aynı zamanda bölgesel ölçekte asit yağmurları, ozon oluşumuna, ya küresel ölçekte ise iklim değişikliğine neden olarak dünyanın geleceği için yıkıcı sonuçlara sebep olabilir. Endüstriyel tesislerin enerji üretimi veya ürün prosesi sırasında hava kirliliğine neden olabilen kirletici emisyonları oluşabilmektedir. Enerji üretimindeki hava kirliliğinin en büyük aktörü fosil yakıt kullanımımızdır. 19. yüzyıldan beri kullanılmakta olan fosil yakıtlar insan ve çevre sağlığı açısından büyük tahribata neden olmuştur. Enerji ihtiyacı ulaşım sektöründe de kendini göstermektedir. Hava, deniz ve kara ulaşımı için gereken enerjinin çok büyük kısmı halen fosil yakıtlardan karşılanmaktadır (Hava Kirliliği Raporu, 2018).

Artan nüfus, kullanılan makinelerden kaynaklı artan emisyonlar ve temiz yakıt ve teknolojilerin kullanılmaması ile dünya ısınmakta ve soluduğumuz hava tehlikeli hale gelmektedir. 10 insandan 9'u kirli hava solumaktadır. Dünya Sağlık Örgütüne (DSÖ) göre her yıl yaklaşık 7 milyon ölüm, hem dış hem de iç ortam hava kirliliğinden kaynaklanmaktadır. Hava kirliliği, sağlık için önemli bir çevresel risktir. Hava kirliliğinin azaltılması felç, kalp hastalıkları, akciğer kanseri, kronik ve akut solunum solu hastalıkları ve astım gibi hastalıkların azalmasını sağlayacaktır. DSÖ Bölgesel Gruplarının bölgesel tahminlerine göre hava kirliliğinden kaynaklı en fazla ölüm olan bölgelerden

en az ölüm olan bölgelere sırasıyla şu şekildedir; Güney Doğu Asya, Batı Pasifik, Afrika, Doğu Akdeniz, Avrupa ve Amerika (Hava Kirliliği Raporu, 2018).

2.1. Hava Kirliliği Tipleri

2.1.1. Londra Tipi Hava Kirliliği



Şekil 1. Londra Tipi Hava Kirliliği (Tozlumikrofon, 2018)

Sisle karışan petrol ve kömür yanma ürünlerinin neden olduğu hava kirliliğidir. İngilizcede sis ve duman sözcüklerinin birer hecesi alınarak smog terimi türetilmiştir. Bu tip kirlenmede kükürt dioksit birikimi ve sülfürik asit yoğunlaşması görülür. Sabahları sıcaklığın düşük ve nem oranının fazla olduğu saatlerde oldukça yoğun şekilde görülür. Oluştugu alanı battaniye gibi örttüğü gözlenebilir (Güler & Çobanoğlu, 1994). Astım ve bronşite neden olduğu belirtilmektedir. Ayrıca çok yüksek seviyelerde boğulma hissine ve ölümlere neden olur (Akbulut Zencirli ve Işıklı, 2017).

2.1.2. Los Angeles Tipi Hava Kirliliği



Şekil 2. Los Angeles Tipi Hava Kirliliği (Tozlumikrofon, 2018)

Gazlara bağlı bir kirliliktir. Los Angeles Okyanus kıyısındadır ve etrafı dağlarla çevrili olan bu kent C biçiminde bir çanakta yer almaktadır. Otomobil trafiği yoğundur. Okyanustan gelen sisi, otomobil egzoz gazlarıyla karışımı sonucu oluşmaktadır. Buna rafineri gazları da eklenmektedir (Güler & Çobanoğlu, 1994). Güneş ışığının etkisiyle oluşan fotokimyasal değişiklikler sonucu ortaya çıkan moleküller gözlerde sulanma ve yanma, iltihaplanma, ciltte tahriş, ve akciğer hasarına neden olur. Ayrıca bitkilerin kurumasına, boyaların aşınarak dökülmesine, lastiklerin çürümesine yol açar (Akbulut Zencirli ve Işıklı, 2017).

2.2. Hava Kirleticileri

2.2.1. Gazlar

Solunum yolu ile rahatlıkla insan vücuduna girebilmektedir. Bunlardan bazıları şunlardır.

2.2.1.1. Kükürt dioksit (SO₂)

Atmosfere salınan SO₂'nin; büyük bir kısmı özellikle kömürün yakıt olarak kullanıldığı termik santraller; ham madde işleyerek üretim yapan

endüstriler; petrol rafineleri, çimento fabrikaları, metalürji endüstrisi; kentsel bölgelerde konut ve işyeri ısıtmasında kullanılan katı ve sıvı yakıtlar; orman yangınları, volkanik faaliyetler gibi doğal kaynaklardan meydana gelir. SO₂ atmosferdeki nemde çözülmesi, güneş ışığı ve bazı kimyasalların varlığında sülfürik asit oluşturması ile asit yağmurları oluşumunda önemli etkenlerden biridir. Asit yağmurları ise bitkileri öldürür, toprağın yapısını ve bakteri florasını olumsuz etkileyerek verimliliği azaltır ve erozyonu hızlandırır, konut ve eşyalarda aşınmalara neden olurlar (Akbulut Zencirli ve Işıklı, 2017).

2.2.1.2. Azot oksitler (NO_x)

NO_x'ler; katı veya sıvı yakıtların yüksek sıcaklıklarda yanmasıyla oluşan genellikle renksiz ve kokusuz gazlardır. İki önemli kaynağı motorlu taşıtlar ve termik santraller olup bunların dışında endüstri tesisleri, ticari ve evsel ısıtma için yakıt tüketiminden de kaynaklanabilir. Atmosfere salınan azot oksitler oksidasyon sonucu NO₂'ye dönüşür ve partiküllerle birlikte bulduklarında kentsel bölgelerde kırmızımsı-kahve renkli bir tabaka halinde görülebilir. Azot oksitler suda eremediğinden üst solunum yollarında elimine edilmeden akciğerlerin en uç noktalarına kadar kadar inhale edilirler. Kanın oksijen taşıma kapasitesinde azalma, solunum yollarında tahriş ve enfeksiyona yatkınlık gibi olumsuz sağlık sonuçlarına neden olur (Akbulut Zencirli ve Işıklı, 2017).

2.2.1.3. Karbonmonoksit (CO)

Genellikle yakıtlardaki karbon tam olarak yanmadığında meydana gelen karbon monoksit (CO) renksiz, kokusuz bir gazdır. Kent atmosferindeki CO'nin çoğu taşıtlardan kaynaklanmakla birlikte endüstri (metal işleme, kimyasal üretim tesisleri), odun yakılması ve orman yangınları sonucu ortaya çıkar (Akbulut Zencirli ve Işıklı, 2017).

2.2.2. Partikül maddeler

Partikül madde, atmosferde asılı bulunan katı partiküllerin ve sıvı damlacıkların bir karışımı olup, asitler (sülfat, nitrat gibi), organik kimyasallar, metaller, toprak veya toz partikülleri, bakteri, küf, mantar, deniz suyunun buharlaşması ile ortaya çıkan tuzlar ve allerjik polenlerden oluşur. Genel olarak katı ve sıvı yakıtların yanmasından, motorin ve kurşunlu benzin kullanan taşıtlar, termik santraller gibi yanma işlemlerinden, bazı endüstriyel

aktivitelerden ve atmosferik gazların dönüşümüyle oluşurlar (Akbulut Zencirli ve Işıklı, 2017).

3. VERİ MADENCİLİĞİ

Teknoloji sürekli olarak gelişmektedir. Gelişen teknoloji hayatımızın her alanında girmiştir. Kullandığımız telefon, tablet, bilgisayarlar gibi birçok teknolojik aletler hem hayatımızı kolaylaştırmakta hem de farkında olmadan günlük yaşamımızın ayrılmaz parçası haline gelmektedir. Teknolojinin gelişmesi ile artık veriler elektronik araçlar ile dijital ortamlara aktarılmaya ve saklanmaya başlamıştır. Meteorolojik ve jeofizik verileri, eğitim, sağlık, bankacılık, çeşitli internet siteleri ve alışveriş sitelerinde oluşturulan üyelikler, güvenlik amaçlı oluşturulan retina, parmak izi, yüz tanıma gibi birçok alanda artarak veri yığınları oluşmaktadır. Oluşan bu veri yığınları içerisinde anlamlı bilginin çıkarılması işlemi olarak tanımlanan veri madenciliği (Bilekdemir, 2010), bazı yazarlar tarafından şu şekilde tanımlanmıştır:

- Veri madenciliğini büyük veri setlerinden belli bir önemi olan, önceden bilinmeyen ve yararlı ve anlaşılır örüntülerin keşfi olarak tanımlamıştır (Büchner ve ark., 1997).

- Veri madenciliğini, kabul edilebilir sayısal verimlilik çerçevesinde, veri içerisinde belirli örüntüleri ortaya koyan veri analizi ve keşif algoritmalarının uygulanması ile oluşan Bilgi Keşfi Sürecinin bir adımı olarak tanımlar (Fayyad ve ark., 1996).

- Veri madenciliği fonksiyonlarını sınıflama, bölümlenme, tahmin ve tanımlama olarak kategorize eder (Westpal ve Blaxton, 1998).

- Veri madenciliğini işlemciye nasıl sorulacağı bilinmeyen soruların cevaplarını istemenin bir yolu olarak tanımlar (Jothishankar ve ark.,2004).

Farklı bilim insanlarının veri madenciliği hakkındaki tanımlamalarına bakıldığında veri madenciliğinin ne olduğu konusunda evrensel bir fikir birliği olmadığını söyleyebiliriz.

Klasik istatistiksel uygulamalar ve veri madenciliği arasındaki en temel farklılık, veri kümesinin büyüklüğüdür. Bir istatistikçi için 'büyük' veri kümesi birkaç yüz veya bin veri içerir. Veri madenciliği ile uğraşan birileri için ise

milyon veya milyarlık veri beklenmeyen bir sayı değildir. Bu tip büyük veri tabanları gerçek hayatta sıkça ortaya çıkmaktadır (Oğuzlar, 2003).

Veri madenciliğinin uygulanabilmesi için yığın halinde verilerin elimizde bulunması ön koşuldur. Veri madenciliği farklı formatlarda çok sayıda kütükte yığın halindeki veriler arasında gizli bir şekilde bulunan mesajları çekip çıkarmamıza yarayan bir araçtır. Veri madenciliği çeşitli açılardan geleneksel istatistiksel yöntemlerle önemli farklılıklar gösterir. Özellikle zaman içinde verinin azlığının değil, çokluğunun bir sorun olması ve bilgisayarların veri saklama ve işleme hızlarındaki inanılmaz artışların sonucunda veri madenciliğinin güncelliği her geçen gün artmış ve artmaktadır (Oğuzlar, 2003).

3.1. Modeller ve Uygulama Alanları

Veri madenciliğinde kullanılan modeller, tahmin edici ve tanımlayıcı modeller olarak iki başlıkta incelenebilir. Tahmin edici modellerde, sonuçları bilinen verilerden hareket edilerek bir model geliştirilmesi ve kurulan bu modelden yararlanılarak sonuçları bilinmeyen veri kümeleri için sonuç değerlerin tahmin edilmesi amaçlanmaktadır. Tanımlayıcı modellerde ise karar vermeye rehberlik etmede kullanılacak mevcut verilerdeki örüntülerin tanımlanması sağlanmaktadır (Özekes, 2003).

Veri madenciliği modellerini gördükleri işlevlere göre,

1. Sınıflama (Classification) ve Regresyon (Regression)
2. Kümeleme (Clustering)
3. Birliktelik Kuralları (Association Rules)

Olarak incelenebilir. Sınıflama ve regresyon modelleri tahmin edici, kümeleme ve birliktelik kuralları tanımlayıcı modellerdir (Özekes, 2003).

3.1.1. Sınıflama (Classification) ve Regresyon (Regression)

Sınıflama ve regresyon, önemli veri sınıflarını ortaya koyan veya gelecek veri eğilimlerini tahmin eden modelleri kurabilen iki veri analiz yöntemidir. Sınıflama kategorik değerleri tahmin ederken, regresyon süreklilik gösteren değerlerin tahmin edilmesinde kullanılır (Özekes, 2003).

Sınıflama ve regresyon modellerinde kullanılan başlıca teknikler şunlardır:

1. Karar Ağaçları (Decision Trees)
2. Yapay Sinir Ağları (Artificial Neural Networks)
3. Genetik Algoritmalar (Genetic Algorithms)
4. K-En Yakın Komşu (K-Nearest Neighbor)
5. Bellek Temelli Nedenleme (Memory Based Reasoning)
6. Naive-Bayes (Özkes, 2003).

3.1.1.1. Karar Ağaçları (Decision Trees)

Karar ağaçları, veri madenciliğinde kuruluşlarının ucuz olması, yorumlanmalarının kolay olması, veri tabanı sistemleri ile kolayca entegre edilebilmeleri ve güvenilirliklerinin iyi olması nedenleri ile sınıflama modelleri içerisinde en yaygın kullanıma sahip tekniktir. Karar ağacı, adından da anlaşılacağı gibi bir ağaç görünümünde, tahmin edici bir tekniktir. Ağaç yapısı ile kolay anlaşılabilen kurallar yaratabilen, bilgi teknolojileri işlemleri ile kolay entegre olabilen en popüler sınıflama tekniğidir (Özkes, 2003).

Karar ağacı karar düğümleri, dallar ve yapraklardan oluşur. Karar düğümü, gerçekleştirilecek testi belirtir. Bu testin sonucu ağacın veri kaybetmeden dallara ayrılmasına neden olur. Her düğümde test ve dallara ayrılma işlemleri ardışık olarak gerçekleşir ve bu ayrılma işlemi üst seviyedeki ayrımlara bağlıdır. Ağacın her bir dalı sınıflama işlemi tamamlamaya adaydır. Eğer bir dalın ucunda sınıflama işlemi gerçekleşmiyorsa, o daim sonucunda bir karar düğümü oluşur. Ancak daim sonunda belirli bir sınıf oluşuyorsa, o dalın sonunda yaprak vardır. Bu yaprak, veri üzerinde belirlenmek istenen sınıflardan biridir. Karar ağacı işlemi kök düğümünden başlar ve yukarıdan aşağıya doğru yaprağa ulaşana dek ardışık düğümleri takip ederek gerçekleşir (Özkes, 2003).

Karar ağacı tekniğini kullanarak verinin sınıflanması iki basamaklı bir işlemdir. İlk basamak öğrenme basamağıdır. Öğrenme basamağında önceden bilinen bir eğitim verisi, model oluşturmak amacıyla sınıflama algoritması

tarafından analiz edilir. Öğrenilen model, sınıflama kuralları veya karar ağacı olarak gösterilir. İkinci basamak ise sınıflama basamağıdır. Sınıflama basamağında test verisi, sınıflama kurallarının veya karar ağacının doğruluğunu belirlemek amacıyla kullanılır. Eğer doğruluk kabul edilebilir oranda ise, kurallar yeni verilerin sınıflanması amacıyla kullanılır (Özekes, 2003).

Test verisine uygulanan bir modelin doğruluğu, yaptığı doğru sınıflamanın test verisindeki tüm sınıflara oranıdır. Her test örneğinde bilinen sınıf, model tarafından tahmin edilen sınıf ile karşılaştırılır. Eğer modelin doğruluğu kabul edilebilir bir değer ise model, sınıfı bilinmeyen yeni verileri sınıflama amacıyla kullanılabilir (Özekes, 2003).

3.1.2. Kümeleme

Kümeleme, veriyi sınıflara veya kümelere ayırma işlemidir. Aynı kümedeki elemanlar birbirleriyle benzerlik gösterirlerken, başka kümelerin elemanlarından farklıdır. Kümeleme veri madenciliği, istatistik, biyoloji ve makine öğrenimi gibi pek çok alanda kullanılır. Kümeleme modelinde, sınıflama modelinde olan veri sınıfları yoktur. Verilerin herhangi bir sınıfı bulunmamaktadır. Sınıflama modelinde, verilerin sınıfları bilinmekte ve yeni bir veri geldiğinde bu verinin hangi sınıftan olabileceği tahmin edilmektedir. Oysa kümeleme modelinde, sınıfları bulunmayan veriler gruplar halinde kümelere ayrılırlar. Bazı uygulamalarda kümeleme modeli, sınıflama modelinin bir önişlemi gibi görev alabilmektedir (Özekes, 2003).

Literatürde pek çok kümeleme algoritması bulunmaktadır. Kullanılacak olan kümeleme algoritmasının seçimi, veri tipine ve amaca bağlıdır. Genel olarak başlıca kümeleme yöntemleri şu şekilde sınıflandırılabilir:

1. Bölme yöntemleri (Partitioning methods)
2. Hiyerarşik yöntemler (Hierarchical methods)
3. Yoğunluk tabanlı yöntemler (Density-based methods)
4. Izgara tabanlı yöntemler (Grid-based methods)
5. Model tabanlı yöntemler (Model-based methods) (Özekes, 2003)

3.1.3. Birliktelik Kuralları

Birliktelik kuralları, büyük veri kümeleri arasında birliktelik ilişkileri bulurlar. Toplanan ve depolanan verinin her geçen gün gittikçe büyümesinden dolayı şirketler veri tabanlarındaki birliktelik kurallarını ortaya çıkarmaktadırlar. Büyük miktardaki mesleki işlem kayıtlarından ilginç birliktelik ilişkilerini keşfetmek, şirketlerin karar almalarını daha verimli hale getirmektedir (Özekes, 2003; Kılınç ve ark., 2022).

4. MATERYAL VE METOD

4.1. Verilerin Elde edilmesi

Araştırmada kullanılacak verilerin toplanabilmesi amacıyla, bu çalışmada 8 sorudan oluşan soru formu kullanılmıştır. Soru formu hazırlanırken, soru formu içerisinde yer alan soruların araştırılmakta olan varsayımlarla doğrudan ilişkili olmasına dikkat edilmiştir. Soru formundaki sorular Sinop İli Merkezde yaşayan kişilerin hava kirliliği bilincinin belirleyecek şekilde tasarlanmıştır. Katılımcılara ilk başta Sinop İli Merkezinde çeşitli mahallelerde yaşayan vatandaşların demografik özelliklerini içeren sorulara (eğitim, yaş, medeni durum, meslek, vb.) sorulara yer verilmiştir. Daha sonra ise bu vatandaşların hava kirliliği bilincini tespit edecek soru sorulmuştur. Bu kapsamda mümkün olduğunca Sinop İli merkezdeki mahallerde ikamet eden 18 yaş ve üzerindeki kişilere sorular sorulmuştur. Soru formunun uygulanacağı kişi sayısı belirlenirken %95 güven düzeyi ve %5 hata payına göre hesaplanmıştır. 20000-60000 (Sinop İli nüfusu bu aralıktadır.) arasındaki birey sayılarında örnek büyüklüğü 377 ile 382 arasında değiştiği tespit edilmiştir. Bazı kişilerin sorulara rasgele cevap verebilecekleri düşünülerek 408 kişiye soru formu uygulanmıştır. Soru formunda rasgele cevap verdiği tespit edilen kişilerin cevapları değerlendirilmemiştir. Tasarlanan soru formu online ortamda oluşturulmuş olup sosyal medyadan kolayda örneklem yöntemiyle Temmuz 2021 Tarihinde uygulanmıştır.

Soru formu oluşturulduktan sonra Sinop Üniversitesi İnsan Araştırmaları Etik Kurulu tarafından 03.02.2021 ve Tarih ve 2021/19 Karar Sayısı ile uygun olduğuna dair izin alınmıştır.

Katılımcılara uygulanan soru formu aşağıda verilmiştir.

1) Cinsiyetiniz

Kadın Erkek

2) Yaşınız

18-24 25-44 45-64 65 ve üstü

3) Medeni durumunuz

Evli Bekâr

4) Eğitim durumunuz

İlköğretim Lise Ön Lisans Lisans Lisansüstü

5) Mesleğiniz

Öğrenci İşçi Memur Emekli İşsiz Diğer

6) Ailenizin ortalama geliri

0-2324TL 2325-4213TL 4214-6123TL 6124-8119TL
8120TL ve üzeri

7) Sinop ilinde kaç yıldır ikamet ediyorsunuz?

0-1 2-4 5-7 8-10 11 yıl ve üstü

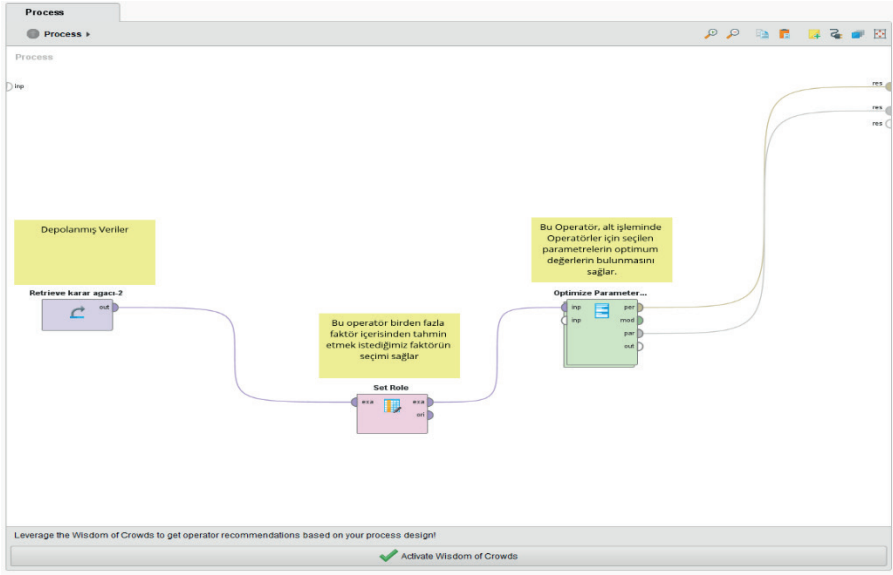
8) Sinop ilinde hava kirliliğine neden olan temel faktör sizce nedir?

Kömür kullanımı Sanayi Atıkları Evsel Atıklar Orman Yangınları
Motorlu Taşıtlar Diğer

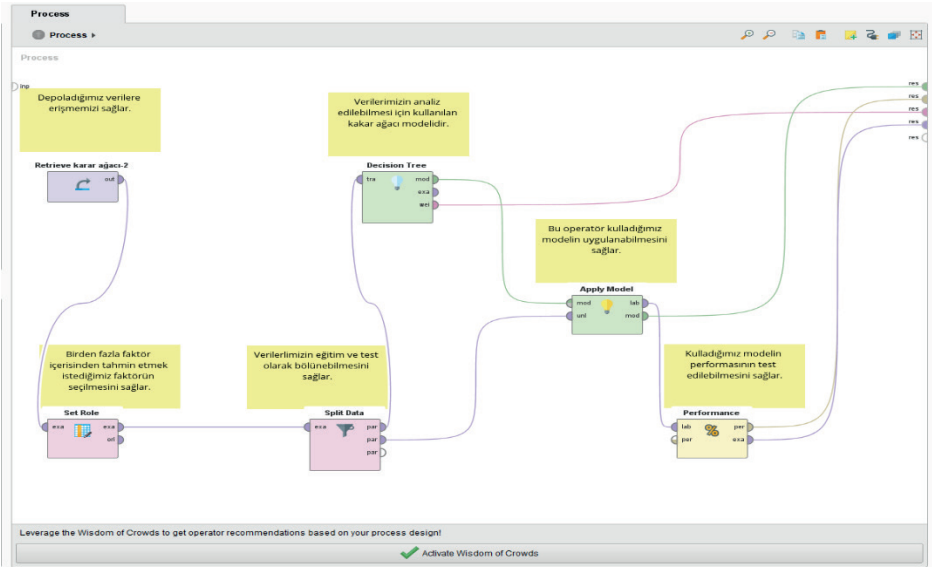
4.2. Modelin Kurulması

Yapılan çalışmada bilim dünyasında ve çeşitli endüstrilerde problemleri çözmek için yaygın olarak kullanılan Rapidminer yazılımından faydalanılmıştır. Rapidminer içinde birçok algoritmanın bulunduğu bir veri bilimi platformudur (Bardak ve Bardak, 2020; Cuesta ve ark., 2019; Chou ve Tran, 2018; Udayakumar ve ark., 2018). Rapidminer yazılımı operatörler ile çalışmaktadır. (Naik ve Samant 2016:665; Ristoski vd., 2015:147). Her operatörün bir görevi bulunmaktadır.

Hazırlanan soru formundaki sorular kullanılarak RapidMiner programında yer alan veri madenciliği yöntemlerinden biri olan kakar ağacı algoritmasının da Sinop İli Merkezde hava kirliliğine neden olan faktörler değerlendirilerek tahmin edilmeye çalışılmıştır. Şekil 3 ve Şekil 4'de Kakar ağacı modelinin en iyi sonuçları verebilmesi için parametrelerin optimizasyonu için hazırlanan proses verilmiştir.

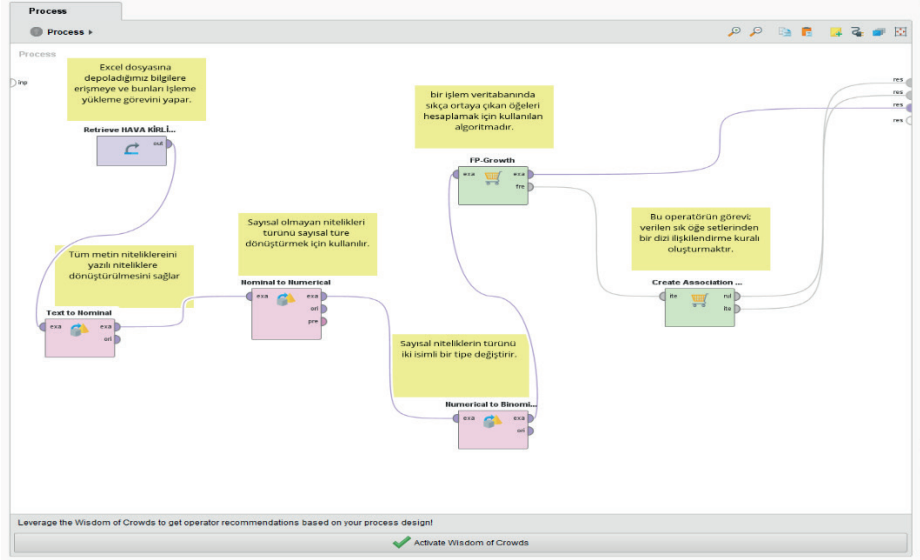


Şekil 3. Parametrelerin Optimizasyonu İçin Hazırlanan Proses



Şekil 4. Karar Ağacı Modelinde Parametrelerin Optimizasyonu Sağlayan Operatör İçin Hazırlanan Proses

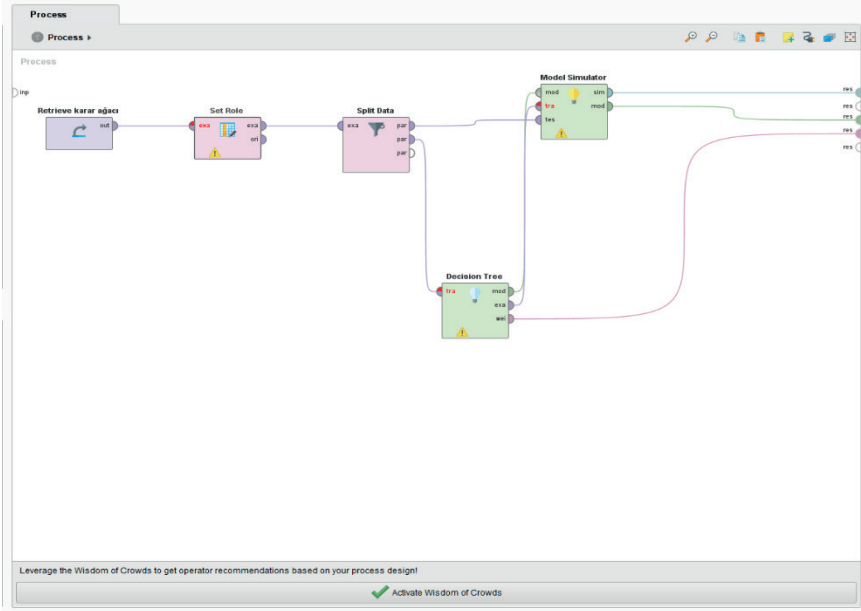
Şekil 5’de karar ağacı modelinde verilerin analizi için hazırlanan proses verilmiştir.



Şekil 5. Karar Ağacı Modelinde Verilerin Analizi İçin Hazırlanan Proses

Yukarıdaki Şekil 3, Şekil 4 ve Şekil 5’de her operatörün görevi üzerinde gösterilmiştir.

Simülasyon, bir sürecin temsili olarak tanımlanabilir (Bardak vd., 2021). Karar ağacı modelinde verilerin analiz işleminden sonra simülasyon işlemi yapılmıştır. Simülasyon işlemi için hazırlanan proses Şekil 6’da verilmiştir.



Şekil 6. Karar Ağacı Modelinde Simülasyon İçin Hazırlanan Proses

Şekil 6’da verilen operatörlerin görevini bakacak olursak; 1. operatör elde ettiğimiz depolanmış verilerimize erişmemizi sağlar. Set role operatörü çalışmamız içerisinde yer alan birçok faktör içerisinde istediğimiz faktörü seçmemizi sağlar. Split data operatörü verilerimizin eğitim ve test olarak bölünmesinde görev alır. Decision tree operatörü verilerimizin analizinde kullanılan modeldir. Model simulator operatörü ise girdileri bir modele dönüştürerek çıktıyı görüntülemek için kolay, gerçek zamanlı bir yöntem elde etmemizi sağlar.

5. BULGULAR VE TARTIŞMA

5.1. Karar Ağacı Modeli Parametrelerinin Optimizasyonu

Karar ağacı modelinde Sinop ili Merkezde katılımcılara sorulan sorular neticesinde hava kirliliğine neden olan faktörlerin tahmin edilebilmesinde en iyi sonuçları elde edebilmek için yapılan parametrelerin optimizasyonu sonucu aşağıdaki tabloda verilmiştir.

Tablo 1. Karar Ağacı Modelinde Optimizasyon Sonuçları

Parametreler	Karar ağacı
Kriter	Gini_index
Maksimum Derinlik	60

Sinop İli Merkezde hava kirliliğini etkileyen faktörlerin tahmin edilebilmesi için oluşturulan karar ağacı modelinin performans sonuçları aşağıdaki tabloda verilmiştir.

Tablo 2. Karar Ağacı Performans Değerleri

Performans değişkenleri	Değerleri (%)
Doğruluk	73,81
Sınıflandırma hatası	26,19
Göreceli hata	32,03

Yukarıdaki tabloya bakıldığında oluşturulan karar ağacı modelinin %80,81 doğruluk ile Sinop İli Merkezde hava kirliliğine neden olan faktörleri tahmin edebilmiştir.

Karar ağacı modelinin metin hali aşağıda verilmiştir.

Eğitim durumunuz = Lisans

| Ailenizin ortalama geliri = 0-2324 TL

| | Cinsiyetiniz = Erkek: Motorlu taşıtlar

| | Cinsiyetiniz = Kadın

| | | Medeni Durumunuz = Bekar

| | | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 0-1: Kömür kullanımı

| | | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 2-4: Motorlu taşıtlar

| | | Medeni Durumunuz = Evli: Motorlu taşıtlar

| Ailenizin ortalama geliri = 2325-4213 TL

| | Medeni Durumunuz = Bekar: Kömür kullanımı

| | Medeni Durumunuz = Evli: Motorlu taşıtlar

| Ailenizin ortalama geliri = 4214-6123 TL

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 0-1

| | | Mesleğiniz = Memur: Motorlu taşıtlar

| | | Mesleğiniz = İşçi: Orman yangınları

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 11 yıl ve üstü

| | | Cinsiyetiniz = Erkek: Motorlu taşıtlar

| | | Cinsiyetiniz = Kadın: Kömür kullanımı

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 2-4

| | | Medeni Durumunuz = Bekar: Kömür kullanımı

| | | Medeni Durumunuz = Evli: Motorlu taşıtlar

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 5-7

| | | Cinsiyetiniz = Erkek

| | | | Medeni Durumunuz = Bekar: Motorlu taşıtlar

| | | | Medeni Durumunuz = Evli: Kömür kullanımı

| | | Cinsiyetiniz = Kadın: Motorlu taşıtlar

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 8-10: Motorlu taşıtlar

| Ailenizin ortalama geliri = 6124-8119 TL

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 0-1: Kömür kullanımı

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 11 yıl ve üstü: Motorlu

taşıtlar

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 2-4

| | | Medeni Durumunuz = Bekar: Motorlu taşıtlar

| | | Medeni Durumunuz = Evli: Kömür kullanımı

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 5-7: Kömür kullanımı

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 8-10: Evsel atıklar

| Ailenizin ortalama geliri = 8120 TL ve üzeri

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 0-1: Kömür kullanımı

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 11 yıl ve üstü

| | | Cinsiyetiniz = Erkek: Motorlu taşıtlar

| | | Cinsiyetiniz = Kadın: Kömür kullanımı

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 2-4: Kömür kullanımı

| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 5-7
| | | Medeni Durumunuz = Bekar: Kömür kullanımı
| | | Medeni Durumunuz = Evli
| | | | Cinsiyetiniz = Erkek: Kömür kullanımı
| | | | Cinsiyetiniz = Kadın: Motorlu taşıtlar
| | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 8-10: Sanayi atıkları

Eğitim durumunuz = Lisansüstü

| Ailenizin ortalama geliri = 0-2324 TL: Evsel atıklar
| Ailenizin ortalama geliri = 2325-4213 TL: Motorlu taşıtlar
| Ailenizin ortalama geliri = 4214-6123 TL
| | Cinsiyetiniz = Erkek
| | | Medeni Durumunuz = Bekar: Orman yangınları
| | | Medeni Durumunuz = Evli: Kömür kullanımı
| | Cinsiyetiniz = Kadın: Motorlu taşıtlar
| Ailenizin ortalama geliri = 6124-8119 TL
| | Medeni Durumunuz = Bekar: Kömür kullanımı
| | Medeni Durumunuz = Evli: Motorlu taşıtlar
| Ailenizin ortalama geliri = 8120 TL ve üzeri
| | Cinsiyetiniz = Erkek: Motorlu taşıtlar
| | Cinsiyetiniz = Kadın: Kömür kullanımı

Eğitim durumunuz = Lise

| Ailenizin ortalama geliri = 0-2324 TL
| | Mesleğiniz = Diğer
| | | Medeni Durumunuz = Bekar: Diğer
| | | Medeni Durumunuz = Evli: Kömür kullanımı
| | Mesleğiniz = Öğrenci
| | | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 0-1: Kömür kullanımı
| | | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 11 yıl ve üstü: Diğer
| | | Sinop ilinde kaç yıldır ikamet ediyorsunuz = 2-4: Diğer
| Ailenizin ortalama geliri = 2325-4213 TL
| | Mesleğiniz = Diğer
| | | Cinsiyetiniz = Erkek: Motorlu taşıtlar
| | | Cinsiyetiniz = Kadın: Kömür kullanımı
| | Mesleğiniz = Emekli: Motorlu taşıtlar
| | Mesleğiniz = Öğrenci: Kömür kullanımı
| | Mesleğiniz = İşçi
| | | Cinsiyetiniz = Erkek: Motorlu taşıtlar
| | | Cinsiyetiniz = Kadın: Kömür kullanımı

- | Ailenizin ortalama geliri = 4214-6123 TL
- | | Yaşınız = 18-24: Kömür kullanımı
- | | Yaşınız = 25-44: Sanayi atıkları
- | | Yaşınız = 45-64: Kömür kullanımı
- | Ailenizin ortalama geliri = 6124-8119 TL: Motorlu taşıtlar
- | Ailenizin ortalama geliri = 8120 TL ve üzeri
- | | Cinsiyetiniz = Erkek: Orman yangınları
- | | Cinsiyetiniz = Kadın: Diğer
- Eğitim durumunuz = Ön lisans
- | Mesleğiniz = Diğer
- | | Medeni Durumunuz = Bekar
- | | | Ailenizin ortalama geliri = 6124-8119 TL: Motorlu taşıtlar
- | | | Ailenizin ortalama geliri = 8120 TL ve üzeri: Kömür kullanımı
- | | Medeni Durumunuz = Evli: Kömür kullanımı
- | Mesleğiniz = Emekli: Orman yangınları
- | Mesleğiniz = Memur
- | | Ailenizin ortalama geliri = 2325-4213 TL: Motorlu taşıtlar
- | | Ailenizin ortalama geliri = 4214-6123 TL
- | | | Cinsiyetiniz = Erkek: Motorlu taşıtlar
- | | | Cinsiyetiniz = Kadın: Kömür kullanımı
- | | Ailenizin ortalama geliri = 8120 TL ve üzeri: Evsel atıklar
- | Mesleğiniz = Öğrenci: Kömür kullanımı
- | Mesleğiniz = İşçi
- | | Ailenizin ortalama geliri = 0-2324 TL: Motorlu taşıtlar
- | | Ailenizin ortalama geliri = 2325-4213 TL: Evsel atıklar
- | | Ailenizin ortalama geliri = 4214-6123 TL: Diğer
- | Mesleğiniz = İşsiz: Kömür kullanımı
- Eğitim durumunuz = İlköğretim
- | Ailenizin ortalama geliri = 0-2324 TL: Kömür kullanımı
- | Ailenizin ortalama geliri = 2325-4213 TL: Motorlu taşıtlar
- | Ailenizin ortalama geliri = 6124-8119 TL: Diğer
- | Ailenizin ortalama geliri = 8120 TL ve üzeri: Diğer

Yukarıdaki karar ağacından elde edilen verilerin bazılarını açıklayacak olursak;

1- Eğitim durumu lisans, ailesinin ortalama geliri 0-2324 TL arasında ve cinsiyeti erkek olan kişiler, Sinop İli Merkezde hava kirliliğine neden olan faktörün motorlu taşıtlar olduğunu söylemişlerdir.

2- Eğitim durumu lisans, ailesinin ortalama geliri 0-2324 TL arasında ve cinsiyeti kadın, medeni durumu bekar ve Sinop İli merkezde 0-1 yıl arası ikamet edenler Sinop İli merkezde hava kirliliğine neden olan faktörün kömür kullanımı, 2-4 yıl arasında ikamet edenler ise motorlu taşıtlar olduğunu bildirmişlerdir.

3- Eğitim durumu lisans, ailesinin ortalama geliri 2325-4213 TL arasında ve medeni durumu bekar olan kişiler, Sinop İlinde hava kirliliğinin temel faktörünün kömür kullanımı evli olanlar ise motorlu taşıtlar olduğunu bildirmişlerdir.

4- Eğitim durumu lisans, ailesinin ortalama geliri 4214-6123 TL arası, Sinop İli Merkezde 0-1 yıl arasında ikamet eden ve mesleği memur olan kişiler, hava kirliliğinin temel faktörünün motorlu taşıtlar, meleği işçi olanların ise orman yangınları olduğunu söylemişlerdir.

5- Eğitim durumu lisans, ailesinin ortalama geliri 4214-6123 TL arası, Sinop İli Merkezde 11 yıl ve üstü ikamet eden ve cinsiyeti erkek olan kişiler, hava kirliliğinin temel faktörünün motorlu taşıtlar, cinsiyeti erkek olan kişiler ise kömür kullanımı olduğunu bildirmişlerdir.

6- Eğitim durumu lisans, ailesinin ortalama geliri 6124-8119 TL arası ve Sinop İli Merkezde 0-1 yıl arasında ikamet eden kişiler, hava kirliliği temel faktörünün kömür kullanımı, 11 yıl ve üstü ikamet edenler ise motorlu taşıtlar olduğunu bildirmişlerdir.

7- Eğitim durumu lisans, ailesinin ortalama geliri 6124-8119 TL arası ve Sinop İli Merkezde 5-7 yıl arasında ikamet eden kişiler, hava kirliliği temel faktörünün kömür kullanımı, 8-10 yıl arası ikamet edenlerin ise evsel atıklar olduğunu söylemişlerdir.

8- Eğitim durumu lisans, ailesinin ortalama geliri 8120 TL ve üzeri ve Sinop İli Merkezde 0-1 yıl arası ikamet eden kişiler, Sinop İli merkezde hava kirliliğinin temel nedeninin kömür kullanımı, 11 yıl ve üstü ikamet eden ve cinsiyeti erkek olan kişiler motorlu taşıtlar, cinsiyeti kadın olan kişiler ise kömür kullanımı olduğunu bildirmişlerdir.

9- Eğitim durumu lisans, ailesinin ortalama geliri 8120 TL ve üzeri ve Sinop İli Merkezde 8-10 yıl arası ikamet eden kişiler, hava kirliliği temel faktörünün sanayi atıkları olduğunu söylemişlerdir.

10- Eğitim durumu lisansüstü ve ailesinin ortalama geliri 0-2324 TL arasında olan kişiler, hava kirliliği temel nedeninin evsel atıklar, ailesinin ortalama geliri 2325-4213 TL olan kişiler ise motorlu taşıtlar olduğunu söylemişlerdir.

11- Eğitim durumu lisansüstü, ailesinin ortalama geliri 4214-6123 TL arası ve cinsiyeti kadın olan kişiler, hava kirliliği temel faktörünün motorlu taşıtlar olduğunu söylemişlerdir.

12- Eğitim durumu lisansüstü, ailesinin ortalama geliri 8120 TL ve üzeri ve cinsiyeti erkek olan kişiler, Sinop İli Merkezde hava kirliliği temel nedeninin motorlu taşıtlar, cinsiyeti kadın olanlar ise kömür kullanımı olduğunu bildirmişlerdir.

13- Eğitim durumu lise, ailesinin ortalama geliri 0-2324 TL arası, mesleği diğer ve medeni durumu bekar olan kişiler hava kirliliği etkileyen temel faktörün seçiminde diğer cevabını medeni durumu evli olanlar ise kömür kullanımı cevabını vermişlerdir.

14- Eğitim durumu lise, ailesinin ortalama geliri 0-2324 TL arası, mesleği öğrenci ve Sinop İli Merkezde 0-1 yıl arası ikamet eden kişiler, hava kirliliği temel nedeninin kömür kullanımı olduğunu söylemişlerdir.

15- Eğitim durumu lise, ailesinin ortalama geliri 4214-6123 TL arası, yaşı 18-24 arası olan kişiler hava kirliliği temel nedeninin kömür kullanımı, yaşı 25-44 arası olanlar sanayi atıkları ve yaşı 45-64 arası olan kişiler ise kömür kullanımı olduğunu bildirmişlerdir.

16- Eğitim durumu lise, ailesinin ortalama geliri 8120 TL ve üzeri ve cinsiyeti, erkek olan kişiler Sinop İli Merkezde hava kirliliğine neden olan temel faktörün orman yangınları, cinsiyeti kadın olan kişiler ise diğer olduğunu düşünmüşlerdir.

17- Eğitim durumu ön lisans, mesleği diğer, medeni durumu bekar ve ailesinin ortalama geliri 6124-8119 TL arası olan kişiler, hava kirliliği temel faktörünün motorlu taşıtlar, ailesinin ortalama geliri 8120 TL ve üzeri olan kişiler ise kömür kullanımı olduğunu bildirmişlerdir.

18- Eğitim durumu ön lisans, mesleği emekli olan kişiler, hava kirliliği temel nedeninin orman yangınları, mesleği memur ve ailesinin ortalama geliri 2325-4213 TL olan kişiler ise, motorlu taşıtlar olduğunu bildirmişlerdir.

19- Eğitim durumu ön lisans ve mesleği öğrenci olan kişiler, hava kirliliği temel faktörünün kömür kullanımı olduğunu söylemişlerdir.

20- Eğitim durumu ön lisans, mesleği işçi ve ailesinin ortalama geliri 0-2324 TL arası olan kişiler hava kirliliği temel nedeninin motorlu taşıtlar, ailesinin ortalama geliri 2325-4213 TL olan kişiler evsel atıklar ve ailesinin ortalama geliri 4214-6123 TL arası olan kişiler ise, diğer olduğunu bildirmişlerdir.

21- Eğitim durumu ilköğretim ve ailesinin ortalama geliri 0-2324 TL arası olan kişiler, hava kirliliği temel faktörünün kömür kullanımı, ailesinin

ortalama geliri 2325-4213 TL arası olan kişiler motorlu taşıtlar ve ailesinin ortalama geliri 6124-8119 TL arası ve 8120 TL ve üzeri olan kişiler ise diğer olduğunu bildirmişlerdir.

Karar ağacı modelinde ağacın oluşmasını sağlayan faktörlerin ağırlıkları aşağıdaki tabloda verilmiştir.

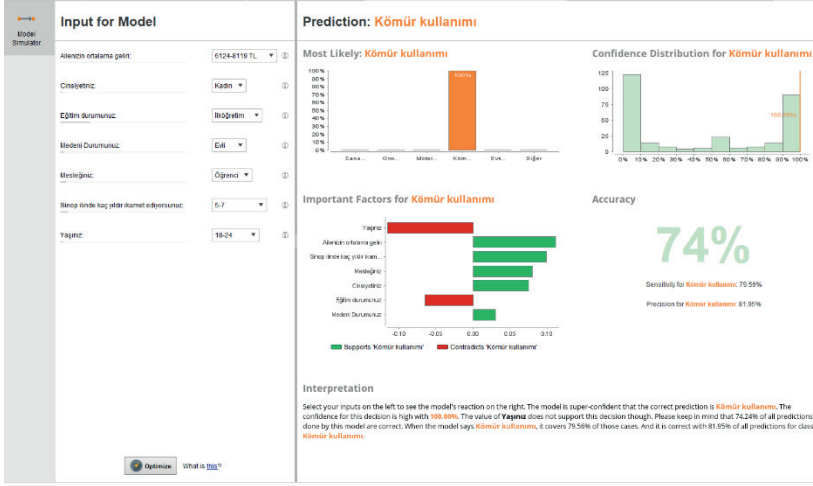
Tablo 3.Faktörler ve Ağırlıkları

Faktör	Ağırlığı
Cinsiyet	0,242
Yaş	0,025
Ortalama gelir	0,206
Eğitim durumu	0,021
Meslek	0,129
Medeni durum	0,183
İkamet	0,193

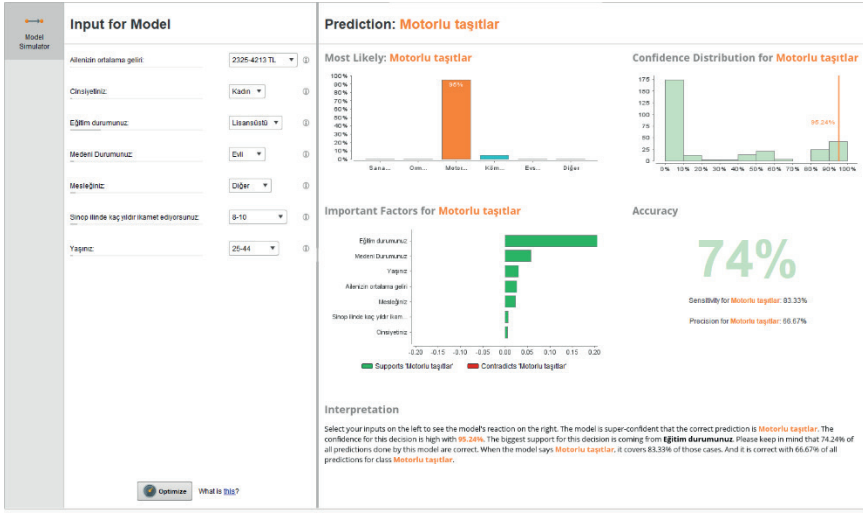
Tabloya bakıldığında karar ağacı modelinde ağacın oluşmasını etkileyen en önemli faktörün cinsiyet (0.242) olduğu bulunmuştur.

Karar ağacı modeli çeşitli alanlarda kullanılabilir. Örnek verilecek olursa; mobilya seçiminde etkili olan faktörlerin belirlenmesinde (Bardak ve ark., 2018), tüketici tercihlerinin belirlenmesinde (Bardak ve Özbek, 2021) ve tatil yeri kararının belirlenmesinde (Lezki ve Er, 2010) gibi birçok alanda kullanılmaktadır.

Verilerin analiz işleminden sonra yapılan simülasyon en güvenilir sonuçları alabilmemiz için giriş verilerimizin optimize edilmesini sağlamaktadır. Ayrıca giriş verilerini değiştirmek suretiyle istediğimiz çıkış verilerini ulaşmamızı imkan sağlamaktadır. Karar ağacı modelinde hava kirliliğini etkileyen faktörlerden biri olan kömür kullanımı için verilerin optimizasyonu sonucu elde edilen simülasyon ekran görüntüsü Şekil 4.3.1'de, motorlu taşıtlar için verilerin optimizasyonu sonucu elde edilen ekran görüntüsü ise Şekil 4.3.2'de verilmiştir.



Şekil 7. Kömür Kullanımı İçin Örnek Simülasyon Ekran Görüntüsü



Şekil 8. Motorlu Taşıtlar İçin Örnek Simülasyon Ekran Görüntüsü

Şekil 7'deki hava kirliliğini etkileyen faktörlerden biri olan kömür kullanımı için oluşturulan simülasyon ekran görüntüsü incelendiğinde, ailesinin ortalama geliri 6124-8119 TL arasında, cinsiyeti kadın, eğitim durumu ilköğretim, medeni durumu evli, mesleği öğrenci, Sinop İli Merkezde ikamet süresi 5-7 yıl arası ve yaşının 18-24 olan kişilerde hava kirliliğini etkileyen faktörlerden kömür kullanımı çıkma olasılığı en yüksektir.

Şekil 8'deki hava kirliliğini etkileyen faktörlerden biri olan motorlu taşıtlar için oluşturulan simülasyon ekran görüntüsü incelendiğinde, ailesinin

ortalama geliri 2325-4213 TL arasında, cinsiyeti kadın, eğitim durumu lisansüstü, medeni durumu evli, mesleği diğer, Sinop İli Merkezde ikamet süresi 8-10 yıl arası ve yaşının 25-44 olan kişilerde hava kirliliğini etkileyen faktörlerden motorlu taşıtlar çıkma olasılığı en yüksektir.

6. SONUÇ

Bu çalışma, Sinop İli Merkezde yaşayan kişilerin hava kirliliğine sebep olan çeşitli etmenler hakkındaki düşüncelerini belirlemek için yapılmıştır. Bu amaçla veri toplamak için 8 sorudan oluşan bir soru formu hazırlanmıştır. Daha sonra verilerin değerlendirilmesi için veri madenciliği yöntemlerinden olan karar ağacı modeli kullanılmıştır. En son olarak da giriş verilerinin optimizasyonunu sağlayan simülasyon işlemi yapılmıştır. Bu analizler için Rapidminer programı kullanılmıştır.

Uygulanan karar ağacı modeli sonucunda, Sinop İli Merkezde hava kirliliğine neden olan en önemli faktörlerin kömür kullanımı ve motorlu taşıtlar olduğu düşünceleridir. Karar ağacı modeli %73,81 doğruluk ile hava kirliliği neden olan faktörlerin tahmin edilebilmesini sağlamıştır. Karar ağacı oluşmasında etkili olan en önemli değişkenin cinsiyet (0,242) olduğu bulunmuştur. Bunu ortalama gelir, ikamet süresi, medeni durum, meslek, yaş ve eğitim durumu takip etmektedir.

Son olarak yapılan karar ağacı modelindeki simülasyon işlemi ise, giriş verilerimizi optimizasyonu ve giriş verileri değiştirerek hava kirliliğine neden olan faktörlerin farklı bir çalışma yapmadan tahmin etmemizi sağlamaktadır. Optimizasyon işlemi hava kirliliğine neden olan en önemli faktörler olarak bulunan kömür kullanımı ve motorlu taşıtlar için yapılmıştır. Bu işlem bize hem maliyet hem de süre yönünden büyük avantajlar sağlamaktadır.

Yapılan çalışmalar sonucu hava kirliliğine neden olan en önemli faktörlerin kömür kullanımı ve motorlu taşıtlar olduğu tespit edilmiştir. Bu kirlleticiler için ek önlemler alınabilir.

Ülkemizde hava kirliliği konusunda veri madenciliği yöntemleri ile ilgili çalışmalar sınırlıdır. Bu alandaki çalışmalar şehirler ve ülke bazında yapılarak çevre bilinci oluşturulabilir.

KAYNAKÇA

- Akbulut Zencirli, S ve Işıklı, B. (2011). Hava kirliliği, türk dünyası uygulama ve araştırma Merkezi Halk Sağlığı Dergisi, Cilt:2, Sayı:2, Sayfa:24-36.
- Bardak, S., Bardak, T. (2020). Mobilya ürününde en çok karşılaşılan sorunların veri madenciliği ile araştırılması, Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences International Indexed and Refereed, 7(13), 285-292.
- Bardak, S., Bardak, T., Peker, H., Sözen, E. ve Çabuk, Y. (2021). Predicting effects of selected impregnation processes on the observed bending strength of wood, with use of data mining models. BioResources, 16(3): 4891-4904.
- Bardak, S., Özbek, A. (2021). Veri madenciliği yöntemleriyle tüketicilerin tişört tercihlerinin belirlenmesi, Mühendislik Alanında Araştırma ve Değerlendirmeler, Cilt II, Gece Kitaplığı, sayfa: 73-95.
- Bardak, T., Peker, H., Bardak, S. (2018). Effects examination of the factors affecting choice of type of furniture with data mining technique (decision tree). International Journal of Ecosystems and Ecology Science (IJEES), 8(2), 249-252.
- Bilekdemir, G.(2010). Veri madenciliği tekniği kullanılarak üretim tahmini ve bir uygulama, (Yayımlanmamış yüksek lisans tezi), T.C. Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü.
- Büchner, A.G., Anand, S.S. ve Hughes, J. (1997). Data mining in manufacturing environments: Goals, techniques and applications, Sayfa:1.
- Chou, J. S., & Tran, D. S. (2018). Forecasting energy consumption time series using machine learning techniques based on usage patterns of residential householders. Energy, 165, 709-726.
- Cuesta, H. A., Coffman, D. L., Branas, C., & Murphy, H. M. (2019). Using decision trees to understand the influence of individual-and neighborhood-level factors on urban diabetes and asthma. Health & place, 58, 102119.
- Çelik, M. (2009). Veri madenciliğinde kullanılan sınıflandırma yöntemleri ve bir uygulama. İstanbul Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı Yüksek Lisans Tezi
- Fayyad, U., Piatetsky-Shapiro, G. Ve Smyth, P. (1996). Knowledge Discovery and Data Mining: Towards a Unifying Framework, Sayfa:3.
- Güler, Ç. ve Çobanoğlu, Z. (1994). Dış Ortam Hava Kirlenmesi, Erişim:27 Aralık 2019 <https://sbu.saglik.gov.tr/Ekutuphane/kitaplar/css8.pdf>

- Jothishankar, M. C., Wu, T., Johnie Roberts ve Shiau, J-Y (2004). Case Study: Applying data mining to defect diagnosis, Cilt: 6, No:1, Sayfa:71.
- Kılınç, M., Bardak, S. ve Bardak, T. Çevre kirliliği bilincinin fp-growth analizi ile değerlendirilmesi: Sinop ili örneği, Gece Kitaplığı, 2022.
- Lezki, Ş., Er, F. (2010). Tatil yeri kararının verilmesinde karar ağacı ve etki diyagramının uygulanması, Anatolia: Turizm Araştırmaları Dergisi, 21(2), 233-242.
- Naik, A. and Samant, L. Correlation review of classification algorithm using data mining tool: weka, rapidminer, tanagra, orange and knime, Procedia Computer Science, vol. 85 pp. 662–668, 2016.
- Oğuzlar, A. (2003). Veri ön işleme, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Sayı: 21, Temmuz-Aralık 2003, Sayfa:69-75.
- Özeker, Ö.(2003). Veri Madenciliği Modelleri ve Uygulama Alanları, İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, Cilt:2, Sayı :3, Sayfa:65-82.
- Ristoski, P., Bizer, C. and Paulheim, H. Mining the web of linked data with RapidMiner, Journal of Web Semantics, vol. 35, pp. 142–51, 2015.
- TMMOB Çevre Mühendisleri Odası (2018). Hava Kirliliği Raporu, 2019;https://www.cmo.org.tr/resimler/ekler/a59522dfa35972d_ek.pdf?tipi=72&turu=X&sube=0
- TozluMikrofon Hava Kirliliği (Londra Tipi ve Los Angeles Tipi) Nedir? Nasıl Azaltılabilir?, 2018; <https://www.tozlumikrofon.com/hava-kirliligi-londra-tipi-ve-los-angeles-tipi-nedir-nasil-azaltilabilir/>
- Udayakumar, S., Senadeera, D. C., Yamunarani, S., & Cheon, N. J. (2018). Demographics analysis of twitter users who tweeted on psychological articles and tweets analysis. Procedia computer science, 144, 96-104.
- Westpal, C. ve Blaxton, T. (1998). data mining solutions methods and tools for solving real-world problems, Sayfa:14.

Bölüm 6

YAPAY ZEKA ALANINDA DİKKAT MEKANİZMASI MODELLERİ İLE GÖRSEL ALTYAZILAMA

İsa ATAŞ¹

¹ Dr. Öğr. Üyesi; Dicle Üniversitesi, Diyarbakır Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü. ORCID No: 0000-0003-4094-9598

I. GİRİŞ

Gelişmiş görüntü tanımlama ve algılama modelleri, yakın zamanda otonom araçlarının hareket kabiliyetlerine veya görme engelli kişilerin dünyayı görmesine yardımcı olabilir. Görsel altyazılama, yapay zekâ alanında çalışan birçok araştırmacıyı kendine çektiği için bilgisayarlı görüşün en önemli konularından biri haline gelmiştir. (Pedersoli vd. 2017; Tavakoli vd. 2017; Zhang vd. 2020). Başlangıçta görüntü tanıma ve üretme yöntemleri, görüntülerde bulunan statik nesne sınıflarını kütüphaneler aracılığıyla tespit ederek görüntü bilgilerini toplar, toplanan bilgiler istatistiksel dil modelleri kullanılarak modellenirdi (Aker vd. 2010). Daha sonraları bir görüntüdeki nesnelere, nitelikleri ve ilişkileri çıkarmak ve bunları bir dizi anlamsal analizler yapıp görsellere dönüştürmek ve ardından bu yapılar için metin açıklamaları oluşturmak üzere dilbilgisini öğrenmeye yönelik üç boyutlu görsel analiz sistemi kullandı (Lin vd. 2015). Yakın zamana kadar yapılan ve açıklanan yöntemler kendi özelliklerine sahiptir. Bundan dolayı hepsinin ortak dezavantajı, görüntüdeki nesnelere veya eylemler üzerinde sezgisel özellik gözlemleri yapmamaları veya görüntüye uçtan uca olgun bir genel model vermemeleridir. Bu yazıda bilgisayarlı görme ve doğal dil işlemeyi birleştirerek görüntü altyazısı için dikkat mekanizması yöntemleri incelenmiştir.

II. DİKKAT MEKANİZMALARININ TEMELLERİ

Dikkat mekanizmalarını etkili bir şekilde kavrayıp anlamak için bir görüntü sahnesinin veya **bağlamın** (mevcut durumu temsil eden bir vektör) belirli öğelerine seçici odaklanmanın yapıldığı insan bilişsel sürecinin bilinmesi gerekir. İnsandan esinlenerek yapılan bu algoritmaların özünde dikkat mekanizmaları yani makinelerin altyazı oluştururken görüntünün ilgili bölümlere odaklanmayı sağlayan teknikler bulunmaktadır.

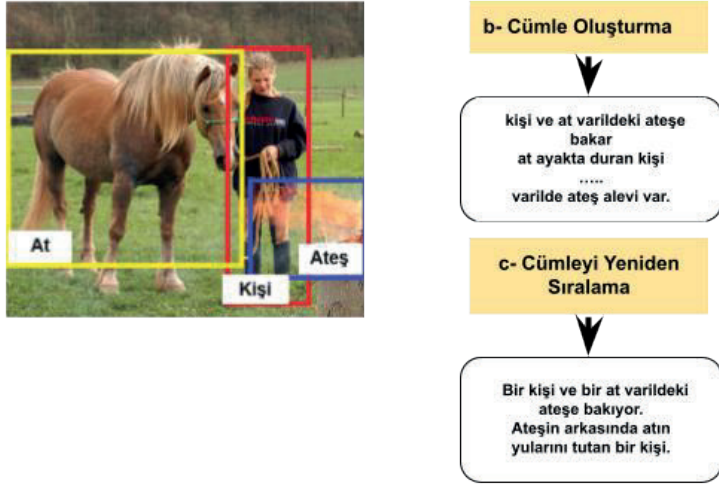
ÖZELLİK ÇIKARMA YÖNTEMLERİ

Görüntü altyazılama modeli iki temel bölümde incelenir: 1. Görüntüden manuel özellikleri oluşturmak için istatistiksel olasılık dili modelini temel

alan bir yöntem. 2. Görüntüden otomatik derin özellikleri çıkarmak için kodlayıcı-kod çözücü dil modelini temel alan bir sinir ağı yöntemi.

1. İstatiksel Dil Modeli

Şekil 1'de gösterilen bu yöntem görsel algılama ve dil modelini doğrudan görüntü tanımlama veri kümesinden öğrenen, önce görüntüyü analiz ederek nesneyi tespit eden ve ardından bir başlık oluşturan maksimum olasılık tahminine dayanır (Fang vd. 2015). Olası kelimeler, görüntü alanına bir Evrişimli Sinir Ağ (ESA) uygulayarak tespit edilir. Daha sonra cümle yapısı, önsel varsayımları en aza indirmek için doğrudan başlıklar ile eğitilir. Son olarak görüntü altyazısı oluşturma problemini bir optimizasyon problemine dönüştürerek en olası cümlenin çıkarılması beklenir.

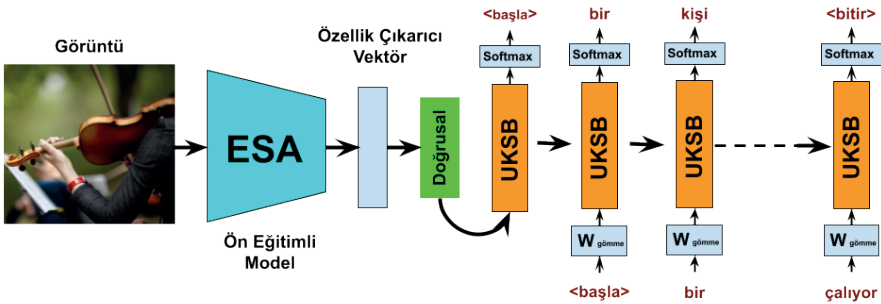


Şekil 1. Görsel Algılama ve Dil Modeli (Flickr8k Dataset)

2. Sinir Ağ ile Derin Öğrenme Modeli

Başlangıçta doğal dil işleme alanında yaygın olarak kullanılan ve dil modellemede iyi sonuçlar elde edilen Tekrarlayan Sinir Ağ (TSA) (Razvan vd. 2014) derin öğrenme alanında büyük ilgi görmüştür (Mikolov vd. 2010). Konuşma alanında TSA, metni ve konuşmayı birbirine dönüştürmekle birlikte karakter ve kelime düzeyinde güçlü dil modelleri olarak kullanılır.

TSA'nın yaygınlaşmasıyla birlikte kodlayıcı-kod çözücü modelini temel alan görüntü tanımlama üretme yöntemi önerilmiştir (Wu vd. 2016). TSA modelinin eğitimi zor (Pascanu vd. 2012) ve genel bir gradyan iniş sorunu mevcut olduğundan, gradyan kaybolması gibi sorunları çözebilen, Uzun Kısa Süreli Belleğe (UKSB) (Andrej vd. 2015) sahip özel bir TSA mimarisi geliştirilmiştir. Şekil 2'de kodlayıcı-kod çözücü temel alan UKSB modeli gösterilmiştir.



Şekil 2. kodlayıcı-kod çözücü temel alan UKSB modeli (Ataş, 2023)

UKSB modelinin sorunu, modelin resim yazısının bir sonraki kelimesini oluşturmaya çalıştığı sırada bu kelimenin genellikle görüntünün yalnızca bir bölümünü tanımlamasıdır. Her kelimenin oluşturulmasını koşullandırmak için görüntünün tüm temsilinin (h) kullanılması, görüntünün farklı bölümleri için farklı sözcüklerin verimli bir şekilde üretilmesini sağlayamaz. İşte tam da bu noktada dikkat mekanizması yardımcı olur.

Bir dikkat mekanizmasıyla görüntü ilk önce n parçaya bölünür ve her parça h_1, \dots, h_n bir ESA temsilleriyle hesaplanır. TSA yeni bir kelime ürettiğinde dikkat mekanizması görüntünün ilgili kısmına odaklanır, böylece kod çözücü görüntünün yalnızca belirli kısımlarını kullanır.

III. DİKKAT MEKANİZMASI MODELLERİ

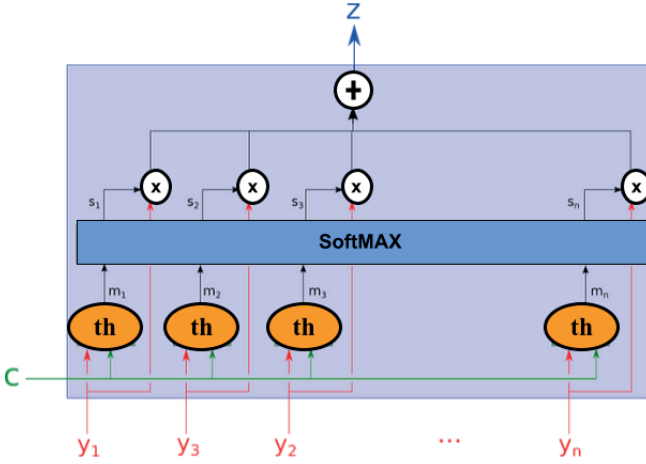
Dikkat mekanizması, bilişsel nörolojide insanın doğasında sahip olduğu karmaşık bir bilişsel yetenektir. Bu durum, bilinçli olarak ana bilgilerin bir veya birkaçına odaklanırken diğer ikincil bilgileri göz ardı edebilir. Yapılan kendini seçme yeteneğine **dikkat** denir. **Dikkat mekanizması** ise, ilgili olanlara odaklanma, geri kalan şeyleri filtreleme veya yok sayma temeline dayanır.

Dikkat mekanizması, özellikle yapay sinir ağlarında ve derin öğrenme modellerinde kullanılır. Bu mekanizma, bir modelin girdi verileri içindeki önemli özelliklere odaklanmasına ve bu özelliklere daha fazla ağırlık vermesine izin verir. Çoğunlukla dil işleme ve görüntü işleme gibi alanlarda tercih edilmektedir. Bu mekanizma ilk olarak TSA modeli üzerinde kullanılarak görsel imgeler alanında görüntü sınıflandırmasına uygulanmıştır (Mnih vd. 2014). Dikkat mekanizması üzerine yapılan; soyut oluşturma (Alexander vd. 2015) metin anlama (Kadlec vd. 2016), metin sınıflandırma (Yang vd. 2016) ve görsel altyazı (Song vd. 2018) gibi çalışmalarda uygulanabilirliği kanıtlanmıştır.

Bu bölümde dikkat mekanizması modelleri ayrıntılı olarak anlatılacaktır.

1. Yumuşak Dikkat Modeli (Belirleyici)

(Dzmitry vd. 2014) tarafından önerilen ve makine çevirisine uygulanan bir modeldir. N adet y_1, \dots, y_n parametrelerini (UKSB modelinde h_i olarak indisenen) ve c bağlamını alan bir yöntem olarak tanımlanır. c bağlamıyla bağlantılı bilgilere odaklanarak y_i 'nin "özeti" olduğu varsayılan bir z vektörünü döndürür. Şekil 3'te Yumuşak Dikkat Modeli gösterilmiştir.



Şekil 3. Yumuşak Dikkat Modeli (Medium)

Şekil 3'te verilen Yumuşak Dikkat Modelinde girişte c 'nin bağlam olduğunu ve y_i 'nin de verilen metnin bir parçası olduğunu biliyoruz.

Bir sonraki adımda ağ y_1, \dots, y_n değerini \tanh (th) katmanı ile hesaplar. Bu, y_i ve c değerlerinin toplamının \tanh ile hesapladığımız anlamına gelir. y_i 'nin her bir indisi bağımsız olarak hesaplanır. Denklem (1)'de başlangıç katman formülü verilmiştir.

$$m_i = \tanh (W_{cm}c + W_{ym}y_i) \quad (1)$$

Daha sonra her ağırlığı (s_i) bir softmax kullanarak hesaplanır. Softmax, adından da anlaşılacağı gibi, neredeyse bir argmax gibi davranır ancak türevlenebilirdir.

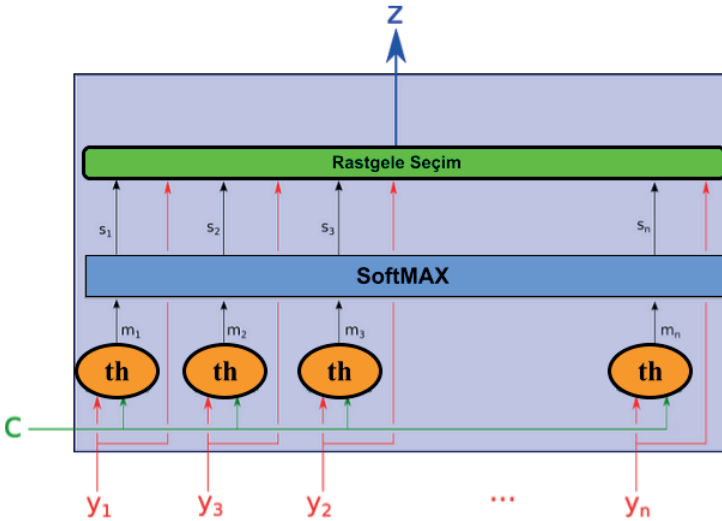
Burada s_i öğrenilmiş bir yönde yansıtılan m_i 'nin softmax'ıdır. Çıktı z , tüm y_i 'nin ağırlıklı aritmetik ortalamasıdır; burada ağırlık, c bağlamına göre her değişkenin alaka düzeyini temsil eder. Denklem (2)'de yumuşak dikkat modelinin çıkış aritmetik ortalama formülü verilmiştir.

$$z = \sum_i s_i i y_i \quad (2)$$

Yumuşak dikkat modeli, öğrenilmiş ağırlıkları ve dönüşümleri kullanarak bir girdi dizisini analiz eder ve her bir girdiye ağırlıklar atar. Bu ağırlıklar, ne kadar "dikkat" edileceğini belirler ve daha sonra bu ağırlıkların ağırlıklı toplamını kullanarak bir çıktı üretir. Yani, dikkatin neye odaklanması gerektiğini belirlemek için bir ağırlık dağılımı kullanılır.

2. Yoğun Dikkat Modeli (Olasılık)

Yoğun dikkat olasık tahminine dayalı bir modeldir. Tüm bölgelerin ağırlıklı toplamını hesaplamaya odaklanan yumuşak dikkat mekanizmasının aksine, yoğun dikkat yalnızca tek bir konuma odaklanır ve benzersiz bir konumun rastgele seçilmesi sürecidir. Bundan dolayı kod çözme için girdi olarak tüm gizli durumları kullanmak yerine, sistem s_i olasılıklarıyla gizli bir durumu (y_i) örnekler (Xu vd. 2015). Şekil 4'te Yoğun Dikkat Modeli gösterilmiştir. Bu süreç boyunca bir gradyanı yaymak için, gradyanı Monte Carlo örnekleme ile tahmin eder. Denklem (3)'de yoğun dikkat modelinin çıkış formülü verilmiştir.



Şekil 4. Yoğun Dikkat Modeli (Medium)

$$z_i = \sum_i s_i \cdot i \alpha_i \quad (3)$$

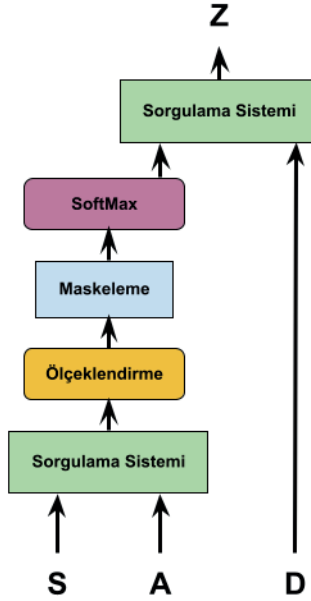
Yoğun dikkatte, bir cümlenin veya bir görüntüdeki parçanın her bir parçası ya bağlam vektörünü elde etmek için kullanılır ya da atılır. Bu durumda (α, i) kullanılan parçanın/yamanın olasılığını temsil eder. Yoğun dikkat modelinin dezavantajı, bilginin maksimum örnekleme veya rastgele örnekleme yöntemine göre seçilmesidir. Bu nedenle son kayıp fonksiyonu ile dikkat dağılımı arasındaki fonksiyonel ilişkiye ulaşamaz ve geri yayılım algoritmasındaki eğitim kullanılamaz. Genelde olasılık yerine belirleyici hesaplanabildiği için tercih yumuşak dikkat mekanizma yönündedir.

3. Ölçeklendirilmiş Nokta Çarpım Dikkat Modeli

Ölçeklendirilmiş nokta-çarpım dikkati (Vaswani vd. 2017) \mathbf{S} (sorgu), \mathbf{A} (anahtar) ve \mathbf{D} (değer) matrislerini kullanarak tek bir dikkat işlevini gerçekleştirir. Denklem (4)'de dikkat mekanizması formülü verilmiştir.

$$Dikkat(S, A, D) = \text{softMAX}\left(\frac{SA^T}{\sqrt{d_A}}\right)D = Z \quad (4)$$

Tek bir gizli katmana sahip ileri beslemeli bir ağ kullanılarak uyumluluk işlevine daha fazla dikkat edilir. Uygulamada, ölçeği küçültülmüş nokta çarpımı, çok başlı dikkat mekanizmasından daha hızlıdır ve alan açısından daha verimlidir çünkü yüksek derecede optimize edilmiş bir matris çarpım kodu (Sorgulama Sistemi) kullanılarak uygulanabilmektedir. Şekil 5'te ölçeklendirilmiş nokta çarpım modeli gösterilmiştir.



Şekil 5. Ölçeklendirilmiş Nokta Çarpım Modeli

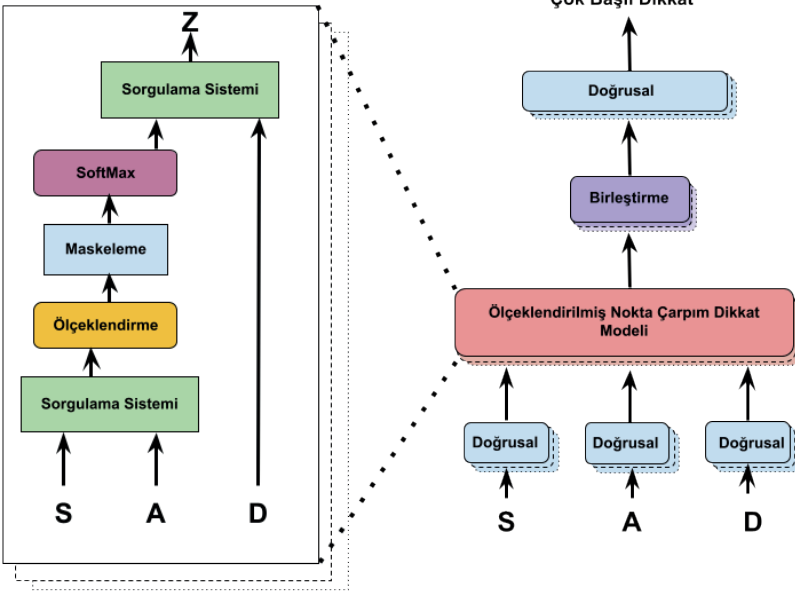
4. Çok Başlı Dikkat Modeli

Çok başlı dikkat mekanizması, doğrusal aktarım için paralel olarak girdi bilgilerinden seçilen çok sayıda veriyi hesaplamak için birden fazla **S**(sorgu), **A**(anahtar) ve **D**(değer) kullanır. Denklem (5) ve Denklem (6) da çok başlı dikkat mekanizması formülü verilmiştir.

$$\text{ÇokBaşlı}(SAD) = \text{Birleştirme}(Baş_1, Baş_2, \dots, Baş_N)W^O \quad (5)$$

$$Baş_i = \text{Dikkat}(SW_i^S, AW_i^A, DW_i^D) \quad (6)$$

Şekil 6'da gösterilen çok başlı dikkat mekanizması, çıktı değerlerini oluşturmak için girdi bilgisinin farklı bölümlerine odaklanır ve son olarak bu çıktı değerleri nihai değeri üretmek için birleştirilir ve yeniden doğrusal şekilde yansıtılır (Vaswani vd. 2017).



Şekil 6. Çok Başlı Dikkat Modeli


5. Genel Dikkat Modeli

Genel dikkat modelinin ana fikri tüm kodlayıcıların gizli katman durumunu dikkate almasıdır (Thang vd. 2015). Geçerli kod çözücü, gizli katman durumunu her kodlayıcının gizli katman durumuyla karşılaştırarak dikkat ağırlık dağılımını elde eder. Genel dikkat modeli yumuşak dikkat modeline benzer. Kod çözme sürecinde, her **zaman** adımının kodlamadaki her kelimenin dikkat ağırlığını hesaplar ve ardından **bağlam** vektörünü ağırlıklandırır. Genel dikkat modeli Şekil 7'de gösterilmiştir. Her kod çözücü durumunu hesaplarken tüm kodlayıcı girişlerine odaklanmayı seçtiğinden hesaplama miktarı nispeten büyüktür.

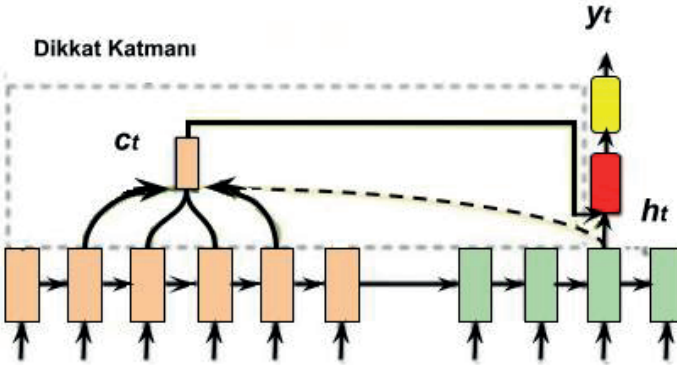
6. Yerel Dikkat Modeli

Yerel dikkat modelinin ana fikri ise önce bir hizalama konumu bulur ve ardından konumunun bulunduğu sol ve sağ pencerelerdeki dikkat ağırlığını hesaplar ve son olarak bağlam vektörünü ağırlıklandırır (Thang vd.

2015). Burada yapılan yol yumuşak ve yoğun arasında karışık bir uzlaşmadır. Yerel dikkatin temel avantajı dikkat mekanizması hesaplamasının maliyetini azaltmaktır. Ayrıca kaynak dil tarafındaki tüm kelimeleri dikkate almayarak, bir tahmin fonksiyonuna göre mevcut kod çözmede hizalanacak kaynak dil ucunun konumunu tahmin eder ve ardından bağlam penceresinde gezinir. Yerel dikkat modeli Şekil 8'de gösterilmiştir.



Şekil 7. Genel Dikkat Modeli (EazyLearn)



Şekil 8. Yerel Dikkat Modeli (EazyLearn)

IV. SONUÇ

Bu yazıda, görüntü alt yazısı oluşturma görevinde son yıllarda önerilen model çerçeveleri arasında farklı dikkat mekanizmalarının yapısal yönüne odaklanarak nasıl uygulandığını özetledik. Dikkat mekanizmasının (soyut oluşturma, metin anlama, metin sınıflandırma ve görsel altyazı gibi) yapılan çalışmalarda uygulanabilirliği kanıtlanmıştır. Fakat temel olarak bu dikkat modellerinde bazı zorluklarda mevcuttur. Bunlardan birincisi, insan gibi tam doğal dil cümlelerinin nasıl oluşturulacağı; ikincisi, oluşturulan cümlelerin dilbilgisi açısından nasıl doğru hale getirileceği; üçüncüsü, önceden hazırlanan altyazılarının mümkün olduğunca net ve verilen görsel içeriğiyle tutarlı hale gelme zorluğudur. Bu sorunlara karşı gelecekte modeller üzerinde bazı değişiklikler yapılarak iyileştirmeler olabilir; örneğin zengin içeriğe sahip örnek görüntülerde sadece tek bir hedef nesneyi tanımlamak yerine birden çok hedef nesneye sahip görüntüler için daha fazla ana nesneye karşılık gelen alt yazı açıklama cümleleri örneklendirilebilir.

KAYNAKÇA

- Aker, A. & Gaizauskas R. (2010). “Bağımlılık ilişkisel kalıplarını kullanarak görüntü açıklamaları oluşturmak,” *Hesaplama Dilbilim Derneği'nin 48. Yıllık Toplantısı Bildirileri*, cilt. 49, hayır. 9, s. 1250–1258, Uppsala, İsveç.
- Andrej, K., Johnson, J. & Li, F. F. (2015). “Tekrarlayan ağların görselleştirilmesi ve anlaşılması”, <http://arxiv.org/abs/1506.02078>.
- Ataş, İ. (2023). “CNN ve LSTM ile Görüntü Yazısı Oluşturucu.” *9. Disiplinler Arası Araştırma ve Uygulamalarda Gelişen Trendler Hakkında Uluslararası Konferans*, s. 61-70, 1-3 Ekim 2023 Manhattan, New York City.
- ISBN: 978-1-955094-52-8.**
- Dzmitry, B., Cho K. & Bengio, Y. (2014). “Hızlamayı ve tercüme etmeyi ortaklaşa öğrenerek sinirsel makine çevirisi”, <http://arxiv.org/abs/1409.0473> Bilgisayar Bilimi.
- Fang, H., Gupta, S., Iandola, F. & diğerleri, (2015). "Altyazılardan görsel kavramlara geçiş", *IEEE Bilgisayarla Görme ve Örüntü Tanıma Konferansı Bildirileri*, Boston, MA, ABD.
- Kadlec, R., Schmid, M., Bajgar, O. & Kleindienst, J. (2016). "Dikkat toplamı okuyucu ağıyla metin anlayışı", *Uluslararası Öğrenme Temsilleri Konferansı Bildirileri*, San Juan, Porto Riko.
- Lin, D., Kong, C., Fidler, S. & Urtasun, R. (2015). “İç mekan sahnelerinin çok cümleli dilsel açıklamalarının oluşturulması”, s. 2333–9721, <http://arxiv.org/abs/1503.00064> Bilgisayar Bilimi.
- Mikolov, T., Karafiat, M. & Burget, L. (2010). “Honza” Cernocky ve S. Khudanpur, “Tekrarlayan sinir ağı tabanlı dil modeli”, *Uluslararası Konuşma İletişimi Derneği Onbirinci Yıllık Konferansı Bildirilerinde*, DBLP, s. 1045–1048, Chiba, Japonya.
- Minh-Thang, L., Pham, H. & Manning, C.D. (2015). "Dikkat temelli sinirsel makine çevirisine etkili yaklaşımlar", *Doğal Dil İşlemede Ampirik Yöntemler Konferansı Bildirileri*, Lizbon, Portekiz.
- Mnih, V., Heess, N. & Graves, A. (2014). “Görsel dikkatin yinelenen modelleri,” *Sinirsel Bilgi İşleme Sistemlerindeki Gelişmeler*, cilt. 3, s. 2204–2212.
- Pascanu, R. Mikolov, T. & Bengio, Y. (2012). “Tekrarlayan sinir ağlarının eğitiminin zorluğu üzerine,” *Uluslararası Makine Öğrenimi Konferansı*, cilt. 52, hayır. 3, s. 1310–1318.

- Pedersoli, M., Lucas, T., Schmid, C. & Verbeek, J. (2017). "Görüntü altyazılama için ilgi alanları", *IEEE Uluslararası Bilgisayarlı Görme Konferansı Bildirileri*, s. 1251–1259, Venedik, İtalya.
- Razvan, P., Çağlar, G., Cho, K. & Yoshua, B. (2014). "Derin tekrarlayan sinir ağları nasıl inşa edilir?", <http://arxiv.org/abs/1312.6026> Bilgisayar Bilimi.
- Rush Alexander, M., Chopra, S. & Weston, J. (2015). "Soyutlayıcı cümle özetlemesi için sinirsel dikkat modeli", *Doğal Dil İşlemede Ampirik Yöntemler Konferansı Bildirileri*, Lizbon, Portekiz.
- Song, J., Li, X., Gao, L. & Shen, H. (2018). "Görsel altyazı için uyarlanabilir dikkat içeren hiyerarşik LSTM'ler", <http://arxiv.org/abs/1812.11004>.
- Tavakoli, H. R., Shetty, R., Ali, B. & Laaksonen, J. (2017). "Görüntü altyazı modellerinin oluşturduğu açıklamalara dikkat etme", *IEEE Uluslararası Bilgisayarlı Görme Konferansı Bildirileri*, s. 2506–2515, Venedik, İtalya.
- Vaswani, A. Shazeer, N. Parmar, N. & diğerleri (2017). "İhtiyacınız olan tek şey dikkattir", *Proceedings of the Neural Information Processing Systems*, Long Beach, CA, ABD.
- Xu, K., Ba, J., Ryan, K. & diğerleri, (2015). "Gösterin, katılın ve anlatın: görsel dikkatle sinirsel resim yazısı oluşturma", *IEEE Bilgisayarlı Görme ve Örüntü Tanıma Konferansı Bildirileri*, s. 2048–2057, Boston, MA, ABD.
- Yang, Z., Yang, D., Dyer, C., He, X., Alex, S. & Hovy, E. (2016). "Belge sınıflandırması için hiyerarşik dikkat ağları", *Hesaplamalı Dilbilim Derneği Kuzey Amerika Bölümü 2016 Konferansı Bildirilerinde: Human Language Technologies*, s. 1480–1489, San Diego, CA, ABD.
- Wang, H., Zhang, Y. & Yu, X. (2020). "Görüntü Altyazısı Oluşturma Yöntemlerine Genel Bakış", *Hesaplamalı Zeka ve Sinirbilim*, Makale Kimliği 3062706, 13 sayfa.
- Wu, Z., Wang, X., Jiang, Y. G., Ye, H. & Xue, X. (2016). "Video sınıflandırması için derin ağların çoklu akışlı çok sınıflı birleşimi", *2016 ACM Multimedya Konferansı Bildirileri*, s. 791–800, Amsterdam, Hollanda.

<https://github.com/jbrownlee/Datasets/releases/download/Flickr8k>

<https://medium.com/heuritech/attention-mechanism-5aba9a2d4727>.

<https://www.eazylearn.in/>

Bölüm 7

**COVID-19'UN YAYILIM TAHMİNİNE
YÖNELİK LSTM TABANLI BİR
TAHMİN MODELİ: G4 ÜLKELERİ İÇİN
ÖRNEK BİR ÇALIŞMA**

Anıl UTKU¹

1. GİRİŞ

Almanya, Brezilya, Hindistan ve Japonya'yı içeren G4 ülkeleri, uluslararası bir koalisyonudur ve Birleşmiş Milletler Güvenlik Konseyi'nde (BMGK) kalıcı üyeliğin savunulması amacıyla kurulmuştur [1]. G4 koalisyonu, BMGK'da daha demokratik bir karar alma sürecinin sağlanmasını amaçlamaktadır [2]. G4 ülkeleri, uluslararası sorunların çözümüne yönelik katkılar sunmayı amaçlamaktadır [3, 4]. COVID-19, dünya çapında hızlı bir şekilde yayılarak ciddi bir küresel sağlık krizine neden olmuştur [5]. COVID-19, ülkelerin sağlık sistemlerini ve ekonomilerini oldukça kötü etkilemiştir [6]. Bu sebeple, COVID-19 gibi küresel ölçekteki salgınlarla başa çıkmak ve kontrol altına almak için uluslararası işbirlikleri önemlidir. COVID-19'un yayılmasını önlemek amacıyla aşı çalışmaları, maske, mesafe ve kişisel hijyen gibi temel önlemler, dünya çapında uygulanmıştır [7, 8].

COVID-19 salgını, Yapay Zekâ (YZ) yöntemlerinin sağlık alanındaki uygulamalarının önemini ortaya koymuştur. YZ teknolojilerinin, sağlık alanındaki uygulamaları, salgının yönetimi, stratejiler geliştirilmesi ve salgın kontrolü için önemlidir. YZ teknolojileri, salgının yayılma örüntüsünü belirlemek, vaka sayısı tahminleri oluşturmak ve hastalık teşhisi gibi uygulama alanlarında kullanılmıştır [9, 10].

G4 ülkeleri, sahip oldukları nüfus yoğunluğu sebebiyle COVID-19 salgınından olumsuz etkilenmiş ve salgın bir her ülkede farklı yayılma örüntüleri göstermiştir. Bu çalışmanın motivasyonu, ülke yönetimlerine sağlık hizmetlerine konusunda salgının gelecekteki seyrinin belirlenmesine yönelik bir tahmin modeli oluşturmaktır. YZ teknikleri yardımıyla günlük vaka ve ölüm sayılarını tahmin edilerek sağlık hizmetlerinin optimize edilmesi, risk gruplarının belirlenmesi ve stratejik planlamalar yapılması sağlanabilir.

Bu çalışmada, G4 ülkelerindeki günlük COVID-19'un vaka ve ölüm sayılarını tahmin etmek amacıyla Long Short-Term Memory (LSTM) tabanlı bir tahmin modeli geliştirilmiştir. Geliştirilen model, Linear Regresyon (LR), Random Forest (RF), Support Vector Machine (SVM), Multilayer Perceptron (MLP), Convolutional Neural Network (CNN) ve Recurrent Neural Network (RNN) ile uygulamalı olarak karşılaştırılmıştır.

Bu bölümün devamında, literatürdeki çalışmaların sonuçları ve bu alandaki önemli gelişmeler incelenmiştir.

Cheng ve ark., yoğun bakım ünitesindeki COVID-19 hastalarının hastane içi ölüm riskini tahmin etmek için göğüs röntgeni görüntüleri ve klinik verilerden yararlanmışlardır [11]. Klinik değişkenlere dayalı ölüm tahmini için çok katmanlı bir derin öğrenme modeli kullanılmıştır. Klinik özneliklerin önem derecelerinin belirlenmesi için RF kullanılmıştır. Göğüs röntgeni görüntülerinin sınıflandırılması için ResNet50 kullanılmıştır. Birleşik ölüm tahmin modeli, ResNet50 modeli ile klinik modelin ağırlıklı toplamından türetilmektedir. Deneysel sonuçlar, geliştirilen modelin 0.732 doğruluk değerine sahip olduğunu göstermiştir.

Alassafi ve ark., COVID-19 salgınının Fas, Malezya ve Suudi Arabistan'daki yayılımının tahmin edilmesine yönelik RNN ve LSTM'in karşılaştırmalı bir analizini sunmuştur [12]. Deneysel sonuçlar, LSTM'in %98,58, RNN'in ise %93,45 hassasiyet değerine sahip olduğunu göstermiştir.

Xu ve ark., Brezilya, Hindistan ve Rusya'da COVID-19 vakalarının sayısını tahmin etmek amacıyla CNN, LSTM ve CNN-LSTM'in karşılaştırmalı bir analizini sunmuştur [13]. Deneysel sonuçlar, CNN-LSTM modelinin Hindistan ve Rusya için başarılı olduğunu, LSTM'in ise Brezilya için başarılı olduğunu göstermiştir. LSTM ve CNN-LSTM modelleri için R Squared (R^2) değerinin, özellikle Hindistan ve Rusya için toplam vaka sayısı tahmini açısından yüksek olduğu görülmüştür.

Akter ve ark., Alzheimer hastalarının COVID-19 kaynaklı ölümlerinin tahminine yönelik LSTM ve MLP modellerini kullanarak hibrit bir derin öğrenme modeli geliştirmiştir [14]. Geliştirilen model, üç farklı veriseti üzerinde test edilmiştir. AdaBoost, XGBoost ve RF modelleri kullanılarak yapılan karşılaştırmalı analizler, geliştirilen modelin daha başarılı olduğunu göstermiştir. Deneysel sonuçlar, geliştirilen modelin ilk iki verisetinde %97, üçüncü verisetinde ise %86 doğruluk değerine sahip olduğunu göstermiştir.

Nagi ve ark., COVID-19'un teşhisi için göğüs X-ray görüntülerini kullanarak derin öğrenme modellerinin karşılaştırmalı bir analizini sunmuştur [15]. Çalışmada, geliştirilen CNN tabanlı model, MobilNetV2 ve Xception modeli ile karşılaştırılmıştır. Deneysel sonuçlar, Xception

modelinin %94,2 doğruluk, %99 hassasiyet, %95 duyarlılık ve %97 F1 puanı ile karşılaştırılan modellerden daha başarılı olduğunu göstermiştir.

Paul ve ark., göğüs X-ray görüntülerinden COVID-19 teşhis doğruluğunu arttırmak amacıyla aktarımlı öğrenme kullanmışlardır [16]. ImageNet veri kümesi üzerinde önceden eğitilmiş modelleri kullanılmıştır. Bu modeller daha sonra göğüs X-ray veriseti ile yeniden eğitilmiştir. Önerilen yöntem, COVID-19 Radyografi Veri Tabanı ve IEEE COVID Göğüs X-ray veriseti olmak üzere iki veriseti üzerinde test edilmiştir. Deneysel sonuçlar, önerilen yöntemin her iki verisetinde de %99'un üzerinde doğruluk değerine sahip olduğunu göstermiştir.

Al-Waisy ve ark. göğüs röntgeni görüntülerinde COVID-19'u tespit etmek için hibrit bir model sunmuştur [17]. Çalışmanın amacı göğüs röntgeni gibi görüntüleme yöntemlerini kullanarak COVID-19 tanısına yardımcı olacak bir model geliştirmektir. Kullanılan veriseti pozitif, negatif ve normal göğüs röntgeni görüntülerini içermektedir. Geliştirilen COVID-CheXNet hibrit modelinde, CNN görüntülerden özellik çıkarmak için kullanılırken LVQ, bu özellikleri kullanarak COVID-19 virüsünü tanımlamak için kullanılmaktadır. Deneysel sonuçlar, COVID-CheXNet'in göğüs röntgeni görüntülerinde COVID-19'u etkili bir şekilde tespit ettiğini göstermektedir. Deneysel sonuçlar geliştirilen modelin yüksek doğruluk ve duyarlılığa sahip olduğunu göstermiştir. Ayrıca model, normal ve COVID-19 negatif görüntüleri ayırt edebilme özelliğiyle hatalı pozitif sonuçları en aza indirmektedir.

2. MATERYAL VE METOT

Bu çalışmada, Dünya Sağlık Örgütü (DSÖ) tarafından sağlanan günlük vaka ve ölüm verileri kullanılarak COVID-19 salgınının G4 ülkelerindeki yayılımını tahmin etmek amaçlanmıştır. Bu amaçla, geliştirilen LSTM tabanlı tahmin modelinin deneysel sonuçları, popüler makine öğrenmesi ve derin öğrenme modelleriyle kapsamlı olarak karşılaştırılmıştır.

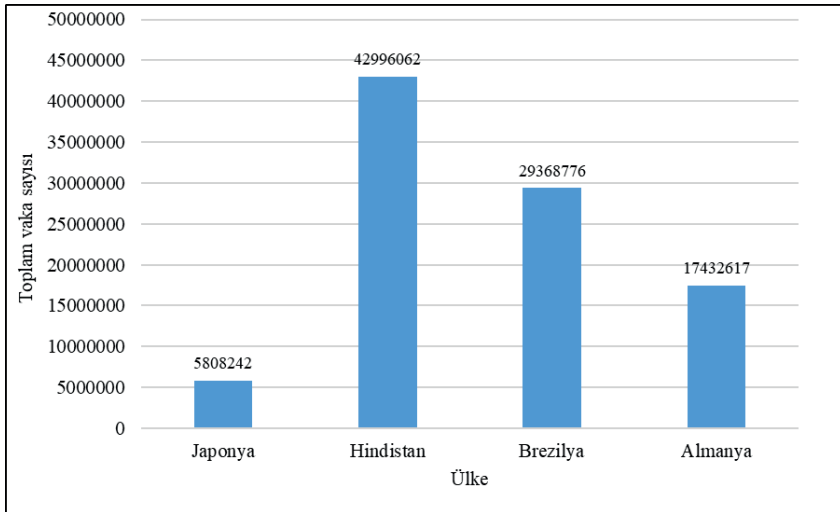
2.1. Veriseti

Bu çalışmada, DSÖ tarafından sağlanan günlük COVID-19 verileri kullanılmıştır. Kullanılan veriseti, COVID-19 salgınının başlangıcından 15

Mart 2022 tarihine kadar olan vaka ve ölüm sayılarıyla ilgili istatistiki bilgileri içermektedir. Verisetinde bulunan öznitelikler aşağıda sunulmuştur.

- `Date_reported`, COVID-19 vakalarının DSÖ'ye bildirildiği tarihi ifade eder.
- `Country_code`, her bir ülke için ISO Alpha-2 ülke kodunu ifade eder.
- `Country`, ülke adını ifade eder.
- `WHO_region`, DSÖ tarafından tanımlanan Afrika Bölgesi (AFRO), Amerika Bölgesi (AMRO), Güneydoğu Asya Bölgesi (SEARO), Avrupa Bölgesi (EURO), Doğu Akdeniz Bölgesi (EMRO) ve Batı Pasifik Bölgesi (WPRO) bölgelerini ifade eder.
- `New_cases`, teyit edilmiş günlük COVID-19 vakalarının sayısını ifade eder.
- `Cumulative_cases`, onaylanmış toplam COVID-19 vakalarını ifade eder.
- `New_deaths`, teyit edilmiş günlük COVID-19 ölümlerinin sayısını ifade eder.
- `Cumulative_deaths`, onaylanmış toplam COVID-19 ölümlerini ifade eder.

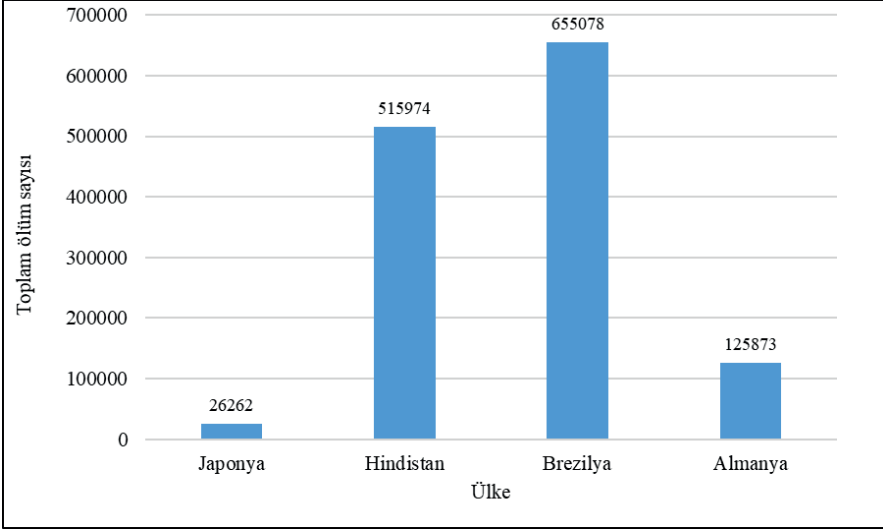
Şekil 1'de G4 ülkeleri için toplam vaka sayıları görülmektedir.



Şekil 1. G4 ülkeleri için toplam vaka sayıları

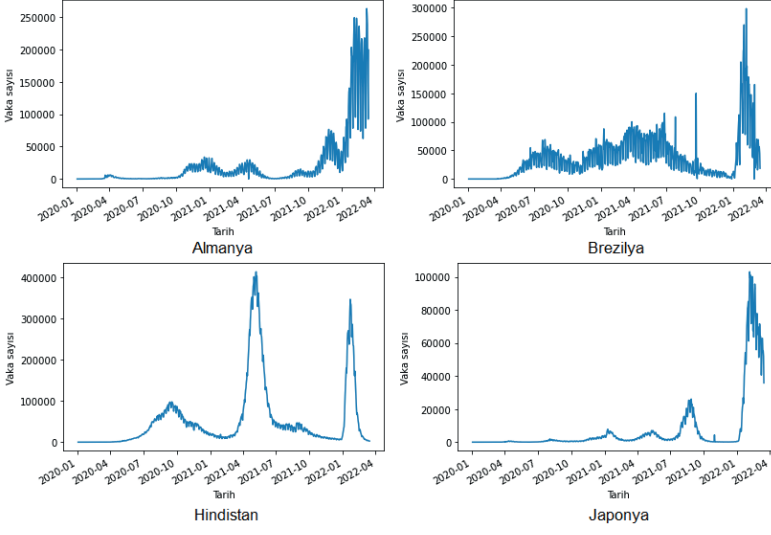
Şekil 1’de görüldüğü gibi Hindistan, 42.996.062 ile en yüksek vaka sayısına sahip ülkedir. Hindistan’ın ardından Brezilya, Almanya ve Japonya en yüksek vaka sayısına sahiptir.

Şekil 2’de G4 ülkeleri için toplam ölüm sayıları görülmektedir.



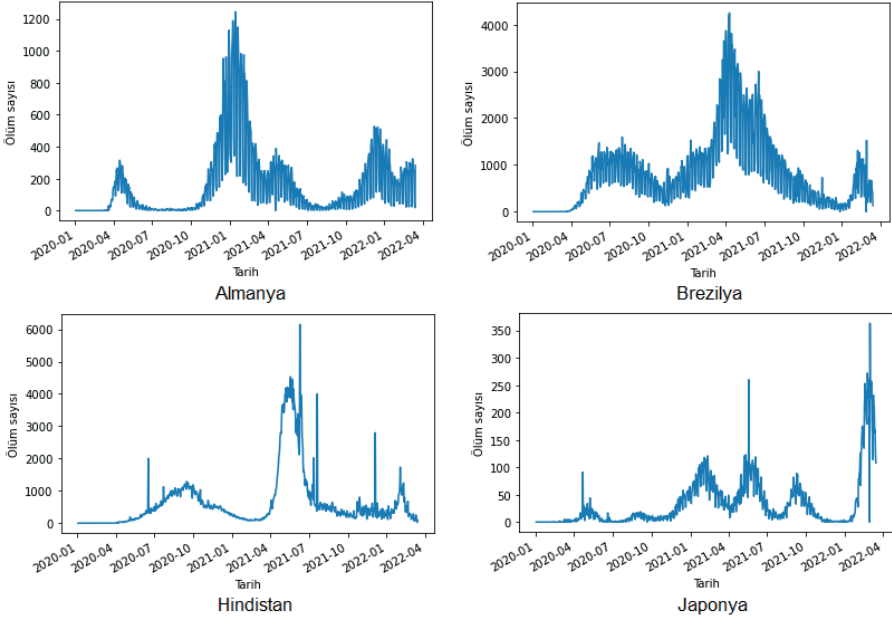
Şekil 2. G4 ülkeleri için toplam ölüm sayıları

Şekil 1’de görüldüğü gibi Brezilya, 655.078 ile en yüksek ölüm sayısına sahip ülkedir. Brezilya’nın ardından Hindistan ve Almanya en yüksek ölüm sayısına sahiptir. Japonya, karşılaştırılan ülkeler arasında en düşük ölüm sayısına sahiptir. Şekil 3’te her bir ülke için vaka sayılarının tarihe göre değişimi görülmektedir.



Şekil 3. Her bir ülke için vaka sayılarının tarihe göre değişimi

Şekil 4'te her bir ülke için ölüm sayılarının tarihe göre değişimi görülmektedir.



Şekil 4. Her bir ülke için ölüm sayılarının tarihe göre değişimi

2.2. Tahmin Modelleri

LR, bağımlı bir değişken ile bir ya da daha fazla bağımsız değişken arasındaki doğrusal ilişkiyi belirleyen bir makine öğrenmesi algoritmasıdır [18]. LR, bağımlı bir değişkenin değerini, bağımsız değişkenleri kullanarak tahmin edebilecek doğrusal bir denklem bulmayı amaçlamaktadır [19].

RF, birden fazla karar ağacına dayalı olarak tahminler üreten bir topluluk öğrenme yöntemidir [20, 21]. RF'da eğitim verisetinden rastgele k veri noktası seçilir ve seçilen veri noktalarına göre bir karar ağacı oluşturulur. Her bir karar ağacı veri noktasının değerini tahmin eder ve elde edilen tahminlerin ortalaması hesaplanır [22].

SVM, verileri uzayda konumlandırarak veriler arasındaki karmaşık sınırları belirleyen bir karar sınıfı oluşturur [23]. Karar sınıfı, destek vektörleri adı verilen veri noktaları tarafından belirlenir ve sınıf sınırlarının en etkin biçimde oluşturulmasını sağlar [24].

Çok katmanlı bir sinir ağı modeli olan MLP, veriler arasındaki karmaşık ilişkileri öğrenme yeteneği ile öne çıkmaktadır [25]. Girdi ve çıktı katmanları arasında bulunan katmanlarda verileri işleyerek sonuç üreten birçok nöron bulunur. Sınıflandırma, regresyon ve görüntü işleme gibi uygulama alanlarında başarılı bir şekilde uygulanmaktadır [26].

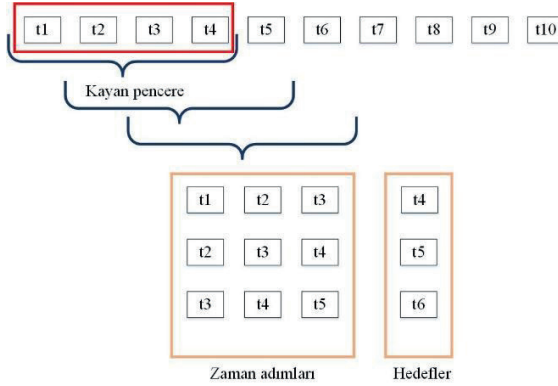
CNN, temel olarak görüntü işleme görevlerinde başarılı olarak kullanılan güçlü bir derin öğrenme modelidir [27]. CNN, verilerin farklı özelliklerinin otomatik olarak öğrenilmesini sağlayan evrişim işlemi yardımıyla özellik çıkarımı yapar [28]. CNN, veriden hiyerarşik olarak öğrenmek ve öğrenme sürecini optimize etmek için evrişim, havuzlama ve tam bağlı katmanları kullanmaktadır.

RNN, sıralı zaman serisi verilerin analizi için geliştirilmiş bir tekrarlı sinir ağı modelidir. RNN, geçmiş zaman adımlarındaki bilgileri saklayarak ve geleceğe dönük tahminler üretebilen bir yapıya sahiptir [29]. RNN, her bir zaman adımındaki girdileri işlerken önceki zaman adımlardan gelen bilgileri hesaba katmaktadır [30]. Ancak, RNN'de yaşanan ve uzun vadeli bağımlılıkları belirlenemesini ifade eden kaybolan gradyan problemine yönelik LSTM ve Gated Recurrent Unit (GRU) modelleri geliştirilmiştir [31].

LSTM, doğal dil işleme, konuşma tanıma ve zaman serisi analizi gibi uygulama alanlarında kullanılan etkili bir modeldir [32]. LSTM, RNN'de yaşanan kaybolan gradyan problemine çözüm olarak geliştirilmiştir. LSTM, geçmiş zaman adımlarındaki bilgilerin etkili bir şekilde saklanmasını ve işlenmesini sağlar [33, 34]. LSTM'in yapısında bulunan kapılar yardımıyla, bilgilerin unutulması, güncellenmesi ve hatırlanması gibi işlemleri başarılı bir şekilde gerçekleştirir.

2.3. Geliştirilen LSTM Tabanlı Derin Öğrenme Modeli

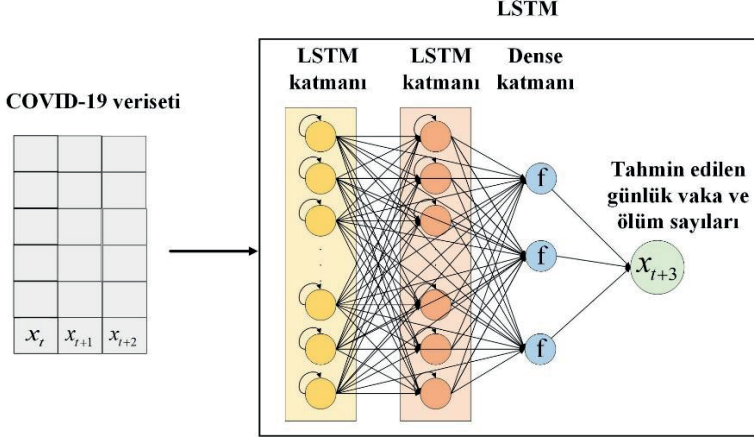
COVID-19 salgını sırasında günlük vaka ve ölüm sayılarını tahmin etmek, salgının yönetimi ve geleceğe dönük stratejilerin geliştirilmesi için oldukça önemlidir. YZ yöntemleri kullanılarak oluşturulacak tahminler, verilerin doğru ve etkili bir şekilde işlenmesiyle doğrudan ilişkilidir. Bu amaçla öncelikle veri ön-işleme işlemleri gerçekleştirilmiştir. Öncelikle verisetindeki eksik ve hatalı veriler kontrol edilmiştir. MinMax normalizasyon kullanılarak veriseti normalize edilmiştir. Modeller verisetine uygulanmadan önce zaman serisi verilerinin, denetimli öğrenme problemine dönüştürülmesi gereklidir. Bu amaçla Şekil 4'te görüldüğü gibi kayan pencere yöntemi kullanılmıştır.



Şekil 4. Kayan pencere yöntemi

Kayan pencere yönteminde her bir pencere, belirli bir süre boyunca gözlemlenen verileri içermektedir. Pencere boyutuna göre girdi değişkenleri ve hedef değişkenler belirlenmektedir. Karşılaştırılan her bir model için en uygun hiperparametrelerin belirlenmesi amacıyla Grid Search kullanılmıştır.

Grid Search, her bir model için farklı hiperparametre kombinasyonlarından en başarılı olanı belirlemeyi amaçlar. Geliştirilen modelin mimarisi Şekil 5'te görülmektedir.



Şekil 5. Geliştirilen LSTM tabanlı model

Geliştirilen model, Şekil 5'te görüldüğü gibi girdi katmanı, LSTM katmanları, dense katmanı ve çıktı katmanından oluşmaktadır. LSTM, ReLu aktivasyon fonksiyonuna sahip 2 farklı katmandan oluşmaktadır. Her bir katman 32 nörondan oluşmaktadır. Model derlenirken optimizasyon fonksiyonu olarak Adam, kayıp fonksiyonu olarak ise MSE kullanılmıştır. Batch size 16 ve epoch 100'dür.

2.4. Performans Değerlendirme Metrikleri

Performans değerlendirme metrikleri, bir tahmin modelinin ne kadar iyi çalıştığını ve tahminlerinin ne kadar doğru olduğunu belirlemek için önemlidir. Bu bölümde, karşılaştırılan modellerin başarılarını değerlendirmek için yaygın olarak kullanılan Root Mean Squared Error (RMSE), Mean Absolute Error (MAE) ve R^2 metrikleri açıklanmıştır.

RMSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasının karekökü alınarak hesaplanır. Bu sayede, hata değerlerinin büyüklüğü ve yönü göz önüne alınarak modelin tahmin yeteneği objektif bir şekilde değerlendirilebilir. RMSE, Eş. 1 kullanılarak hesaplanmaktadır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2} \quad (1)$$

MAE, Eş.2'de görüldüğü gibi tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalama değerini hesaplar.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y - \hat{y}| \quad (2)$$

R^2 , bir tahmin modelinin verilere ne kadar iyi uyduğunu ölçen bir metriktir. Bu metrik, tahmin edilen değerler ile gerçek değerler arasındaki varyansın oranını hesaplar. R^2 değeri, 0 ile 1 arasında bir değer alır ve değeri 1'e ne kadar yakınsa, modelin verilere o kadar iyi uyduğunu gösterir. R^2 , Eş. 3 kullanılarak hesaplanmaktadır.

$$R^2 = 1 - \frac{\sum (y - \hat{y})^2}{(y - \bar{y})^2} \quad (3)$$

3. DENEYSEL SONUÇLAR


Bu çalışmada, COVID-19'un G4 ülkelerindeki yayılımını belirlemek amacıyla LSTM tabanlı bir tahmin modeli geliştirilmiştir. Geliştirilen model, LR, RF, SVM, MLP, CNN ve RNN ile RMSE, MAE ve R^2 metrikleri kullanılarak karşılaştırılmıştır.

Tablo 1'de, vaka sayısının tahminine yönelik deneysel sonuçlar görülmektedir.

Tablo 1. Vaka sayısının tahminine yönelik deneysel sonuçlar

Metrik	Ülke	LR	RF	SVM	MLP	CNN	RNN	LSTM
RMSE	Almanya	16160.40	14807.46	13739.96	6700.11	7572.32	5443.08	4204.10
	Brezilya	33114.81	27308.32	25358.17	13311.55	13428.07	13200.46	12559.79
	Hindistan	11914.65	11053.06	8222.38	7219.76	10843.94	7098.58	6330.89
	Japonya	9948.22	8889.17	4744.30	2857.44	2972.94	2750.28	2400.54
MAE	Almanya	9338.92	8083.65	7948.62	4147.22	4841.33	3385.02	2665.41
	Brezilya	16918.36	14238.06	13490.32	6183.83	6621.44	6624.31	6665.68
	Hindistan	6926.27	6464.93	4617.77	4433.85	5599.91	4110.51	3723.89
	Japonya	5154.78	4304.04	2163.72	1325.17	1484.31	1277.71	1163.88
R ²	Almanya	0.943	0.946	0.959	0.990	0.988	0.993	0.996
	Brezilya	0.612	0.740	0.743	0.938	0.937	0.939	0.945
	Hindistan	0.985	0.985	0.986	0.994	0.986	0.994	0.995
	Japonya	0.861	0.868	0.968	0.988	0.987	0.989	0.991

Tablo 1 ve Şekil 6’da görüldüğü gibi vaka sayısının tahminine yönelik deneysel sonuçlar, geliştirilen LSTM tabanlı modelin karşılaştırılan diğer modellerden daha başarılı olduğunu göstermiştir. LSTM, Almanya, Hindistan ve Japonya için 0.99’un üzerinde R² değerine sahip olmuştur.

Şekil 6. Vaka sayısı tahminine yönelik R² metriğine göre deneysel sonuçlar

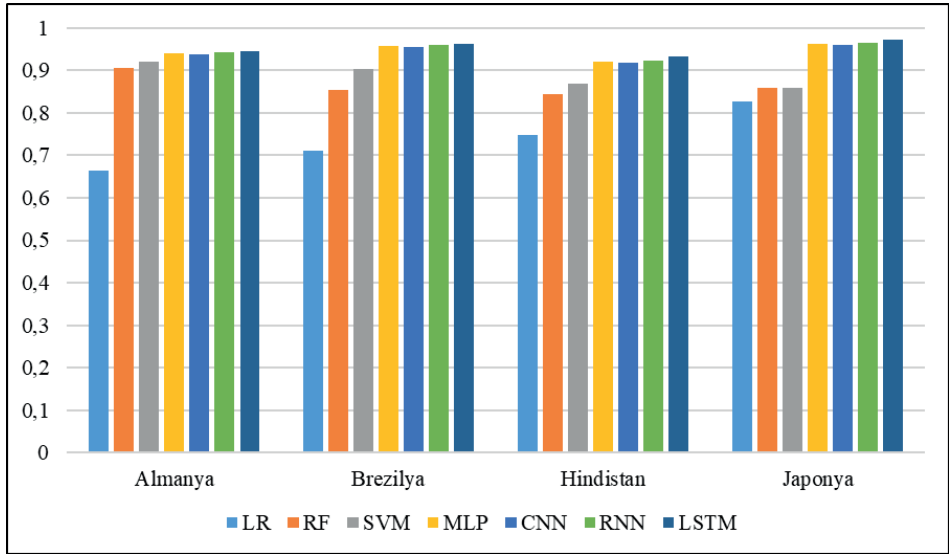
Brezilya için elde edilen R² değeri 0.945’tir. Elde edilen R² değerleri, geliştirilen LSTM tabanlı tahmin modelinin, verilere oldukça iyi uyduğunu göstermektedir. LSTM’in ardından, RNN, MLP, CNN, SVM, RF ve LR sırasıyla başarılı olan modellerdir.

Tablo 2’de, ölüm sayısının tahminine yönelik deneysel sonuçlar görülmektedir.

Tablo 2. Ölüm sayısının tahminine yönelik deneysel sonuçlar

Metrik	Ülke	LR	RF	SVM	MLP	CNN	RNN	LSTM
RMSE	Almanya	78.69	39.55	37.88	32.94	33.46	32.78	31.86
	Brezilya	387.05	208.00	219.94	144.25	149.64	138.41	136.87
	Hindistan	464.34	457.98	431.96	327.44	333.12	322.09	299.28
	Japonya	27.88	24.73	25.37	12.88	13.35	12.39	11.21
MAE	Almanya	52.31	26.97	25.60	21.41	22.39	22.29	21.41
	Brezilya	250.58	141.42	149.09	99.74	100.69	95.42	90.45
	Hindistan	204.46	202.52	206.94	155.05	152.67	154.74	143.04
	Japonya	12.23	11.04	10.64	7.28	8.11	7.18	6.76
R ²	Almanya	0.663	0.905	0.922	0.941	0.939	0.942	0.945
	Brezilya	0.711	0.855	0.903	0.958	0.955	0.961	0.962
	Hindistan	0.747	0.845	0.869	0.920	0.918	0.923	0.933
	Japonya	0.828	0.859	0.860	0.964	0.961	0.966	0.972

Tablo 2 ve Şekil 7’de görüldüğü gibi ölüm sayısının tahminine yönelik deneysel sonuçlar, geliştirilen LSTM tabanlı modelin karşılaştırılan diğer modellerden daha başarılı olduğunu göstermiştir.



Şekil 7. Ölüm sayısı tahminine yönelik R² metriğine göre deneysel sonuçlar

LSTM, tüm ülkeler için 0.9’un üzerinde R² değerine sahip olmuştur. Elde edilen R² değerleri, geliştirilen LSTM tabanlı tahmin modelinin, verilere

oldukça iyi uyduğunu göstermektedir. LSTM'in ardından, RNN, MLP, CNN, SVM, RF ve LR sırasıyla başarılı olan modellerdir.

RF'in LR'den daha başarılı olması, RF'in topluluk öğrenme yapısı sayesinde veriye daha iyi uyan ve daha karmaşık ilişkileri yakalayabilen bir model oluşturması ile yorumlanabilir. RF, veri dağılımına daha az duyarlı olduğu için COVID-19 gibi olayların nadir bir şekilde gerçekleştiği veri setlerinde başarılı olmaktadır.

SVM'in RF'den daha başarılı olması, SVM'in veri dağılımına duyarlı bir şekilde çalışması ile açıklanabilir. SVM, çekirdek fonksiyonları kullanarak veriyi yüksek boyutlu uzaylara taşıyabilir ve bu sayede karmaşık ayrım sınırları oluşturabilir. MLP'nin SVM'den daha başarılı olması, MLP'nin sahip olduğu çok katmanlı yapı ile açıklanabilir. MLP bu sayede karmaşık ilişkileri daha başarılı modelleme yeteneğine sahiptir. COVID-19 verileri gibi karmaşık ve değişken verisetleri için MLP'nin daha fazla esneklik sunması, verilere daha iyi uyan bir model oluşturmasını sağlar. MLP'nin CNN'den daha başarılı olması, MLP'nin karmaşık ve değişken verisetlerini modelleme yeteneği ile açıklanabilir.

RNN'in MLP'den daha başarılı olması, RNN'in sıralı verileri işlemek için geliştirilmiş yapısıyla yorumlanabilir. Zaman serileri, geçmiş verilere dayalı bağlantıları gerektirir. RNN, bu bağlantıları yakalamak için bellek hücrelerine sahiptir. LSTM'in RNN'den daha başarılı olması, LSTM'in uzun vadeli bağlantıları yakalama yeteneği ile yorumlanabilir. RNN, uzun vadeli zaman serileri için eğitilirken kaybolan gradyan problemiyle karşılaşır. LSTM, bu problemi çözmek amacıyla geliştirilmiş bir modeldir. Ayrıca LSTM, önceki zaman adımlarından gelen bilgileri saklama yeteneğine sahiptir.

4. SONUÇLAR

COVID-19, büyük bir küresel sağlık krizi olarak insanlık tarihe geçen bir salgındır. COVID-19, ülkelerin sağlık sistemlerini, ekonomilerini ve sosyal yaşantılarını da olumsuz etkiledi. COVID-19 salgınının yönetiminde YZ tekniklerinin kullanılması, kritik bir rol oynamaktadır. YZ teknikleri, verilerin etkili analizi ve tahmini, enfekte bölgelerin belirlenmesi ile sağlık sistemlerinin ve kaynaklarının optimizasyonuna yardımcı olabilir. Ayrıca,

hükümetlerin ve yerel yönetimlerin salgınla mücadele stratejileri geliştirmelerine yardımcı olabilir.

Bu çalışmada, günlük COVID-19 vaka ve ölüm sayılarının tahminine yönelik LSTM tabanlı bir model geliştirilmiştir. Geliştirilen model, DSÖ'den elde edilen teyit edilmiş COVID-19 vaka ve ölüm sayılarından oluşan bir veriseti kullanılarak LR, RF, SVM, MLP, CNN ve RNN ile kapsamlı olarak karşılaştırılmıştır. Deneysel sonuçlar, LSTM'in karşılaştırılan modellere göre daha başarılı olduğunu göstermiştir. LSTM, günlük vaka ve ölüm sayılarını tahmin etmede daha yüksek doğruluk sağlayarak salgının gelecekteki seyrinin daha iyi anlaşılmasına yardımcı olmaktadır. Deneysel sonuçlar, salgın ile mücadelede YZ tekniklerinin etkili bir araç olabileceğini ve sağlık sistemlerine entegre edilmesi açısından umut verici olduğunu göstermiştir.

KAYNAKLAR

1. da Silva Bezerra, V. (2022). Brazil's viewpoints on international organizations: Political aspects. *BRICS Journal of Economics*, 3(1), 73-91.
2. Acharya, S. (2022). Role and Function of United Nation Security Council (UNSC) in Maintaining Peace and Harmony amongst the Nation-A Special Reference to India's Claim in Becoming Permanent Member in UNSC. *Supremo Amicus*, 28, 518.
3. Khullar, A. (2019). Information Bulletin of the BRICS Trade Union Forum Issue 16.2019. *International relations*, 2019, 21.
4. Oates, J. G. (2017). The fourth face of legitimacy: Constituent power and the constitutional legitimacy of international institutions. *Review of International Studies*, 43(2), 199-220.
5. Khachfe, H. H., Chahrour, M., Sammouri, J., Salhab, H., Makki, B. E., Fares, M., ... & Fares, M. Y. (2020). An epidemiological study on COVID-19: a rapidly spreading disease. *Cureus*, 12(3).
6. Kretchy, I. A., Asiedu-Danso, M., & Kretchy, J. P. (2021). Medication management and adherence during the COVID-19 pandemic: perspectives and experiences from low-and middle-income countries. *Research in social and administrative pharmacy*, 17(1), 2023-2026.
7. Swain, S. K., Jena, P. P., & Das, S. (2022). Role of social distancing, hand hygiene and wearing mask in controlling covid-19 pandemic: A review. *Asia Pacific Journal of Health Management*, 17(1), 173-180.
8. Zoumpourlis, V., Goulielmaki, M., Rizos, E., Baliou, S., & Spandidos, D. A. (2020). The COVID-19 pandemic as a scientific and social challenge in the 21st century. *Molecular medicine reports*, 22(4), 3035-3048.
9. Awotunde, J. B., Folorunso, S. O., Jimoh, R. G., Adeniyi, E. A., Abiodun, K. M., & Ajamu, G. J. (2021). Application of artificial intelligence for COVID-19 epidemic: an exploratory study, opportunities, challenges, and future prospects. *Artificial Intelligence for COVID-19*, 47-61.
10. Ilhan, B., Guneri, P., & Wilder-Smith, P. (2021). The contribution of artificial intelligence to reducing the diagnostic delay in oral cancer. *Oral oncology*, 116, 105254.
11. Cheng, J., Sollee, J., Hsieh, C., Yue, H., Vandal, N., Shanahan, J., ... & Wang, J. (2022). COVID-19 mortality prediction in the intensive care unit with deep learning based on longitudinal chest X-rays and clinical data. *European radiology*, 32(7), 4446-4456.
12. Alassafi, M. O., Jarrah, M., & Alotaibi, R. (2022). Time series predicting of COVID-19 based on deep learning. *Neurocomputing*, 468, 335-344.

13. Xu, L., Magar, R., & Farimani, A. B. (2022). Forecasting COVID-19 new cases using deep learning methods. *Computers in biology and medicine*, 144, 105342.
14. Akter, S., Das, D., Haque, R. U., Tonmoy, M. I. Q., Hasan, M. R., Mahjabeen, S., & Ahmed, M. (2022). AD-CovNet: An exploratory analysis using a hybrid deep learning model to handle data imbalance, predict fatality, and risk factors in Alzheimer's patients with COVID-19. *Computers in Biology and Medicine*, 146, 105657.
15. Nagi, A. T., Awan, M. J., Mohammed, M. A., Mahmoud, A., Majumdar, A., & Thinnukool, O. (2022). Performance analysis for COVID-19 diagnosis using custom and state-of-the-art deep learning models. *Applied Sciences*, 12(13), 6364.
16. Paul, A., Basu, A., Mahmud, M., Kaiser, M. S., & Sarkar, R. (2023). Inverted bell-curve-based ensemble of deep learning models for detection of COVID-19 from chest X-rays. *Neural Computing and Applications*, 35(22), 16113-16127.
17. Al-Waisy, A. S., Al-Fahdawi, S., Mohammed, M. A., Abdulkareem, K. H., Mostafa, S. A., Maashi, M. S., ... & Garcia-Zapirain, B. (2023). COVID-CheXNet: hybrid deep learning framework for identifying COVID-19 virus in chest X-rays images. *Soft computing*, 27(5), 2657-2672.
18. Rustam, F., Reshi, A. A., Mehmood, A., Ullah, S., On, B. W., Aslam, W., & Choi, G. S. (2020). COVID-19 future forecasting using supervised machine learning models. *IEEE access*, 8, 101489-101499.
19. Abdulhafedh, A. (2017). Incorporating the multinomial logistic regression in vehicle crash severity modeling: A detailed overview. *Journal of Transportation Technologies*, 7(03), 279.
20. Dang, A. T. N., Nandy, S., Srinet, R., Luong, N. V., Ghosh, S., & Kumar, A. S. (2019). Forest aboveground biomass estimation using machine learning regression algorithm in Yok Don National Park, Vietnam. *Ecological Informatics*, 50, 24-32.
21. Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), e1249.
22. Deist, T. M., Dankers, F. J., Valdes, G., Wijzman, R., Hsu, I. C., Oberije, C., & Lambin, P. (2018). Machine learning algorithms for outcome prediction in (chemo) radiotherapy: An empirical comparison of classifiers. *Medical physics*, 45(7), 3449-3459.
23. Zheng, B., Myint, S. W., Thenkabail, P. S., & Aggarwal, R. M. (2015). A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. *International Journal of Applied Earth Observation and Geoinformation*, 34, 103-112.

24. Mathew, J., Pang, C. K., Luo, M., & Leong, W. H. (2017). Classification of imbalanced data by oversampling in kernel space of support vector machines. *IEEE transactions on neural networks and learning systems*, 29(9), 4065-4076.
25. Bikku, T. (2020). Multi-layered deep learning perceptron approach for health risk prediction. *Journal of Big Data*, 7(1), 1-14.
26. Lucas, A., Iliadis, M., Molina, R., & Katsaggelos, A. K. (2018). Using deep neural networks for inverse problems in imaging: beyond analytical methods. *IEEE Signal Processing Magazine*, 35(1), 20-36.
27. Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017, August). Understanding of a convolutional neural network. In *2017 international conference on engineering and technology (ICET)*, 1-6.
28. Liang, T., Xu, X., & Xiao, P. (2017). A new image classification method based on modified condensed nearest neighbor and convolutional neural networks. *Pattern Recognition Letters*, 94, 105-111.
29. Gao, S., Huang, Y., Zhang, S., Han, J., Wang, G., Zhang, M., & Lin, Q. (2020). Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. *Journal of Hydrology*, 589, 125188.
30. Ramesh, K., Ravishankaran, S., Joshi, A., & Chandrasekaran, K. (2017). A survey of design techniques for conversational agents. In *International conference on information, communication and computing technology* (pp. 336-350). Singapore: Springer Singapore.
31. Kisvari, A., Lin, Z., & Liu, X. (2021). Wind power forecasting—A data-driven method along with gated recurrent neural network. *Renewable Energy*, 163, 1895-1909.
32. Eapen, J., Bein, D., & Verma, A. (2019, January). Novel deep learning model with CNN and bi-directional LSTM for improved stock market index prediction. In *2019 IEEE 9th annual computing and communication workshop and conference (CCWC)*, 0264-0270.
33. Nguyen, H. D., Tran, K. P., Thomassey, S., & Hamad, M. (2021). Forecasting and Anomaly Detection approaches using LSTM and LSTM Autoencoder techniques with the applications in supply chain management. *International Journal of Information Management*, 57, 102282.
34. Yazdaniyan, P., & Sharifian, S. (2021). E2LG: a multiscale ensemble of LSTM/GAN deep learning architecture for multistep-ahead cloud workload prediction. *The Journal of Supercomputing*, 77, 11052-11082.