BİLGİSAYAR BİLİMLERİ VE MÜHENDİSLİĞİNDE ÖNCÜ VE YENİLİKÇİ ÇALIŞMALAR

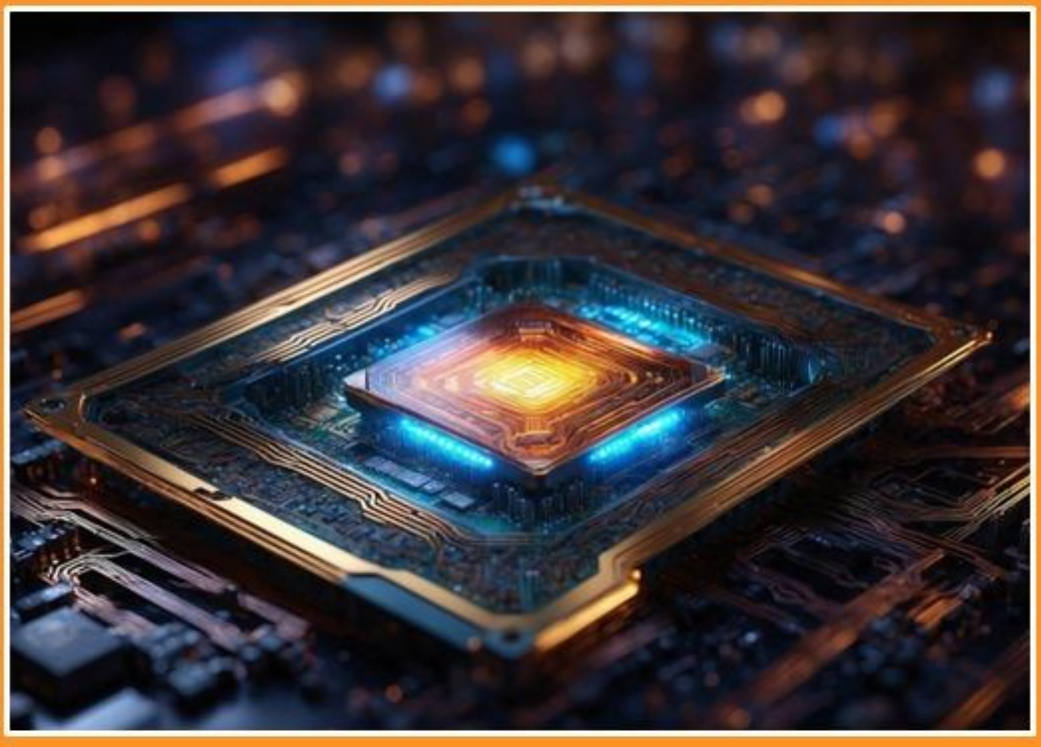

All Sciences Academy

BİLGİSAYAR BİLİMLERİNDE VE MÜHENDİSLİĞİNDE ÖNCÜ VE YENİLİKÇİ ÇALIŞMALAR

Editör
Prof. Dr. AYŞEGÜL ALAYBEYOĞLU

Bilgisayar Bilimleri ve Mühendisliğinde Öncü ve Yenilikçi Çalışmalar
Editör: *Prof. Dr. AYŞEGÜL ALAYBEYOĞLU*

Dizayn: All Sciences Academy Design
Basım Tarihi: Aralık 2024
Yayıncı Sertifika Numarası: 72273
ISBN: 978-625-5954-17-6

© All Sciences Academy

www.allsciencesacademy.com
allsciencesacademy@gmail.com

İÇERİK

1. Bölüm **6**

Yapay Zeka Destekli Denetim: Potansiyeller ve Engeller

Abdullah SEVİN

2. Bölüm **27**

Veritabanı Yönetim Sistemi Seçim Rehberi: Teknik ve İşlevsel Bakış Açısıyla İnceleme

Ebubekir SEYYARER

3. Bölüm **46**

Dinamik Özellik Seçimi Problemlerinde Meta-Sezgisel Yaklaşımlar

Emrullah GAZİOĞLU

4. Bölüm **63**

Derin Öğrenmede Genetik Algoritmalar ile Hiperparametre Optimizasyonu

Emrullah GAZİOĞLU

5. Bölüm **78**

Quantum Machine Learning ile Siber Güvenlik: Yeni Nesil Tehditlerle Mücadelede Yenilikçi Yaklaşımlar

Faruk AYATA

6. Bölüm **93**

Bilgisayar Destekli EEG Analiz Sistemleri

Gamzepelin AKSOY, Murat KARABATAK

7. Bölüm **129**

Kimlik Avı saldırılarının tespitinde sınıflandırma algoritmalarının performans karşılaştırılması

Fatih Kürşad GÜNDÜZ

8. Bölüm **147**
Tıbbi Veri Analizinde Derin Öğrenme
Hasan AYDOĞAN, Gül Fatma TÜRKER

Yapay Zeka Destekli Denetim: Potansiyeller ve Engeller

Abdullah SEVİN[1]

1- Dr. Öğr. ÜYESİ; Sakarya Üniversitesi Bilgisayar ve Bilişim Bilimleri Fakültesi Bilgisayar Mühendisliği Bölümü. asevin@sakarya.edu.tr ORCID No: 0000-0001-9694-0870

ÖZET

Yapay zekanın denetim aşamalarına uyumu, geleneksel yöntemleri dönüştürerek etkinlik, doğruluk ve analiz kapasitesinde önemli olanaklar sunmaktadır. Yapay zeka destekli otomasyon, büyük veri setlerini hızlıca işleyebilmekte ve gerçek zamanlı izleme ile sürekli denetim fırsatı tanıyarak manuel işlem ve analiz süreçlerini önemli ölçüde azaltmaktadır. Bu da insan kaynaklı hataları en aza indirirken, denetim standartlarının daha tutarlı şekilde uygulanmasını ve süreçlerin genel doğruluk seviyesinin artmasını sağlamaktadır. Yapay zeka, aynı zamanda rutin görevlerin otomasyonu ve kaynakların daha stratejik işlere tahsisi sayesinde maliyetleri azaltarak denetçilerin yüksek değer oluşturan faaliyetlere odaklanmasını kolaylaştırmaktadır. Ancak bu teknolojinin uygulanması sırasında çeşitli güçlüklerle karşılaşılmaktadır. Veri kalitesinin sağlanması, farklı veri kaynaklarının uyumlaştırılması, algoritmaların genellikle şeffaf olmayan yapısı ("kara kutu" problemi) ve gizlilik/güvenlik kaygıları bu zorluklardan sadece birkaçıdır. Ek olarak, başlangıç yatırımları, düzenli bakım masrafları ve yapay zeka araçlarının etkin kullanımı için gerekli eğitimlerin sağlanması önemli gereksinimlerdir.

Bu araştırma, yapay zeka teknolojisinin belirli bir alanda nasıl etkili bir şekilde uygulanabileceğini, bu süreçte ortaya çıkan potansiyeller ve karşılaşılan engeller detaylı bir şekilde incelemektedir. Ele alınan analizler, yapay zekanın sunduğu potansiyelin tam anlamıyla değerlendirilebilmesi için stratejik planlamanın, kapsamlı eğitim programlarının ve doğru yatırımların kritik bir öneme sahip olduğunu göstermektedir. Ayrıca, yapay zeka kullanımının hem organizasyonel yapı hem de bireysel beceri geliştirme açısından taşıdığı öneme vurgu yapılmakta, bu teknolojinin etik, yasal ve toplumsal boyutları da göz önünde bulundurularak çok yönlü bir yaklaşımın gerekliliği tartışılmaktadır. Bu bağlamda çalışma, yapay zekanın fırsatlarını en üst düzeye çıkarmak ve zorluklarını en aza indirmek için benimsenebilecek yöntem ve stratejilere dair kapsamlı bir perspektif sunmaktadır.

Anahtar Kelimeler – Yapay Zeka, Denetim, Potansiyeller, Engeller, Entegrasyon.

GİRİŞ

Günümüzde hem blokzincir hem de yapay zeka teknolojilerinin büyük ölçekte hızla ivme kazandığı yaygın olarak kabul edilmektedir. Bu teknolojiler teknik olarak ileri düzeydedir ve önemli ekonomik sonuçlar doğurmaktadır (Moll & Yiğitbaşıoğlu, 2019:1). Günümüzde yeniliklerin arkasındaki teknolojilerin büyük kısmını yapay zeka ve blokzincir teknolojileri oluşturmaktadır. Her ikisi de muhasebe ve denetim de dahil

olmak üzere hayatın birçok alanında önemli değişikliklere neden olmuştur. Bu teknolojiler dijital ekonomi, gelecekteki meslekler, insanların nasıl yaşadığı ve gelecekte nasıl etkileşimde bulunduğu üzerinde önemli bir etkiye sahiptirler (Smith, 2018:1). Denetim süreci, bilgi teknolojisi sayesinde geleneksel denetimlerden dijital denetimlere veya teknoloji tabanlı denetimlere dönüşmüştür (Huang & Vasarhelyi, 2019:4). Denetçiler artık doğrudan görev odaklı muhasebe programlarıyla eskisi kadar ilgilenmemektedirler. Sonuç olarak, roller daha çok tavsiye niteliğinde olacak şekilde gelişim göstermektedir. Bu, klasik denetçinin mesleki şüphe, muhakeme ve eleştirel düşünme becerileri gibi yeni beceriler geliştirmesi gerekliliğini ortaya çıkarmıştır. Yapay zeka ve blokzincir teknolojisinin yakın gelecekte denetim mesleğinde birçok değişime sebep olması beklenmekte ve modern denetçilerin rolünün bu kapsamda değişimi öngörülmektedir (Abdennadher, v.dğr., 2022:15).

Etkili bir yönetişim yapısı ve yönergeleri, kuruma ait hedeflere ulaşılmasını, risk yönetimini ve kurumsal yönetimin geliştirilmesini desteklemektedir (Chowdhury, 2021:48). Kurumların yönetim sistemi, bağımsız bir görüş sunmak, belirli konularda yardımcı olmak ve iyileştirmeyi ve yeniliği teşvik etmek ve ilerletmek için iç denetim fonksiyonuna bağlıdır (Tiron-Tudor v.dğr., 2021:14). Yapay zekanın tanıtılması, iç denetim fonksiyonunun kurumun dağınık ve büyük verilerini anında işlemesini sağlayarak iç denetim fonksiyonunun rolünde önemli iyileştirmeler sağlama vaadini taşımaktadır (Ghanoum & Alaba, 2020:11). Yapak zekanın kurumlara sunduğu gelişmiş yetenekler, iç denetim fonksiyonun sorumluluğunda olan kurum operasyonları ve yönetişim konusunda paydaşlara artan memnuniyet sağlaması beklenmektedir (Florea & Florea, 2016:6).

Bu çalışmanın motivasyonu, yapay zekanın denetim süreçlerindeki potansiyelini ve karşılaşılan engelleri detaylı bir şekilde incelemektir. Teknolojinin hızla gelişmesi ve iş dünyasının dinamik yapısı, denetim alanında yapay zekanın entegrasyonunu giderek daha önemli hale getirmektedir. Yapay zekanın denetim süreçlerinde sağlayabileceği verimlilik, doğruluk ve ileri analiz yeteneklerinin anlaşılması, denetçiler için büyük önem taşımaktadır. Çalışmanın birincil amacı, yapay zekanın denetim süreçlerindeki katkılarını ve bu teknolojinin uygulama alanlarını ortaya koymaktır. Aynı zamanda, yapay zekanın kullanımı ile ortaya çıkan veri kalitesi, algoritma şeffaflığı, güvenlik ve gizlilik gibi zorlukları da ele alarak, bu konulara ilişkin farkındalık oluşturmayı hedeflemektedir. Bu çalışma, hem akademik literatüre hem de pratik uygulamalara katkıda bulunarak, iç denetçi, bağımsız denetçi, kamu denetçisi ve firmaların yapay zeka teknolojisini nasıl etkili bir şekilde kullanabileceklerine dair rehberlik sağlamayı amaçlamaktadır. Ayrıca, yapay zekanın sunduğu yenilikçi yaklaşımları inceleyerek, denetim alanındaki bilgi birikimini artırmayı ve sürdürülebilir, güvenilir denetim süreçleri geliştirmeye katkı sağlamayı

hedeflemektedir. Sonuç olarak, bu çalışma, denetçiler ve akademisyenlere yönelik olarak, yapay zekanın denetim süreçlerindeki rolünü daha iyi anlamalarına ve bu alandaki bilgi birikimlerini artırmalarına katkı sağlamayı amaçlamaktadır.

Çalışma, beş ana bölümden oluşmaktadır. İlk bölümde, denetim mesleğinin teknolojik gelişmelerle nasıl değiştiği ve yapay zeka ile blokzincir teknolojilerinin bu süreçteki rolü ele alınmıştır. İkinci bölümde, denetimde yapay zeka araştırmaları ile alakalı literatür çalışmalarına yer verilmiştir. Üçüncü bölümde, yapay zekanın temel tanımı ve genel kullanımı hakkında bilgi verilmiştir. Dördüncü bölümde, yapay zekanın sunduğu spesifik potansiyeller, otomatik veri işleme, sürekli denetim, gelişmiş analitik, maliyet tasarrufu ve uyum gibi konular ayrıntılı olarak incelenmiştir. Beşinci ise yapay zekanın denetim süreçlerindeki kullanımında karşılaşılan engeller ve bu engellerin nasıl aşılabileceği üzerinde durulmuştur. Son bölümde çalışmaya ait sonuçlar değerlendirilmiştir.

LİTERATÜR ARAŞTIRMASI

Literatürde denetim süreçlerinde yapay zeka kullanımını araştıran birçok çalışma bulunmaktadır. Wassie ve Lakatos (2024) sistematik bir literatür taraması yaklaşımını benimseyerek bir çalışma gerçekleştirmişlerdir. İç denetim fonksiyonlarında yapay zeka kullanımına ilişkin araştırmaların durumunu vurgulamayı, akademisyenlere ve endüstri uzmanlarına konu hakkında fikir vermeyi ve yeni teknolojinin iç denetim fonksiyonları için sonuçlarını ortaya çıkarmayı amaçlamışlardır. Ayrıca yapay zekanın iç denetim fonksiyonlarında hızlı bir şekilde çalışmasını sağlamak için yükümlülük, erişim, yetenek ve beceri geliştirme gibi niteliklere sahip bir çerçeve önerisinde bulunmuşlardır (s. 1-3). Abu Huson vd. (2024) denetimde bilgi teknolojisi, yapay zeka ve blokzincir ile ilgili literatürdeki son durumu analiz etmek için inceleme makalesi yazmışlardır. Literatürde yer alan makale çalışmaları taranarak bu konudaki araştırma eğilimleri ve popüler konuları tasvir etmek için bibliyometrik bir analiz çalışması gerçekleştirilmiştir (s. 1-2). Patel vd. (2023) yapay zekanın mali denetim süreci üzerindeki etkisini incelemekte ve denetim uygulamalarını nasıl geliştirdiğini araştırmışlardır. Yapay zeka teknolojisinin finansal denetimlere entegrasyonu, görevleri otomatikleştirerek, gerçek zamanlı analiz sağlayarak, risk değerlendirme yeteneklerini geliştirerek ve değerli bilgiler sunarak meslekte devrim oluşturma potansiyeline vurgu yapmışlardır. Bu araştırma, denetim sürecinde yapay zeka entegrasyonuyla ilgili sonuçları, faydaları, zorlukları ve etik hususları incelemiştir (s. 1). Hasan (2021) çalışmasında yapay zekanın muhasebe ve denetimdeki uygulanmalarını incelemiştir. İlgili yayınlanmış kitap ve dergilerin analizi

gerçekleştirilmiş ve yarı sistematik veya anlatısal inceleme yaklaşımı kullanılmıştır. Endüstri 4.0'ın getirdiği yenilikçi teknolojilerin getirdiği zorluklarla karşı karşıya kalan muhasebe ve denetim disiplininin bir sonraki aşamaya geçebilmesi için bir dönüşüm geçirmesi gerektiği vurgulanmıştır (s. 1).

Zemankova (2019) denetim ve muhasebede yapay zekaya ilişkin mevcut durum ve trendler üzerinde, fırsatlar ve tehditler dahil olmak üzere bir analiz çalışması gerçekleştirmiştir. Yapay zeka alanının sürekli olarak değişmesinden; en büyük şirketlerin, denetim ve muhasebede yapay zekanın geniş kullanımını sağlamak için muazzam miktarda sermaye yatırımı yaptığından bahsetmektedir. Çalışmanın ana hedeflerinden biri, risk değerlendirmesine vurgu yaparak yapay zeka uygulamasından yararlanan denetim görevlerinin bir analizini gerçekleştirmek olarak vurgulamışlardır (s. 1-2). Omoteso (2012), yapay zeka ve denetim alanındaki araştırma ve yazılım geliştirmenin gelecekteki yönlerini tahmin etmek amacıyla, denetçilerin yapay zekalı sistemlerin kullanımına ilişkin ana araştırma çabalarını ve mevcut tartışmaları gözden geçirmeyi amaçlamaktadır. Çalışma, denetimde yapay zeka sistemlerinin gelişim sürecini, belirlenen yararları ve dezavantajları ışığında haritalanmaktadır. Ayrıca denetimde uzman sistemlerin ve sinir ağlarının kullanımına ve bunların sonuçlarına ilişkin önceki araştırma çalışmaları da gözden geçirilmektedir (s. 1-2).

Bu araştırmada ise, yapay zekanın denetim süreçlerinde kullanılmasının sunduğu potansiyeller ve karşılaşılan engeller literatürdeki çalışmalar esas alınarak incelenmiştir. Öncelikle, yapay zekanın denetim süreçlerine entegrasyonunun sağlayabileceği verimlilik, hız, doğruluk ve ileri düzey analiz yetenekleri ele alınmıştır. Yapay zekanın otomatik veri işleme, sürekli denetim, anomali tespiti, desen tanıma, tahminsel analitik ve risk yönetimi gibi alanlarda sunduğu faydalar detaylandırılmıştır. Ayrıca, yapay zekanın denetim süreçlerine getirdiği maliyet tasarrufu, kaynakların optimize edilmesi ve uyum süreçlerindeki katkıları vurgulanmıştır. Çalışma, yapay zekanın kullanımının beraberinde getirdiği zorlukları da kapsamlı bir şekilde tartışmıştır. Veri kalitesi ve bütünlüğü, yapay zeka modellerinin yorumlanması, güvenlik ve gizlilik konuları, düzenleyici ve etik zorluklar, başlangıç ve bakım maliyetleri ile değişime direnç gibi konular ele alınarak, bu zorlukların nasıl aşılabileceği konusunda öneriler sunulmuştur. Son olarak, yapay zekanın denetim süreçlerine entegrasyonunun sağladığı genel faydalar özetlenmiş ve bu teknolojinin başarılı bir şekilde uygulanması için gerekli stratejiler ve eğitim ihtiyaçları belirtilmiştir.

YAPAY ZEKA

Tıpkı yapay zekanın kendisi gibi, kavramın tanımı da devamlı olarak değişmektedir. Grewal (2014), yapay zekanın malumat ve bilgi toplayan ve aynı zamanda evrenin zekasını işleyen mekanik simülasyon sistemi olduğunu ifade etmiştir. Yazara göre malumat, bilgi ve zekanın bir araya getirilmesini, analiz edilmesini ve nihayetinde icraata dönüştürülebilir zeka formatında belirli taraflara dağıtılmasını içermektedir (s. 1). Haenlein vd. (2019) Yapay zeka, bir sistemin dış verileri doğru bir şekilde kavrayıp onlardan öğrenerek, öğrendiklerini esnek bir şekilde adapte ederek belirli hedef ve görevleri yerine getirme yeteneği olarak tanımlamıştır (s. 1). Zhang vd. (2020), yapay zekayı büyük veri ve makine öğrenimi teknolojisinin geçmişi kavramak ve büyük hacimde veri kullanarak ileriyi tahmin etmek için başarılı bir şekilde kullanılmasının sonucu olduğunu söyleyerek farklı bir bakış açısıyla tanımlamışlardır (s. 8). Lee & Tajudeen (2020), yapay zekanın, bilgisayarların yanlışlıklardan ders çıkarmasını, yeni girdilere uyum sağlamasını ve insan benzeri görevleri yerine getirmesini sağladığını ifade etmişlerdir. Yazarlar, yapay zeka teknolojileri sayesinde büyük hacimde verinin yorumlanabilmekte ve verilerdeki örüntülerin daha tanınabilir hale geldiğini söylemişlerdir (s. 1). Odoh vd. (2018), yapay zekanın bir cihazın normalde insan beyni tarafından gerçekleştirilecek görevleri yapma yeteneği olduğu bakış açısını paylaşmıştır. Bilgi kapasitesi ve onu edinme yeteneği bu görevlerden ikisidir. Diğer yetenekler arasında yargı çıkarımı, ilişkileri anlama ve yeni fikirler üretme yeteneği yer aldığını ifade etmişlerdir (s. 3).

Yapay zeka, insan benzeri zeka davranışlarını taklit eden makineler veya sistemler geliştirmeyi amaçlayan bir teknoloji alanıdır. Yapay zekanın temel bileşenleri veri, algoritmalar ve işlem gücüdür. Veri, yapay zeka sistemlerinin etkinliğini artırırken, algoritmalar (makine öğrenmesi, derin öğrenme, yapay sinir ağları gibi) veriyi işleyip öğrenmeye olanak tanır. Yapay sinir ağları, insan beynine benzer yapılarla karmaşık veri özelliklerini öğrenir. Ayrıca, yüksek işlem gücü, güçlü işlemciler ve grafik işlemcileri gereklidir. Yapay zeka, görsel, işitsel tanıma ve doğal dil işleme gibi yeteneklerle insan benzeri algılama sağlar. Bu sistemler, veriden öğrenir, kendini geliştirir ve yeni bilgiler üretir.

Sonuç olarak, yapay zeka, veri, algoritmalar, makine öğrenmesi, sinir ağları, veri işleme gücü, görsel ve işitsel tanıma ve doğal dil işleme gibi birçok bileşenin bir araya gelmesiyle oluşturulan karmaşık bir teknolojik yapıdır. Bu bileşenler, yapay zekanın farklı alanlarda insanlara yardımcı olmasını ve karmaşık problemleri çözebilmesini sağlamaktadır. Yapay zeka günümüzde sektörde birçok alanda kullanılmaktadır ve her geçen gün kullanım alanı artmaktadır.

YAPAY ZEKANIN DENETİMDEKİ POTANSİYELLERİ

Denetim süreçlerinde yapay zekanın kullanımı, günümüz teknolojik gelişmeleri ve iş dünyasının dinamik ihtiyaçları doğrultusunda hızla önem kazanan bir konu haline gelmiştir. Yapay zekanın denetim alanında sunduğu potansiyellerin kapsamlı bir şekilde incelenmesi ve bu teknolojinin potansiyelini ve uygulama alanlarını ortaya koymak denetçiler ve akademisyenler açısından önemli bir katma değerdir. Yapay zekanın hızla gelişmesi, denetim süreçlerinin de bu yeniliklere uyum sağlamasını önemli bir konu haline gelmiştir. Bu teknolojik dönüşümün denetim üzerindeki etkilerini analiz etmek ve okuyuculara bu alandaki en son gelişmeler hakkında bilgi vermek önemli bir katkı sağlayacaktır.

Otomatik Veri İşleme

Yapay zekanın denetim süreçlerinde sunduğu en önemli olanaklardan biri otomatik veri işlemedir. Bu teknoloji, denetim sürecinin verimliliğini ve doğruluğunu artırarak denetçilerin iş yükünü önemli ölçüde azaltmaktadır. Otomatik veri işleme, büyük veri kümelerinin hızlı ve doğru bir şekilde işlenmesini sağlar. Yapay zeka, manuel veri girişini otomatikleştirir ve ham verileri temizleyerek hataları düzeltebilir. Bu, denetim sürecinin hızlanmasına ve doğruluğun artmasına katkıda bulunmaktadır. Veri madenciliği ve desen tanıma, yapay zekanın otomatik veri işleme yeteneklerinin önemli bir parçasıdır. Yapay zeka, büyük veri kümelerindeki gizli kalıpları, ilişkileri ve trendleri belirlemek için veri madenciliği tekniklerini kullanmaktadır. Gelişmiş algoritmalar, verilerdeki anormallikleri ve sapmaları tespit edebilir, bu da potansiyel hileli işlemlerin veya hataların erken tespit edilmesini sağlamaktadır (Dimyadi & Amor, 2017:1-2).

Otomatik veri işleme, raporlama ve görselleştirme süreçlerini de içerir. Yapay zeka, verileri analiz ettikten sonra otomatik olarak raporlar oluşturabilir ve verileri görsel olarak sunabilir. Bu, denetçilerin bulgularını daha hızlı ve etkili bir şekilde sunmalarını sağlamaktadır. Grafikler, tablolar ve diğer görselleştirme araçları, verilerin daha anlaşılır olmasını sağlar. Sonuç olarak, otomatik veri işleme, yapay zekanın denetim süreçlerinde sağladığı en önemli faydalardan biridir. Bu teknoloji, veri işleme ve analiz süreçlerini hızlandırarak, doğruluğu artırarak ve denetçilerin daha stratejik görevler üzerine odaklanmasını sağlayarak denetim süreçlerine katkı sağlamaktadır. Efe & Tunçbilek (2023) yapmış oldukları çalışmalarında otomatik veri işleme yazılımlarını incelemişler ve bu denetim araçları üzerine bir değerlendirme çalışması gerçekleştirmişlerdir (s. 1).

Otomatik veri işleme kapsamında uygulamaya dayalı bir örnek vermek gerekir ise; kamu sektöründe yapılan sağlık hizmetlerindeki tedavi sürecinin faturalandırılması için otomatik veri işleme sistemleri kullanılarak hastalara ait işlemlerdeki anormal işlem modelleri tespit edilebilir. Sistem, normal işlem davranışları ile anormal durumları karşılaştırarak olası hata

durumlarını hızlı bir şekilde belirleyebilir. Bu tür bir uygulama, denetim sürecini hızlandırır ve insan hatasını azaltarak daha güvenilir sonuçlar elde edilmesini sağlar.

Sürekli Denetim ve Gerçek Zamanlı İzleme

Yapay zekanın denetim süreçlerinde sunduğu önemli olanaklardan biri, sürekli denetim ve gerçek zamanlı izleme yetenekleridir. Bu teknoloji, denetim süreçlerinin statik ve periyodik olmaktan çıkarak dinamik ve sürekli bir hale gelmesini sağlamaktadır. Gerçek zamanlı izleme, verilerin anında işlenmesine ve analiz edilmesine olanak tanımaktadır, bu da denetçilerin anında geri bildirim almasını ve hızlıca aksiyon almasını mümkün kılmaktadır. Gerçek zamanlı veri analizi, denetçilerin potansiyel sorunları veya riskleri anında tespit etmelerini sağlamaktadır. Sürekli denetim, denetim süreçlerinin daha etkin ve verimli olmasını sağlar. Yapay zeka, büyük veri kümelerini sürekli olarak analiz ederek, denetçilerin zaman alıcı ve tekrarlayan görevlerden kurtulmasına olanak tanır. Bu, denetçilerin daha stratejik ve katma değerli işlere odaklanmalarını sağlar. Sürekli izleme ve analiz, denetim süreçlerinin daha proaktif bir şekilde yönetilmesini mümkün kılmaktadır. Bu, denetim süreçlerinin her zaman güncel ve uyumlu olmasını sağlar (Ruiter, 2017:18-22). Sonuç olarak, sürekli denetim ve gerçek zamanlı izleme, yapay zekanın denetim süreçlerinde sağladığı önemli faydalardan biridir. Bu teknoloji, denetim süreçlerini daha dinamik, verimli ve proaktif hale getirerek, denetçilerin işlerini daha etkili bir şekilde yapmalarına olanak tanımaktadır.

Bu kapsamda, bir perakende zinciri, yapay zeka destekli sürekli denetim sistemlerini kullanarak mağaza envanterlerini gerçek zamanlı olarak izleyebilir. Sistem, mağaza satış noktalarından gelen verileri anlık olarak analiz eder ve envanterdeki eksiklikler veya hatalı kayıtlar gibi sorunları hemen tespit eder. Bu sayede, stok yönetimi optimize edilir ve mağazanın performansı sürekli olarak izlenir, böylece olası sorunlara hızlı bir şekilde müdahale imkanı oluşmaktadır.

Gelişmiş Analitik ve Tahmin Yeteneği

Yapay zekanın denetim süreçlerinde sunduğu önemli olanaklardan biri, gelişmiş analitik ve tahmin yetenekleridir. Bu teknoloji, denetçilerin veri setlerindeki karmaşık ilişkileri ve kalıpları anlamalarına ve gelecekteki riskleri öngörmelerine olanak tanır. Yapay zeka, büyük veri kümelerini analiz ederek, gizli kalıpları ve ilişkileri belirleyebilir ve bu bilgiler doğrultusunda daha bilinçli ve veri odaklı kararlar alınmasını sağlayabilir. Gelişmiş analitik yetenekler, denetçilerin verilerdeki anormallikleri ve sapmaları tespit etmelerini kolaylaştırır. Bu, denetim süreçlerinin daha güvenilir ve etkili olmasını sağlamaktadır. Tahmin yetenekleri ise gelecekteki risklerin ve sorunların öngörülmesini mümkün kılar. Yapay zeka, geçmiş verileri analiz ederek gelecekteki trendleri ve olası riskleri

tahmin edebilir. Bu, denetçilerin proaktif önlemler almasını ve potansiyel sorunları önceden belirleyerek gerekli tedbirleri uygulamalarını sağlar (Appelbaum v.dğr., 2017:22).

Sonuç olarak, yapay zeka, denetçilerin büyük veri setleri üzerinde derinlemesine analiz yapmalarını ve karmaşık ilişkileri daha iyi anlamalarını sağlar. Bu da denetim süreçlerinin daha verimli, güvenilir ve etkili olmasını sağlar. Örneğin, bir bağımsız denetim firması, finansal denetim için yapay zeka destekli gelişmiş analitik sistemlerini kullanarak usulsüzlük ve uyuşmazlık tespitinde bulunabilir. Sistem, geçmiş işlem verilerini ve müşteri davranışlarını analiz ederken, alışılmadık işlem desenlerini ve anormal davranışları tespit eder. Bu verileri kullanarak, gelecekteki usulsüzlük ve uyuşmazlık faaliyetlerini tahmin edebilir ve bu faaliyetlere karşı proaktif önlemler alabilir. Bu sayede, denetim süreçleri daha etkili hale gelir ve riskler önceden belirlenerek azaltılabilir.

Maliyet Tasarrufu

Yapay zekanın denetim süreçlerinde sunduğu önemli olanaklardan biri, maliyet tasarrufudur. Yapay zeka teknolojileri, manuel ve tekrarlayan işlerin otomatikleştirilmesi sayesinde iş gücü maliyetlerini önemli ölçüde azaltır. Bu, denetim firmalarının personel kaynaklarını daha verimli kullanmasını sağlar ve denetim süreçlerinin genel maliyetlerini düşürür. Ayrıca, otomatik veri işleme yetenekleri sayesinde daha hızlı ve verimli olan süreçler, müşteri memnuniyetini artırarak uzun vadede maliyetlerin azalmasına katkıda bulunur. Yapay zekanın sunduğu maliyet tasarrufu, hataların ve hileli işlemlerin daha erken tespit edilmesini de kapsar. Erken tespit, olası mali kayıpların önüne geçerek finansal riskleri de azaltır. Bu, denetim firmalarının ve müşterilerinin maliyetlerini düşürerek finansal sağlığı korumalarına yardımcı olur. Sonuç olarak, yapay zekanın denetim süreçlerinde kullanılması, maliyet tasarrufu sağlayarak denetim firmalarının rekabet gücünü artırır ve sürdürülebilir büyüme sağlamalarına katkıda bulunur. Bu teknoloji, denetim süreçlerini daha verimli, hızlı ve ekonomik hale getirerek, denetçilerin işlerini daha etkili bir şekilde yapmalarına olanak tanımaktadır (Bughin v.dğr., 2017:20-24). Örneğin, kamu sektöründe satın alma süreçlerinde örnekleme uygulamasını, yapay zeka tabanlı bir sistem kullanarak geniş çaplı mali belgeleri otomatik olarak taranarak ve analiz edilmesi sağlanabilir. Geleneksel yöntemlerde, bu süreç manuel olarak yürütülür ve zaman alıcı olabilir, ayrıca insan hatası riski taşımaktadır. Yapay zeka, belgelerdeki kritik bilgileri hızlı bir şekilde tanımlayarak çıkarabilir, bu da denetim uzmanlarının yalnızca anormal durumları ve önemli bulguları incelemesine olanak tanır. Bu otomasyon, iş gücü ihtiyacını azaltır ve belge tarama süresini önemli ölçüde kısaltır. Sonuç olarak, denetim firması hem iş gücü maliyetlerinde hem de işlem süresinde tasarruf sağlar.

Uyum ve Regülasyon Takibi

Yapay zekanın denetim süreçlerinde sunduğu önemli olanaklardan biri, uyum ve regülasyon takibidir. Yapay zeka, sürekli değişen düzenleyici gereksinimlerin ve uyum kurallarının izlenmesini ve bu değişikliklere hızlıca uyum sağlanmasını kolaylaştırır. Bu teknoloji, düzenleyici değişiklikleri otomatik olarak tespit edebilir ve denetim süreçlerine entegre edebilir, böylece denetçilerin güncel bilgilerle çalışmasını sağlamaktadır. Bu, denetim süreçlerinin daha doğru ve eksiksiz olmasını temin etmektedir. Yapay zeka tabanlı sistemler, uyum denetimlerinde gereksiz hata ve eksikliklerin önüne geçerek, kurumları düzenleyici otoritelerle olan ilişkilerini güçlendirir ve olası cezalardan kaçınmalarına yardımcı olur. Sonuç olarak, yapay zekanın uyum ve regülasyon takibi yetenekleri, denetim süreçlerinin güncel ve doğru olmasını sağlar. Bu teknoloji, şirketlerin düzenleyici gereksinimlere sürekli uyum sağlamasına yardımcı olurken, denetim süreçlerini daha verimli ve etkili hale getirir (Thelisson v.dğr. 2017:1-4).

Denetim uygulamalarında yapay zekanın uyum ve regülasyon takibi alanındaki olanaklarına spesifik bir örnek olarak "Basel III" regülasyonunu ele alabiliriz. Basel III, bankaların sermaye yeterliliğini, likiditeyi ve risk yönetimini sıkılaştıran küresel bir düzenlemeler bütünüdür. Bir banka, Basel III ile ilgili uyum süreçlerini yapay zeka destekli bir sistem ile yönetebilir. Örneğin, bir bankanın denetim ve uyum ekipleri, Basel III kapsamında zorunlu olan sermaye yeterliliği rasyolarını ve likidite gereksinimlerini izlemek için yapay zeka kullanabilir. Yapay zeka, bankanın günlük işlemlerinden elde edilen büyük miktardaki finansal verileri gerçek zamanlı analiz ederek, Basel III standartlarına uyum sağlanıp sağlanmadığını sürekli olarak kontrol eder. Sistemin tespit ettiği herhangi bir uyumsuzluk veya riskli durum, denetim birimlerine anında raporlanır. Örneğin, yapay zeka, bankanın likidite durumu aniden düşerse veya belirlenen sermaye yeterlilik oranlarının altına inerse, bunu otomatik olarak algılar ve yönetim ekibini uyarabilir.

Anamoli ve Hata Tespiti

Yapay zekanın denetim süreçlerinde sunduğu önemli olanaklardan biri, anomali ve hata tespitidir. Yapay zeka algoritmaları, büyük veri kümelerini analiz ederek normalden sapmaları belirler ve potansiyel hileli işlemleri veya hataları erken aşamada tespit eder. Erken tespit sayesinde potansiyel riskler ve hatalar önceden belirlenir ve bu sayede şirketler önleyici tedbirler alabilir. Bu da finansal kayıpların ve itibar kaybının önlenmesine katkı sağlar. Bu, denetçilerin daha güvenilir ve etkili kararlar almalarına olanak tanımaktadır (Nonnenmacher & Gómez, 2021:5-6). Yapay zeka, geçmiş veriler üzerinde öğrenme sağlayarak normal davranış kalıplarını tanımlar ve bu kalıplardan sapmaları belirler. Örneğin, beklenmeyen finansal işlemler veya veri giriş hataları gibi durumlar tespit edilebilir.

Hata tespiti ise veri setlerindeki eksiklikleri ve hataları belirlemeyi içerir. Yapay zeka, veri girişi ve işleme süreçlerindeki hataları otomatik olarak tespit eder ve düzeltir. Bu, verilerin daha doğru ve güvenilir olmasını sağlar, böylece denetim süreçlerinin doğruluğu arttırmaktadır. Sonuç olarak, yapay zekanın anomali ve hata tespiti yetenekleri, denetim süreçlerinin güvenilirliğini artırır ve şirketlerin operasyonel risklerle başa çıkmasına yardımcı olur. Bu teknoloji, denetçilerin veri odaklı kararlar almalarını kolaylaştırır ve iş süreçlerinin daha güvenli ve verimli bir şekilde yürütülmesini sağlamaktadır.

Denetim uygulamalarında yapay zekanın anomali ve hata tespiti alanındaki kullanımına spesifik bir örnek olarak, büyük bir perakende şirketinin finansal işlemlerini ele alabiliriz. Bu perakende şirketi, finansal kayıtlarında potansiyel hataları ve dolandırıcılık faaliyetlerini tespit etmek amacıyla yapay zeka tabanlı bir anomali tespit sistemi kullanabilir. Şirketin muhasebe kayıtları, satış verileri, harcamaları ve banka işlemleri sürekli olarak büyük hacimlerde işlenir. Yapay zeka algoritmaları, bu işlemleri analiz ederek alışılmadık kalıpları ve olası sapmaları belirler.

Örneğin, sistem, bir tedarikçiye normalde aylık düzenli ödemeler yapılırken bir ay içinde aynı tedarikçiye aniden olağandışı bir miktarda birkaç ödeme yapılmasını fark edebilir. Bu durum, dolandırıcılık, hata veya yetkisiz bir işlem olabileceği için sistem bunu bir anomali olarak işaretler. Yapay zeka ayrıca, mali tablo kalemlerinde beklenmedik sapmaları tespit edebilir, örneğin belirli bir gider kaleminde ani bir artış olduğunda ya da bir satış faturasında mantıksız tutarlar yer aldığında, bu durumu raporlar.

YAPAY ZEKANIN DENETİMDEKİ ENGELLERİ

Yapay zekanın kullanımı beraberinde bazı riskler ve engeller getirmektedir. Yapay zekanın denetim süreçlerine entegrasyonunda dikkate alınması gereken önemli zorluklar bulunmaktadır. Bunlar arasında; veri kalitesi ve bütünlüğü, anormalliklerin tanımlanması, etik ve hukuki sorunlar, yapay zeka modellerinin yorumlanması, sürekli güncelleme ve adaptasyon ile insan ve yapay zeka işbirliği sorunları ifade edilebilir. Her bir zorluk, teknolojinin etkin ve güvenilir bir şekilde kullanılabilmesi için çözümlenmesi gereken bir alanı temsil etmektedir.

Veri Kalitesi ve Bütünlüğü

Yapay zekanın denetim süreçlerinde karşılaştığı önemli engellerden biri, veri kalitesi ve bütünlüğüdür. Veri kalitesi, analizlerin ve sonuçların doğruluğunu etkileyen temel bir faktördür. Yapay zeka modelleri, doğru ve güvenilir sonuçlar üretebilmek için yüksek kaliteli, temiz ve güncel verilere ihtiyaç duymaktadır. Ancak, işletmelerdeki veri kaynakları genellikle çeşitli formatlarda ve kalitede olabilir. Bu durum, veri setlerinin homojen

olmamasına ve tutarsızlık sorunlarına yol açabilir. Veri bütünlüğü ise veri setlerinin eksiksiz ve doğru olmasını ifade eder. Veri bütünlüğü eksik veya bozuk veri noktalarının olmaması, verilerin doğruluğunu ve güvenilirliğini sağlamaktadır. Ancak, büyük veri kümeleri içinde veri bütünlüğünü sağlamak ve veri kirliliğini önlemek zor olabilir (Mitan, 2024:9).

Bu zorluklar, yapay zeka destekli denetim süreçlerinde doğru kararlar alınabilmesi için önemli bir engel teşkil edebilmektedir. Veri kalitesi ve bütünlüğü sağlanamadığında, yapay zeka modelleri yanlış sonuçlar üretebilir veya beklenmeyen sonuçlar ortaya çıkarabilir. Bu nedenle, denetim süreçlerinde veri yönetimi stratejilerinin iyi bir şekilde kurulması ve veri kalitesi standartlarının belirlenmesi önemlidir. Ayrıca, sürekli olarak veri setlerinin güncellenmesi ve temizlenmesi, yapay zeka modellerinin doğruluğunu artırmak için kritik bir rol oynar. Sonuç olarak, veri kalitesi ve bütünlüğü, yapay zeka teknolojisinin etkin bir şekilde kullanılabilmesi için vazgeçilmez bir öneme sahiptir. Kurumların bu konulara odaklanması önemli bir husus haline gelmiştir ve yapay zeka destekli denetim süreçlerinden maksimum faydayı sağlanması bu sayede mümkün olmaktadır.

Denetim uygulamalarında veri kalitesi ve bütünlüğü ile ilgili karşılaşılan zorluklara bir örnek olarak, bir finansal kuruluşun yapay zeka tabanlı bir risk yönetimi sistemi verilebilir. Bu sistem, şirketin finansal işlemlerini analiz ederek kredi risklerini, yatırım kararlarını ve diğer finansal riskleri belirlemeyi amaçlar. Ancak yapay zeka sisteminin başarıyla çalışabilmesi için kullanılan verilerin doğru, eksiksiz ve tutarlı olması gerekir. Örneğin, bu finansal kuruluş farklı bölümlerden veya dış kaynaklardan toplanan verileri birleştirirken, veriler arasında uyumsuzluklar ortaya çıkabilir. Kredi değerlendirme süreçlerinde bir müşteri hakkında eksik veya yanlış bilgi girildiğinde, yapay zeka modeli bu hatalı veriyle eğitildiğinde yanlış tahminler yapabilir.

Anormalliklerin Tanımlanması

Yapay zeka teknolojisinin denetim süreçlerinde karşılaştığı önemli zorluklardan biri, anormalliklerin tanımlanmasıyla ilgilidir. Anormallikler, genellikle beklenmeyen veya tipik olmayan veri noktalarını ifade eder ve bu veriler genellikle normal davranış kalıplarından sapmış durumdadır. Anormallik tespiti yapay zeka tarafından gerçekleştirilirken bazı önemli zorluklarla karşılaşılabilir (Li, L. v.dğr., 2022:1-4).

• Düşük Sinyal-Gürültü Oranı: Veri setleri çok sayıda gürültü içerebilmektedir. Bu durum, anormalliklerin doğru bir şekilde tanımlanmasını zorlaştırabilir çünkü gerçek anormallikler, veri içindeki doğal varyasyonlarla karışabilir.

• Yetersiz Eğitim Verisi: Anormallik tespiti için yapay zeka modelleri genellikle büyük ve çeşitli eğitim veri setlerine ihtiyaç duymaktadır. Yetersiz veya temsil edici olmayan eğitim verisi, modelin anormallikleri doğru bir şekilde öğrenmesini ve tanımlamasını engelleyebilmektedir.

• Değişken Veri Dağılımları: Farklı işletmelerde veya sektörlerdeki veri dağılımları farklılık gösterebilir. Bu durum, genel anormallik tanımlama modellerinin uygulanabilirliğini azaltabilir ve daha spesifik çözümler gerektirebilir.

• İnsan Etiketi Gerekliliği: Bazı anormallik tespiti modelleri insan denetçiler tarafından etiketlenmiş verilere dayanabilir. Ancak, bu etiketleme süreci zaman alıcı olabilir ve subjektif olabilir.

• Zamanla Değişen Anormallikler: Kurumlarda ve veri setlerinde zamanla değişen anormallikler olabilir. Yapay zeka modellerinin bu dinamik değişikliklere uyum sağlayabilmesi gerekmektedir.

Bahsedilen zorluklar, anormallik tespiti için yapay zeka kullanımının etkinliğini ve doğruluğunu etkileyebilir. Ancak, ileri düzey algoritmaların ve sürekli model iyileştirmelerinin kullanılmasıyla bu zorlukların üstesinden gelinebilir. Sonuç olarak, yapay zeka destekli anormallik tespiti, denetim süreçlerindeki önemli bir araç olmasına rağmen, doğru uygulanması için belirtilen zorlukların dikkate alınması gerekmektedir.

Bu kapsamda, bir e-ticaret platformunun finansal işlemlerini izlemek için yapay zeka tabanlı bir dolandırıcılık tespit sistemi kullanması örnek olarak verilebilir. Bu sistem, kullanıcıların alışveriş alışkanlıklarını izleyerek olağandışı davranışları tespit etmeyi amaçlar. Ancak yapay zeka, normal ve anormal davranışları ayırt etmekte zorlanabilir. Örneğin, bazı kullanıcılar özel kampanyalar sırasında büyük miktarda alışveriş yaparken, diğer kullanıcılar mevsimsel olarak veya belirli günlerde yüksek hacimli alışveriş yapabilir. Yapay zeka, bu tür meşru anormallikleri, dolandırıcılık olarak yanlış etiketleyebilir. Bu, şirketin hem müşteriyi gereksiz yere rahatsız etmesine hem de operasyonel süreçlerde ek bir yük oluşmasına neden olabilir.

Etik ve Hukuki Sorunlar

Yapay zekanın denetim süreçlerinde karşılaştığı önemli zorluklardan biri etik ve hukuki sorunlardır. Bu sorunlar, teknolojinin kullanımıyla ilgili çeşitli ahlaki ve yasal endişeleri içermektedir. Bunları bazı başlıklar altında inceleyebiliriz (Munoko v.dğr. 2020:3-7):

• Veri Gizliliği ve Güvenliği: Yapay zeka kullanımıyla elde edilen büyük veri setleri, kişilerin veya kurumların özel bilgilerini içerebilir. Bu verilerin güvenliği ve gizliliği, sıkı yasal düzenlemeler ve etik kurallar gerektirir. Veri ihlalleri veya kötüye kullanım durumları, ciddi hukuki sonuçlar doğurabilmektedir.

• Ayrımcılık ve Önyargı: Yapay zeka algoritmaları, veri setlerindeki bilinçsiz önyargıları öğrenebilir ve bu önyargıları analizlerine yansıtabilir. Örneğin, eğitim verilerindeki önyargılar, algoritmaların haksız veya ayrımcı kararlar vermesine neden olabilir. Bu durum, etik ve hukuki sorunlara yol açabilir ve şirketlerin itibarını zedeleyebilir.

• Kararın İnsanlık Boyutu: Yapay zeka, karmaşık veya hatalı kararlar alabilmektedir ve bu kararlar genellikle insan denetçiler tarafından anlaşılması zor olabilir. Özellikle hassas veya etik değerlendirme gerektiren durumlarda, yapay zeka kararlarının insan etiği ve değerleriyle uyumlu olup olmadığı sorgulanması önemli bir husustur.

• Hukuki Uyum ve Sorumluluk: Yapay zeka teknolojilerinin kullanımıyla ilgili hukuki düzenlemeler, hukukun üstünlüğü ve kullanıcı hakları gibi temel prensiplere uygun olmalıdır. Yapay zeka kararlarının yasal sorumluluğu ve bu teknolojinin işletmeler tarafından nasıl kullanılacağı konularında net yönergeler gerekmektedir.

• Eğitim ve Farkındalık: Kurumlar, çalışanları ve paydaşları yapay zeka teknolojilerinin etik kullanımı konusunda eğitmeli ve bilinçlendirmelidir. Etik değerlerin ve sosyal sorumlulukların korunması, uzun vadeli sürdürülebilirlik ve güvenilirlik için kritik öneme sahiptir.

Bu zorluklar, yapay zekanın denetim süreçlerinde güvenilir ve etik bir şekilde kullanılmasını sağlamak için dikkate alınmalıdır. Şirketler, bu sorunları ele alarak teknolojiyi etik ve hukuki standartlara uygun olarak entegre etmeli ve güvenilirliklerini korumalıdır. Bu kapsamda bir finans kuruluşunun kredi risk değerlendirme süreçlerinde yapay zeka algoritmaları kullanılması örnek olarak değerlendirilebilir. Bu tür bir sistem, müşterilerin kredi geçmişlerini, gelirlerini ve diğer finansal bilgilerini analiz ederek, kredi başvurularını otomatik olarak onaylama veya reddetme kararları verebilir. Bir uygulama örneği olarak, yapay zeka algoritması, düşük gelirli bireylerin kredi başvurularını sistematik olarak reddetme eğiliminde olabilir çünkü eğitim verilerinde bu gruba ait bireylerin daha yüksek riskli olduğu öne sürülmüş olabilir. Bu durum, şirketin kredi politikalarının şeffaf olmaması nedeniyle etik açıdan sorgulanabilir ve aynı zamanda eşit kredi fırsatları sunmama ile ilgili hukuki bir sorun doğurabilir. Kredi raporlama sistemleri (Türkiye'de Türkiye Bankalar Birliği Risk Merkezi tarafından yürütülmekte) bu tür ayrımcılıkları önlemeyi amaçlamakta, fakat bu sistemlerin yapay zeka uygulamaları ile uyumlu hale getirilmesi zor olabilir.

Yapay Zeka Modellerinin Yorumlanması

Yapay zeka modellerinin yorumlanması, denetim süreçlerinde karşılaşılan önemli bir zorluktur çünkü bu modeller genellikle karmaşık yapılardır ve nasıl kararlar aldıkları genellikle şeffaf değildir. Yapay zeka modellerinin yorumlanması konusundaki bazı ana zorluklar (Zhang v.dğr., 2022:2-5):

• Kara Kutu Problemi: Derin öğrenme gibi bazı yapay zeka teknikleri, karmaşık iç yapıları nedeniyle genellikle "kara kutu" olarak adlandırılır. Bu modeller, genellikle milyonlarca parametre ve katman içermektedir ve bu nedenle nasıl bir karar aldıklarını açıklamak veya yorumlamak zor olabilmektedir.

• Sınırlı Şeffaflık: Bazı yapay zeka modelleri, aldıkları kararları açıklamak için sınırlı bir şeffaflık sunmaktadır. Örneğin, karar verme sürecinde hangi özelliklerin dikkate alındığı veya belirli bir sonucun nasıl elde edildiği konusunda detaylı bir açıklama sağlamak mümkün olmayabilir.

• Doğruluk ve Güvenilirlik: Yapay zeka modellerinin yorumlanması, modelin doğruluğunu ve güvenilirliğini değerlendirmek için önemlidir. Modelin yanlış kararlar verme olasılığı veya veri setlerindeki önyargılar, doğru yorumlanmadığı takdirde ciddi sonuçlara yol açabilmektedir.

• Hukuki ve Etik Yükümlülükler: Yapay zeka modellerinin kararlarının yorumlanması, hukuki sorumlulukları belirlemek ve etik standartlara uygunluğu sağlamak için önemlidir. Özellikle finansal veya tıbbi kararlar gibi kritik alanlarda, kararların doğru bir şekilde yorumlanması gereklidir.

• İnsan-Yapay Zeka Etkileşimi: Yapay zeka modellerinin yorumlanması, insan denetçilerle etkileşim içinde olmayı gerektirebilir. Modelin kararları hakkında doğru bir şekilde bilgi sahibi olmak ve gerektiğinde insan müdahalesi sağlamak, güvenilir ve etkin bir denetim süreci için önemlidir.

Bahsedilen zorluklar, yapay zeka modellerinin denetim süreçlerinde nasıl kullanılacağı konusunda dikkatlice düşünülmesini ve teknolojinin güvenilir ve şeffaf bir şekilde entegre edilmesini gerektirmektedir. Yapay zeka modellerinin doğru yorumlanması, kurumların riskleri etkin bir şekilde yönetmesine ve güvenilirliklerini artırmasına yardımcı olmaktadır. Örneğin, bir kredi risk değerlendirme sisteminde kullanılan derin öğrenme modelinin tahminleri, genellikle bir "kara kutu" gibi görünür; yani, modelin nasıl çalıştığı ve hangi verilerin kararları etkilediği şeffaf değildir. Bu durum, denetçiler için sorun oluşturabilir çünkü modelin sonuçlarını doğru bir şekilde değerlendirebilmek için modelin iç mekanizmalarını ve neden belirli kararlar verdiğini anlamak gerekir. Mesela, bir kredi başvurusu değerlendirirken modelin neden belirli bir başvuruyu yüksek riskli olarak sınıflandırdığını açıklayabilmek önemlidir.

Sürekli Güncelleme ve Adaptasyon

Yapay zekanın denetim süreçlerinde karşılaştığı önemli zorluklardan biri sürekli güncelleme ve adaptasyon gerekliliğidir. Yapay zeka modelleri, işletme koşulları ve veri girişimleri sürekli değiştiği için sürekli güncellenmeli ve adapte edilmelidir. Yeni veri kaynakları farklı formatlarda ve kalitede olabilir, bu da modellerin veri entegrasyonu ve uyum sorunlarına neden olabilmektedir. Modeller, işletme koşullarına veya düzenleyici değişikliklere uyum sağlayabilmek için düzenli olarak güncellenmeli ve yeniden eğitilmelidir. Bu süreç zaman ve maliyet gerektirmektedir. İşletme koşulları hızla değişebilir ve yapay zeka modellerinin bu değişikliklere hızlı adapte olması gerekebilir. Ani olaylar veya kriz durumları, adaptasyon sürecini zorlaştırmaktadır. Modellerin güncellenmesi ve adapte edilmesi

sırasında yerel veya uluslararası düzenleyici gereksinimlere uyum sağlamak önemlidir. Yeni düzenlemeler, modellerin nasıl güncelleneceği konusunda belirleyici olabilmektedir (Minkkinen v.dğr., 2022:5-7). Bu zorluklar, yapay zeka destekli denetim süreçlerinin etkinliğini ve güvenilirliğini sağlamak için dikkate alınmalıdır. İşletmeler, teknolojiden en iyi şekilde faydalanabilmek ve rekabet avantajını sürdürebilmek için sürekli güncelleme ve adaptasyon süreçlerini düzenlemelidir.

Finansal denetimlerde kullanılan makine öğrenmesi algoritmalarının regülasyonlardaki değişikliklere ayak uydurması bu alandaki örneklerden bir tanesidir. Örneğin, bir denetim şirketi, yapay zeka kullanarak dolandırıcılık tespitinde bulunuyorsa, yasal düzenlemeler ve finansal raporlama standartları sürekli olarak değişebilir. Bu durumda, yapay zeka sistemlerinin bu yeni regülasyonlara göre yeniden eğitilmesi gerekir. Eğer sistem bu güncellemeleri zamanında ve doğru şekilde adapte edilmez ise hem yanlış sonuçlar üretebilir hem de yasal uyumsuzluk riskini artırır.

İnsan ve Yapay Zeka İşbirliği

Yapay zekanın denetim süreçlerinde karşılaştığı önemli zorluklardan biri, insan ve yapay zeka işbirliğinin nasıl etkili bir şekilde yönetileceği konusudur. Bu işbirliği, bazı zorlukları içermektedir (Li, J. v.dğr., 2022:4-7):

• İşbirliği ve Güven İlişkisi: İnsanlar ve yapay zeka sistemleri arasında güvenilir bir işbirliği kurulması önemlidir. İnsanların yapay zeka sistemlerine olan güveni artırmak ve bu sistemlerin kararlarını anlamak, etkin işbirliği için kritik öneme sahiptir.

• Yapay Zekanın Sınırları ve Yetkinlikleri: İnsanlar ve yapay zeka sistemleri, kendi sınırları ve yetkinlikleri doğrultusunda nasıl işbirliği yapacaklarına dair net bir anlayışa sahip olmalıdır. Yapay zekanın analitik gücü ve insanların karar verme yetisi arasındaki dengeyi sağlamak önemlidir.

• Eğitim ve Yetkinlik Geliştirme: İnsanların yapay zeka teknolojilerini doğru bir şekilde kullanabilmeleri için eğitim ve yetkinlik geliştirme süreçleri gereklidir. Bu süreçler, hem teknik hem de etik açıdan yapay zeka ile etkili bir işbirliği sağlamak için önemlidir.

• Sorumluluk ve Hukuki Çerçeve: Yapay zeka sistemlerinin kararlarından kimin sorumlu olduğu ve bu süreçlerin yasal çerçeveler içinde nasıl yönetileceği belirleyici öneme sahiptir. İnsan ve yapay zeka işbirliğinin yasal sorumlulukları net bir şekilde tanımlanmalıdır.

Bu zorluklar, insan ve yapay zeka işbirliğinin başarılı bir şekilde yönetilmesi ve denetim süreçlerinde etkin kullanımı için dikkate alınmalıdır. Kurumlar, bu zorlukları aşabilmek ve yapay zekanın potansiyelinden en iyi şekilde faydalanabilmek için stratejik planlamalar ve uygun politikalar geliştirmeleri gerekmektedir. Örneğin, bir denetçi, finansal verilerdeki anormallikleri tespit etmek için yapay zeka destekli bir analiz aracı

kullanıyor olabilir. Yapay zeka çok sayıda veriyi hızlı bir şekilde işleyip anomalileri belirler, ancak bu anomalilerin gerçekten hata mı, dolandırıcılık mı yoksa yasal bir işlemin sonucu mu olduğunu anlamak için bazı koşullarda insan denetçilerin devreye girmesi gerekebilir. Bu işbirliği sürecinde, yapay zeka sonuçlarının doğru yorumlanmaması veya yapay zekanın belirli bir anomaliyi önemsemediği durumlar, insan ve makine işbirliğinde uyumsuzluğa neden olabilir.

SONUÇ

Yapay zekanın denetim aşamalarında kullanımının sunduğu potansiyeller, iş süreçlerinin etkinliğini ve doğruluğunu artırma olanağı taşırken, aynı zamanda çeşitli engellerle de karşı karşıya kalmaktadır. Bu çalışmada, yapay zeka kullanımının denetim süreçlerindeki potansiyelleri ve engelleri kapsamlı bir şekilde ele alınmıştır. Yapay zeka, otomatik veri işleme, sürekli denetim ve gerçek zamanlı izleme, gelişmiş analitik ve tahmin yetenekleri, maliyet tasarrufu, uyum ve regülasyon takibi gibi birçok alanda önemli faydalar sağlarken, aynı zamanda veri kalitesi, etik ve hukuki sorunlar, modellerin yorumlanması ve sürekli güncelleme gereksinimi gibi zorluklarla da karşı karşıya kalmaktadır.

Bu zorlukların aşılması, yapay zekanın denetim süreçlerinde etkili ve güvenilir bir şekilde kullanılmasını sağlamak için kritik öneme sahiptir. İşletmelerin, yapay zekayı başarıyla entegre edebilmek için insan ve yapay zeka iş birliğini etkin bir şekilde yönetmesi, sürekli güncellemelerle modellerin adaptasyonunu sağlaması ve etik ve hukuki gerekliliklere uygun hareket etmesi gerekmektedir. Sonuç olarak, yapay zekanın denetim süreçlerinde sunduğu fırsatları en iyi şekilde değerlendirmek ve karşılaşılan zorlukları aşmak hem denetim kalitesini artıracak hem de işletmelerin rekabet gücünü sürdürülebilir kılacaktır.

Bu çalışma, iç denetçiler, kamu denetçileri, bağımsız denetçiler ve akademisyenler için yapay zekanın denetim süreçlerindeki rolünü daha iyi anlamalarına ve bu alandaki bilgi birikimlerini artırmalarına yardımcı olmayı amaçlamıştır. Aynı zamanda, yapay zeka kullanımının sağladığı avantajlara ait finans sektörü, sağlık hizmetleri, kamuda satın alma işlemleri gibi pratik uygulamalara ait örnekler verilmiştir. Bununla birlikte denetim uygulamalarında karşılaşılan yapay zeka zorluklarını değerlendirebilmek için e-ticaret uygulamalarına, kredi risk değerlendirme süreçlerine ve finansal işlemlere ait pratik örneklerde verilmiştir.

Bu çalışma sonucunda elde edilen çıkarımlar sonucunda; iç denetçiler, yapay zekayı rutin ve tekrarlayan görevlerde kullanarak zaman kazanabilir ve risk yönetimi, kontrol süreçlerinin iyileştirilmesi gibi stratejik alanlara odaklanabilirler. Bununla birlikte, yapay zeka sistemlerinin işleyişini anlamak için eğitim programlarına yatırım yapmaları önerilebilir. Kamu

denetçileri, yapay zeka araçlarını regülasyon ve mevzuat uyumunu izlemek için etkin bir şekilde kullanması tavsiye edilebilir. Gerçek zamanlı izleme ve veri analitiği yoluyla potansiyel usulsüzlükleri erken tespit ederek kamu kaynaklarının korunmasını sağlamaları mümkündür. Bağımsız denetçiler, yapay zekanın sunduğu gelişmiş analitik ve tahmin yeteneklerinden yararlanarak finansal raporlamada doğruluk ve şeffaflığı artırabilirler. Bunun yanında, denetim süreçlerinde yapay zekayı kullanarak müşteri beklentilerini karşılayacak hızda ve derinlikte analizler sunmaları önemlidir. Sonuç olarak yapay zeka denetim süreci için dönüşüm potansiyeli taşırken, bu yararları tam olarak elde edebilmek için yapay zekanın sunduğu potansiyeller değerlendirilmeli ve engellerin dikkatlice ele alınması gerekmektedir.

REFERANSLAR

Abdennadher, S., Grassa, R., Abdulla, H., & Alfalasi, A. (2022). The effects of blockchain technology on the accounting and assurance profession in the UAE: An exploratory study. Journal of Financial Reporting and Accounting, 20(1), 53–71.

Abu Huson, Y., Sierra-García, L., & Garcia-Benau, M. A. (2024). A bibliometric review of information technology, artificial intelligence, and blockchain on auditing. Total Quality Management & Business Excellence, 35(1-2), 91-113.

Appelbaum, D., Kogan, A., & Vasarhelyi, M. A. (2017). Big Data and analytics in the modern audit engagement: Research needs. Auditing: A Journal of Practice & Theory, 36(4), 1-27.

Bughin, J., Hazan, E., Sree Ramaswamy, P., DC, W., & Chu, M. (2017). Artificial intelligence the next digital frontier. http://dln.jaipuria.ac.in:8080/jspui/bitstream/123456789/14268/1/MGI-artificial-intelligence-discussion-paper.pdf (Erişim Tarihi, 24 Haziran 2024).

Chowdhury, E.K. (eds.) (2021) The essentials of machine learning in finance and accounting: prospects and challenges of using artificial intelligence in the audit process. London, Taylor and Francis Inc.

Dimyadi, J., & Amor, R. (2017). Automating conventional compliance audit processes. In Product Lifecycle Management and the Industry of the Future: 14th IFIP WG 5.1 International Conference, (pp. 324-334). Springer International Publishing.

Efe, A., Tunçbilek, M. (2023). Yapay zekâ algoritmaları ile dönüşen denetim araçları üzerine bir değerlendirme. Denetişim Dergisi, (27), 72-102.

Florea, R., & Florea, R. (2016). Internal audit and risk Management. ISO 31000 and ERM approaches. Economy Transdisciplinarity Cognition, 19(1), 72-77.

Ghanoum, S. & Alaba, F., (2020). Integration of artificial intelligence in auditing: The effect on auditing process. (Yüksek lisans tezi). Kristianstad University, Sweden: Kristianstad.

Grewal, D. S. (2014). A critical conceptual analysis of definitions of artificial intelligence as applicable to computer engineering. IOSR Journal of Computer Engineering, 16(2), 9-13. https://doi.org/10.9790/0661-16210913

Haenlein, M., Kaplan, A., Tan, C. W., & Zhang, P. (2019). Artificial intelligence (AI) and management analytics. Journal of Management Analytics, 6(4), 341-343.

Hasan, A. R. (2021). Artificial Intelligence (AI) in accounting & auditing: A Literature review. Open Journal of Business and Management, 10(1), 440-465.

Huang, F., & Vasarhelyi, M. A. (2019). Applying robotic process automation (RPA) in auditing: A framework. International Journal of Accounting Information Systems, 35(4), 100433–100445.

Lee, C. S., & Tajudeen, F. P. (2020). Usage and impact of artificial intelligence on accounting: Evidence from Malaysian organisations. Asian Journal of Business and Accounting, 13(1). 213-239

Li, J., Huang, J., Liu, J., & Zheng, T. (2022). Human-AI cooperation: modes and their effects on attitudes. Telematics and Informatics, 73, 101862.

Li, L., Yan, J., Wen, Q., Jin, Y., & Yang, X. (2022). Learning robust deep state space for unsupervised anomaly detection in contaminated time-series. IEEE Transactions on Knowledge and Data Engineering, 35(6), 6058-6072.

Minkkinen, M., Laine, J., & Mäntymäki, M. (2022). Continuous auditing of artificial intelligence: A conceptualization and assessment of tools and frameworks. Digital Society, 1(3), 21.

Mitan, J. (2024). Enhancing audit quality through artificial intelligence: an external auditing perspective. https://scholarworks.uark.edu/acctuht/58/ (Erişim Tarihi, 25 Haziran 2024).

Moll, J., & Yigitbasioglu, O. (2019). The role of internet-related technologies in shaping the work of accountants: New directions for accounting research. The British Accounting Review, 51(6), 100833–100846.

Munoko, I., Brown-Liburd, H. L., & Vasarhelyi, M. (2020). The ethical implications of using artificial intelligence in auditing. Journal of business ethics, 167(2), 209-234.

Nonnenmacher, J., & Gómez, J. M. (2021). Unsupervised anomaly detection for internal auditing: Literature review and research agenda. International Journal of Digital Accounting Research, (21). 1-22.

Odoh, L. C., Echefu, S. C., Ugwuanyi, U. B., & Chukwuani, N. V. (2018). Effect of artificial intelligence on the performance of accounting operations among accounting firms in South East Nigeria. Asian Journal of Economics, Business and Accounting, 7(2), 1-11.

Omoteso, K. (2012). The application of artificial intelligence in auditing: Looking back to the future. Expert Systems with Applications, 39(9), 8490-8495.

Patel, R., Khan, F., Silva, B., & Shaturaev, J. (2023). Unleashing the potential of artificial intelligence in auditing: a comprehensive exploration of its multifaceted impact. Journal of Artificial Research , 4 (35), 41-57.

Ruiter, B. (2017). Towards a continuous auditing philosophy, (Yüksek lisans tezi). University of Twente, Twente.

Smith, S. S. (2018). Digitization and financial reporting – How technology innovation May drive the shift toward continuous accounting. Accounting and Finance Research, 7(3), 240–250.

Thelisson, E., Padh, K., & Celis, L. E. (2017). Regulatory mechanisms and algorithms towards trust in AI/ML. In Proceedings of the IJCAI 2017

workshop on explainable artificial intelligence (XAI), Melbourne, Australia (pp. 19-21).

Tiron-Tudor, A., Deliu, D., Farcane, N., Dontu, A. (2021) Managing change with and through block chain in accountancy organizations: a systematic literature review. Journal of Organizational Change Management 34(2):477–506.

Wassie, F. A., & Lakatos, L. P. (2024). Artificial intelligence and the future of the internal audit function. Humanities and Social Sciences Communications, 11(1), 1-13.

Zemankova, A. (2019). Artificial intelligence in audit and accounting: Development, current trends, opportunities and threats-literature review. In 2019 International Conference on Control, Artificial Intelligence, Robotics & Optimization (pp. 148-154). IEEE.

Zhang, C. A., Cho, S., & Vasarhelyi, M. (2022). Explainable artificial intelligence (xai) in auditing. International Journal of Accounting Information Systems, 46, 100572.

Zhang, Y., Xiong, F., Xie, Y., Fan, X., & Gu, H. (2020). The impact of artificial intelligence and blockchain on the accounting profession. IEEE Access, 8, 110461-110477.

Veritabanı Yönetim Sistemi Seçim Rehberi: Teknik ve İşlevsel Bakış Açısıyla İnceleme

Ebubekir SEYYARER[1]

1- Dr. Öğr. Üyesi; Van Yüzüncü Yıl Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü. eseyyarer@yyu.edu.tr ORCID No: 0000-0002-8981-0266

ÖZET

Bilgiye sahip olmak, günümüz toplumunda en önemli güç olarak kabul edilmektedir. Geçmişte enerji kaynakları ve tarım gibi unsurlar toplumları ayırt ederken, günümüzde bilgi en değerli kaynak haline gelmiştir. Bilgi, modern toplumlarda veri olarak depolanır ve veritabanı yönetim sistemleri (VTYS) aracılığıyla işlenir. İlişkisel VTYS'ler, dinamik sorgular ve veri geçerliliği için avantaj sağlarken, ilişkisel olmayan VTYS'ler hızlı veri erişimi gereksinimi olan durumlarda öne çıkar. İhtiyaçlara göre VTYS seçimi yapılması önerilirken, şirketlerin ilişkisel ve ilişkisel olmayan VTYS çözümlerini bir arada kullanabilecekleri hibrit yapılara yönelmeleri beklenmektedir. Özellikle büyük şirketler için veri güvenliği büyük bir öneme sahiptir. Veri güvenliğini sağlamak adına VTYS seçiminin yanı sıra kapsamlı bir güvenlik politikası oluşturulmalı ve sistemler güvenlik tehditlerine karşı önlemlerle desteklenmelidir. Oracle, Microsoft SQL Server, PostgreSQL gibi ilişkisel VTYS'ler yaygın olarak tercih edilirken, büyük veri için NoSQL VTYS modelleri performans açısından avantaj sunmaktadır.

Anahtar Kelimeler – Veri, Bilgi, Veritabanı, VTYS, İlişkisel VTYS.

GİRİŞ

Günümüz dünyasında bilginin sahibi olmak, en büyük güç olarak kabul edilmektedir. Bilgi toplumun en ayırt edici kriteri bu bilgileri elinde tutmaktır (Seyyarer ve Ayata, 2023). Petrol, doğal gaz gibi enerji kaynaklarını kullanmak, tarım arazilerini ekip biçmek ve çeşitli sanayi teknolojilerini kullanmak, önceki toplumların elindeki en büyük kriter olarak tanımlanmaktaydı (Tonta, 1999). Bu tür kriterlerden bilgi kriterine dönüşüm günümüzde birçok şeyi değiştirmiştir. Günümüzün petrolü olarak da adlandırılan bilgi, iletişim teknolojilerindeki gelişmeyle boyutları hızla artmaktadır. Bunların depolanması, korunması ve işlenmesi de ayrıca büyük önem arz etmektedir (Aktaş, 2007). Şekil 1'de bilgi piramidi gösterilmektedir. Ham verinin işlenip bilgeliğe giden yolunu göstermektedir. Günümüzde ise paraya veya güce dönüşen en büyük kaynak olarak gösterilmektedir.

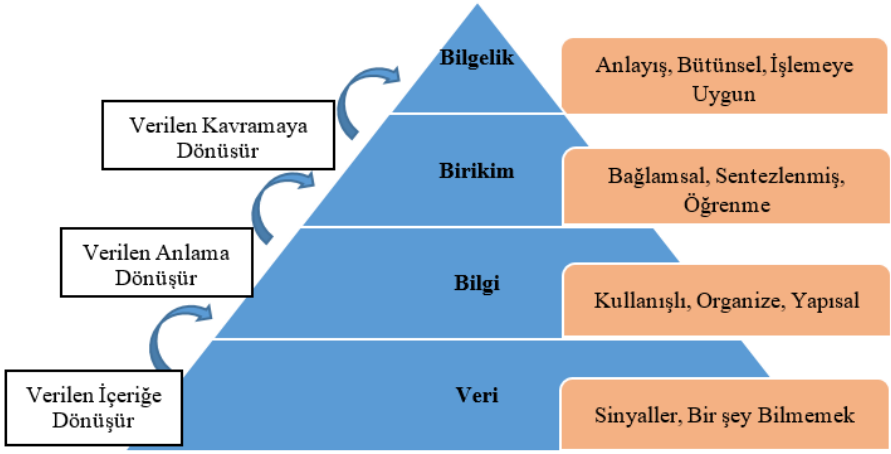

Şekil 1: Bilgi piramidi (Aydın vd., 2015)

Verilerin depolandığı yerlere veritabanı adı verilmektedir. Bir veritabanı, genellikle bir veri modeline göre depolanan birbiriyle ilişkili verilerin bir koleksiyonudur. Genellikle, veritabanı bir VTYS aracılığıyla bir veya birkaç yazılım uygulaması tarafından kullanılmaktadır. Veritabanı, VTYS ve yazılım uygulaması topluca bir veritabanı sistemi olarak adlandırılmaktadır (Taipalus, 2024). Tablo 1'de veritabanı ile VTYS'nin ayrıntılı karşılaştırılması gösterilmektedir.

Tablo 1: Veritabanı ve VTYS Arasındaki Fark (Geeksforgeeks, 2024)

Kategori	Veritabanı	VTYS
Tanım	Veritabanı, insanlar, konumlar veya nesneler hakkında birbirine bağlı bilgilerin bir koleksiyonudur.	VTYS, bir veritabanı oluşturmanıza, yönetmenize ve çalıştırmanıza olanak tanıyan programların bir koleksiyonudur.
Depolamak	Veritabanları, bilgisayarların yanı sıra fiziksel defterlerde veya kâğıtlarda da tutulabilir.	Bir VTYS'de tüm kayıtlar yalnızca bir bilgisayarda tutulur.
Veri Alma	Veritabanlarından bilgi alma işlemi manuel olarak, sorgular aracılığıyla veya programlar (C, C++, Java, vb.) kullanarak yapılabilir.	SQL dilinde yazılmış sorgular aracılığıyla veri tabanı yönetim sisteminden veriler alınabilir.
Hız	Veritabanları manuel olarak veya bilgisayarlar aracılığıyla yönetilebildiğinden, SQL kullanılarak bilgi alınamadığında çok yavaş olabilir.	Bir bilgisayar sistemi bir VTYS içerisinde yer aldığından, bilgiye erişim çok hızlıdır.
Erişim	Veritabanları, aynı anda verilere erişebilen çok sayıda kişi için değil, farklı zamanlarda verilere erişen çok az sayıda kişi (tercihen birkaç kişi) için tasarlanmıştır.	VTYS, verilere aynı anda erişebilen çok sayıda kişiye yönelik tasarlanmıştır.
Veri	Veriler veritabanlarında saklanır.	VTYS, verileri yönetir ve işler.
Veri Manipülasyonu	Veritabanlarında aynı anda çok az bilgi değiştirilebilmektedir.	VTYS aynı anda çok sayıda bilgi değiştirilebilir (çünkü aynı anda birçok kullanıcı tarafından kullanılabilir)
Yedekleme ve Kurtarma	Veritabanları, bir arıza ortaya çıktığında verilerin erişilebilir olacağını garanti etmez.	VTYS, sistem arızalarından sonra bile verilerin her zaman erişilebilir olmasını sağlar.

VTYS

VTYS, veritabanında verileri etkili bir şekilde oluşturmak, depolamak, almak ve yönetmek için kullanılan, birbiriyle ilişkili kapsamlı bir program setidir. Ayrıca erişim, güvenlik, depolama, büyük bir yapısal veri kümesini yönetmekten sorumludur ve veri bütünlüğünü korurken birden fazla eşzamanlı kullanıcıya veri erişimi sağlar. VTYS, veritabanları ile son kullanıcılar veya veritabanları ile uygulama programları arasında arayüzler olarak düşünülebilir. VTYS, sorgu dilleri adı verilen özel programlama dillerine dayanır (Mostafa, 2020).

VTYS'nin Özellikleri

Bir VTYS'nin aşağıdaki özelliklere veya buna benzer yapılara sahip olması beklenmektedir (Afteracademy, 2019, Palanisamy ve SuvithaVani, 2020).

❖ Gerçek Dünya Varlığı: Bir VTYS, mimarisini tasarlamak için gerçek dünya varlıklarını (nesnelerini) kullanmaktadır. Örneğin, bir müşteri veritabanında, müşteriler bir varlık olarak ve müşterinin telefon numarası ise bir öznitelik olarak alınmaktadır.

❖ İlişki Tabanlı Tablolar: VTYS kullanarak çeşitli varlıklar arasındaki ilişkilere dayalı tablolar oluşturulabilir. Örneğin, bir üniversite veritabanında, öğrenciler ve bölüm varlıkları olabilir. Yani, bir öğrencinin bir bölümde okuduğuyla ilgili öğrenci ve bölüm arasında bir ilişki vardır. Bu iki varlık arasındaki ilişkiye dayanarak iki tablo oluşturulabilir. Bir tablo, öğrenci_adı, öğrenci_sınıfı vb. gibi sütunlara sahip olan 'öğrenci' varlığına ait olacak ve diğer tablo, bölüm_adı, bölüm_şehri vb. gibi sütunlara sahip olan 'bölüm' varlığına ait olacak.

❖ Sorgu Dili: VTYS, kullanıcıların verileri depolamasına ve sorgu dili sayesinde bu verilere erişmesine olanak tanır. Gerektiğinde çeşitli filtreleme seçenekleri uygulanarak belirli sonuçlar elde edilebilir.

❖ Çoklu Görünümler: Kullanıcıya bağlı olarak aynı verinin farklı görünümlerini sağlar. Örneğin, bir üniversite veritabanında muhasebeci ile öğrencinin veri görünümü farklıdır. Muhasebeci, öğretmenlerin maaş bilgilerine erişebilirken öğrenciler bu bilgilere erişemez.

❖ Çoklu Kullanıcılar: VTYS, birden fazla kullanıcının aynı anda verilere erişebilmesine ve paralel olarak çalışabilmesine olanak tanır.

❖ ACID Özellikleri: VTYS'deki işlem (bir görev grubu) ACID (Atomik, Tutarlılık, Yalıtım, Dayanıklılık) kavramını takip eder. Atomiklik, işlemin gerçekleşeceği veya gerçekleşmeyeceği anlamına gelir. Tutarlılık, veritabanının durumunun işlemden önce ve sonra tutarlı olacağı anlamına gelir. Yalıtımda, bir işlem diğerlerinin çalışmasını etkilemez. Dayanıklılık, veritabanının dayanıklı olması ve bazı sistem arızalarından veya diğer hatalardan etkilenmemesi gerektiği anlamına gelir.

VTYS'nin Amaçları

VTYS, tipik dosya işleme sistemlerini destekleyen standart işletim sistemlerinin tüm dezavantajlarını yönetmek için oluşturulmuştur. VTYS'nin ulaşmayı başardığı hedeflerden bazıları veri fazlalığı ve tutarsızlığı, veri erişim zorlukları, bilgi izolasyonu, bütünlük sorunları, güncelleme atomikliği, birden fazla kullanıcı tarafından eşzamanlı erişim ve güvenlik sorunlarıdır. VTYS'yi kullanmak için daha fazla neden şunlardır (Mostafa vd., 2020, Palanisamy ve SuvithaVani, 2020, Sharma, 2017):

❖ Veri çoğaltmayı kontrol etmek ve belirli ayrıcalıklara sahip olmayan kullanıcıları kısıtlamak.

❖ Veri kaybı olmayan ve mevcut verilerden bilgi çıkarılmasına izin veren bir depolama ortamı sağlamak.

❖ Verileri kullanma ve değiştirmede ve son derece güncellenmiş veriler sağlamada aşırı esneklik.

❖ Kullanıcının verilerle etkileşimi için birden fazla arayüz sağlamak ve veriler arasındaki karmaşık ilişkileri kolayca temsil etmek.

❖ Güvenlik ve gizlilik kısıtlamalarının uygulanabilmesi ve veri bütünlüğünün korunması.

VTYS'nin Avantajları

Veritabanı çeşitli çalışmalarda büyük öneme sahiptir ve önemi birçok noktada vurgulanmıştır, bunlar arasında aşağıdaki özellikler yer alır (Mostafa vd., 2020, Palanisamy ve SuvithaVani, 2020, Sharma, 2017):

❖ İnsan potansiyelinin ötesinde büyük miktarda veri depolama.
❖ Verilerin entegre bir şekilde depolanması.
❖ Saklanan verilerdeki değişiklikleri izleme ve gerekli ayarlamaları yapma.
❖ Saklanan verilerin tam gizliliği.
❖ Verilerin depolanmasında ve geri alınmasında yüksek hız.

VTYS'nin Dezavantajları

Veritabanı Sisteminin aşağıdaki dezavantajları vardır (Geeksforgeeks, 2024, Afteracademy, 2019, Sharma, 2017):

❖ Maliyet: VTYS, donanım, yazılım ve eğitimli personel için yüksek bir ilk yatırım gerektirir. Organizasyonun büyüklüğüne ve işlevselliğine bağlı olarak önemli bir yatırım olmalıdır. Ayrıca organizasyon eş zamanlı yıllık bakım maliyeti ödemek zorundadır.
❖ Karmaşıklık: Bir VTYS birçok gereksinimi karşılar ve veritabanıyla ilgili birçok sorunu çözer. Ancak tüm bu işlevsellik VTYS'yi son derece karmaşık bir yazılım haline getirmiştir. Veritabanının geliştiricisi, tasarımcısı, yöneticisi ve son kullanıcısı, onu düzgün bir şekilde kullanmak istiyorlarsa tam becerilere sahip olmalıdır. Bu karmaşık sistemi anlamazlarsa veri kaybına veya veritabanı arızasına neden olabilir.
❖ Veritabanı Arızası: VTYS'deki tüm dosyalar tek bir veritabanında saklandığı için veritabanı arızası olasılığı daha fazla olur. Herhangi bir bileşenin kazara arızalanması değerli verilerin kaybına neden olabilir. Bu, büyük firmalar için gerçekten büyük bir soru işaretidir.
❖ Ek Donanım Maliyeti: Bir VTYS, veriler için disk depolama alanı gerektirir ve bazen verileri depolamak için ekstra alan satın alınması gerekir. Ayrıca bazen veritabanının daha iyi performansı için özel bir makineye ihtiyaç olur. Bu makineler ve depolama alanı, donanımın ekstra maliyetlerini artırır.
❖ Boyut: VTYS, işlevsellikleri nedeniyle büyük bir yazılım haline geldiğinden, uygulamasını verimli bir şekilde çalıştırmak için çok fazla alan ve bellek gerektirir. Veriler beslendikçe daha büyük bir boyut kazanır.
❖ Performans: Geleneksel dosya sistemleri, muhteşem performans sağladıkları için küçük kuruluşlar için çok iyiydi. Ancak VTYS, hızı yavaş olduğu için küçük ölçekli firmalar için zayıf performans sağlar.

VTYS Bileşenleri

Veritabanı sistemleri, entegre ve birbirine bağlı bir sistem oluşturan birkaç bileşenden oluşur. Şekil 2'de VTYS'nin tüm bileşenlerinin merkezlendiği nokta olan veriyi içeren veritabanı bileşenlerini ve ortamını göstermektedir:

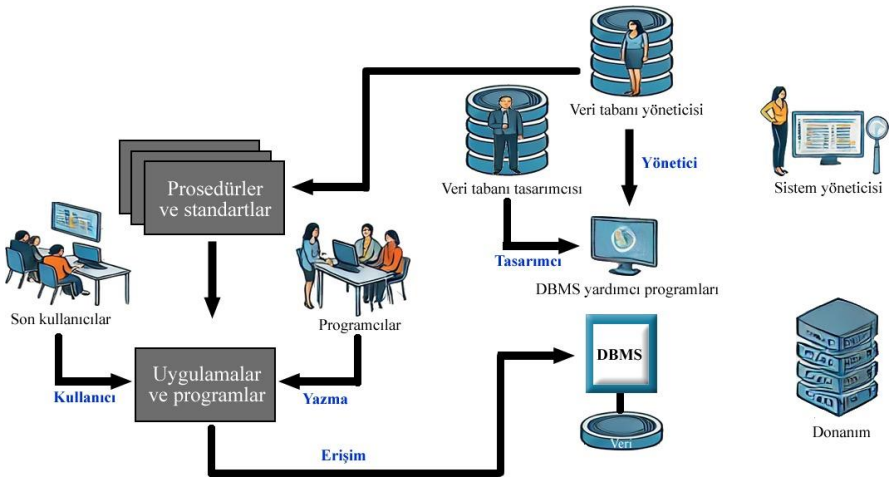

Şekil 2. VTYS bileşenleri ve ortamı (Sharma, 2017).

Verilerin bütünleyici, tekrarsız ve katılımcı olması gerekmektedir. Donanım ise veritabanlarının manyetik disklerde depolandığı yerdir. Disklerin üstündeki dosyalarda depolanan veriler ile veritabanı kullanıcıları arasında yer alan orta katmana 'Yazılım' denir; bu yazılım veritabanını yönetmek ve kontrol etmek için kullanılır. Veritabanlarını kullanan ve farklı işlemler gerçekleştiren dört kullanıcı grubu vardır: (1) Veritabanı Programcısı, bazı programlama dillerinde (Cobol, Java, Visual Basic veya C++) veritabanı uygulama programı yazan ve hiçbir hata olmadığından emin olmak için programı uygulayanlardır. (2) Veritabanı Yöneticisi, programların ve ekipmanların veritabanı gereksinimlerini belirlemekten, veritabanını çalıştırmaktan, güvenlik ve gizlilik koşullarını tanımlamaktan ve kullanım koşullarını belirlemekten sorumlu olanlardır. (3) Son Kullanıcılar, veritabanıyla ilgilenen ve veri ekleme, güncelleme ve silme gibi çeşitli işlemleri gerçekleştirenlerdir. (4) Prosedürler ise veritabanı sisteminin tasarımını ve kullanımını yöneten talimatlar ve kuralları içerir (Mostafa vd., 2020, Sharma, 2017).

VTYS'deki kullanıcılar

VTYS, birçok kullanıcının verilere erişmesi ve bunları alması için bir arayüz sağlar. Bu erişim türü, kullanıcının yazılım yeteneklerine bağlıdır. Bu

nedenle, bir VTYS'deki kullanıcılar, yazılım yetenekleri ve uzmanlıklarına göre aşağıdaki üç türe sınıflandırılabilir (Afteracademy, 2019):

❖ Uygulama Programcıları: Veritabanını yönetmek için yazılım programları yaparlar.

❖ Veritabanı Yöneticisi: Tüm veritabanı sistemini yönetmekten sorumlu olan kişilere veritabanı yöneticisi (DBA) denir.

❖ Son Kullanıcılar: VTYS yazılımlarını kullanan ve veri alma, silme, ekleme vb. gibi çeşitli işlemleri gerçekleştiren kişilerdir.

VTYS Modelleri

Bir veri modeli, veritabanı modeli olarak da adlandırılır. Veritabanının yapısını tanımlayan çerçeveyi temsil eder. Bu çerçeve, verilerin veritabanında nasıl saklanacağını açıklar, bu açıklama veri türünü, tablolar arasındaki ilişkileri, koşulları, kısıtlamaları ve tabloların kendilerini içerir. Verinin kendisi kelimenin tam anlamıyla bu çerçeve içinde bir veritabanında saklanacaktır. Bu nedenle, bir veri modeli oluşturmak veri ambarının tasarımında kritik bir adımdır. Birçok farklı veri modeli vardır (Mostafa vd., 2020). Charles Bachman tarafından 1960'lı yıllarda Genel amaçlı ilk VTYS, Bütünleştirilmiş Veri Depolama (Integrated Data Store) ismi ile tasarlanmıştır. Bu sayede 1973 yılında Turing ödülünü almıştır. Toplamda 4 tane VTYS modeli bulunmaktadır, bunlar hiyerarşik, ağ, ilişkisel ve nesne yönelimli VTYS yaklaşımlarıdır (Elvira vd., 2019). En çok tercih edilen ilişkisel VTYS yaklaşımı Peter Chen tarafından 1976 yılında tasarlanmıştır. Son yıllarda nesne yönelimli VTYS'ler de önerilmektedir (Vural ve Sağıroğlu, 2010, UKEssays, 2018).

A. Hiyerarşik Model (1970 – 1990)

1960'ların sonunda IBM tarafından ilk ticari VTYS tanıtılmıştır. Bu sistem, hiyerarşik modelin temelini oluşturmuş ve verileri bir ağaç yapısında modelleyerek o dönemin ana bilgisayarlarında yaygın biçimde kullanılmıştır. Hiyerarşik VTYS, bir kök kayıttan ve ona bağlı alt kayıtlardan oluşan bir yapıyı ifade eder. Alt kayıtlara ulaşmak için kök kayıttan başlayarak belirli bir yolu izlemek gereklidir. Bu tür sistemleri kullanacak yazılımı geliştiren kişinin ağaç yapısındaki yolları bilmesi zorunludur. Verilerin güncellenmesiyle yolların değişmesi, uygulamalar için sorunlara yol açabilmektedir (Vural ve Sağıroğlu, 2010, UKEssays, 2018).

❖ Avantajları: Hiyerarşik bir veritabanında kayıtlar arasında gezinmek, Kök/Yaprak ilişkileri gibi bir kayıttan diğerine işaretçilerle uygulandığından çok hızlıdır, veri paylaşımını teşvik eder ve veritabanı güvenliği sağlanmaktadır (Mostafa vd., 2020, Sharma, 2017).

❖ Dezavantajları: Hiyerarşik veritabanının birincil dezavantajı katı yapısıdır. Bir tabloya alan eklemek istiyorsanız, veritabanı yönetim sistemi

tarafından büyük kayıtlar için yeni bir tablo oluşturulmalıdır. Bir SQL veritabanının aksine, hiyerarşik modelde ALTER TABLE komutu yoktur. Ayrıca, yeni bir ilişki eklemek istiyorsanız, yeni ve potansiyel olarak yedekli bir veritabanı yapısı oluşturmanız ve fiziksel veri depolamanın özelliklerini bilmeniz gerekecektir (Mostafa vd., 2020, Sharma, 2017).

B. Ağ Modeli (1970 – 1990)

Cobol dilinin standartlarını oluşturan CODASYL (Conference on Data System Languages) grubu, bir VTYS modeline yönelik standartları belirlemek amacıyla DBTG (DataBase Task Group) adlı bir alt grup kurmuştur. Bu grup, çalışmalarının sonucunda önerdikleri VTYS modelini ağ şeması, alt şema ve dil olmak üzere üç bileşenle tanımlamıştır. Model, birçok yönden hiyerarşik modele benzerlik gösterse de bağlantı sayısında bir sınırlamanın olmaması ile ayrılmaktadır. Ancak, düğümler arasında çoklu bağlantı kurulamayışı modelin dezavantajı olarak öne çıkmaktadır (Vural ve Sağıroğlu, 2010, UKEssays, 2018).

❖ Avantajları: Ağ modeli kavramsal olarak basittir ve tasarımı kolaydır. Hiyerarşik model gibi, gerçek yaşam durumlarını modellemede gerçek bir yardım olan bire çok ve çoktan çoğa ilişkileri ele alabilir. Veri erişimi hiyerarşik modelden daha kolay ve esnektir. Ağ modeli, programları karmaşık fiziksel depolama ayrıntılarından izole etmede hiyerarşik modelden daha iyidir. Ayrıca, matematiksel küme teorisine dayanan bu model, ilişkili kayıtların bir bütünü olarak yapılandırılmıştır (Mostafa vd., 2020, Sharma, 2017).

❖ Dezavantajları: Tüm kayıtlar işaretçiler kullanılarak tutulur ve böylece veritabanının tüm yapısı çok karmaşık hale gelir. Herhangi bir kayıt işlemini eklemek, silmek ve güncellemek çok sayıda işaretçi ayarlaması gerektirir ve veritabanında yapısal değişiklikler yapmak çok zordur (Mostafa vd., 2020, Sharma, 2017).

C. İlişkisel Model (1980 – Halen Kullanılıyor)

E.F. Codd tarafından geliştirilen ilişkisel VTYS, tablo merkezli bir yapıya sahiptir. Varlıklar ve kayıtlara ait öznitelikler ile ilişkiler tablolarda tutulur; tabloların satırları kayıtları, sütunları ise bu kayıtların özniteliklerini temsil eder. IBM tarafından geliştirilen DB2, ilk ilişkisel VTYS modelidir. 1980'lerin sonlarına doğru farklı ilişkisel VTYS modelleri de ortaya çıkmıştır. Günümüzde en popüler ticari ilişkisel VTYS'ler arasında MS SQL Server, Oracle ve DB2 yer alırken, PostgreSQL ve MySQL gibi ücretsiz ilişkisel VTYS seçenekleri de yaygın olarak kullanılmaktadır (Vural ve Sağıroğlu, 2010, UKEssays, 2018).

❖ Avantajları: İlişkisel model, verileri karmaşıklıktan kaçınan bir şekilde yapılandırır, farklı kaynaklardan veri toplamak için diğer türlerden

daha esnektir. İlişkisel veritabanı, güvenilirlik, verileri düzenlemek için basit dizinleme ve tanımlanmış kısıtlamalar belirleyerek veri bütünlüğünü koruma sunar. İlişkisel model, özel araçlara ve özelliklere sahiptir ve tüm programlama dilleriyle kullanılabilir (Mostafa vd., 2020, Sharma, 2017).

❖ Dezavantajları: İlişkisel Veritabanı Sistemleri, veri depolaması gerektiren hemen hemen her alanda kullanılır. İlişkisel veritabanı yönetim sistemi, sağlam bir matematiksel temele dayanır ve yazılım sistemlerinin bulunduğu her yerde görünmelerine yardımcı olan çok sayıda veriyi işlemede çok güçlüdür. Ancak, resim koleksiyonları, video akışı koleksiyonları vb. gibi uygulamalarda, büyük miktarda karmaşık bilgiyi işlemede oldukça verimsiz görünmektedir. İlişkisel veri modeli, gerçek dünya nesnelerini temsil etmek için yeterli olmayan sınırlı miktarda veri türüne sahiptir ve ayrıca verileri ve veri ilişkilerini temsil etmek için yeterli değildir (Mostafa vd., 2020, Sharma, 2017).

D. Nesne Yönelimli Model (1990 – Halen Kullanılıyor)

1980'lerin ortalarında ortaya çıkan Nesne Yönelimli Programlama mimarisine dayanan bu model, verileri ilişkisel formata dönüştürmeden doğrudan nesne formatında saklar. Nesne Yönelimli Programlama özelliklerini kullanmasından dolayı, nesne yönelimli VTYS olarak bilinir. Yapısı gereği karmaşık bir modeldir, ancak arama işlemlerini hızlıca gerçekleştirebilir ve büyük tablolar üzerinde ilişkisel VTYS'lere göre daha yüksek performans sunar. Özellikle karmaşık veri modellerinin oluşturulması açısından avantajlı olsa da, yüksek maliyetleri nedeniyle ticari başarı elde edememiştir (Vural ve Sağıroğlu, 2010, UKEssays, 2018).

❖ Avantajları: Geleneksel veritabanlarının (hiyerarşik, ağ veya ilişkisel gibi) aksine, nesne yönelimli veritabanı, metin, sayılar vb. dahil olmak üzere resim, ses, video gibi farklı veri türlerini depolayabilir. Nesne yönelimli veritabanının en önemli özelliklerinden biri, karmaşık yapıdaki nesnelere başvurma yeteneğine sahip olması ve bunları karmaşık veri sunumları için ideal hale getirmesidir. Bilgisayarla Bütünleşik Üretim (CIM), Bilgisayar Destekli Tasarım (CAD), Bilgisayar Destekli Üretim (CAM), Bilgisayar Destekli Yazılım Mühendisliği (CASE) ve gelişmiş ofis otomasyon sistemi alanları, karmaşık grafik verileri ve hipermedya verilerini işlemek için nesne yönelimli veritabanı sistemleri kullanılmaktadır. Ayrıca, koruma ve güvenlik sistemlerinin nesne kavramına dayalı olmasını sağlamaktadır (Mostafa vd., 2020, Sharma, 2017).

❖ Dezavantajları: Bu modeli daha yaygın olan ilişkisel veritabanı modeliyle karşılaştırdığımızda, olgunlaşması için çok az zaman tanındığını görüyoruz, bu da sınırlı sayıda yetenekli programcı ve destekle sonuçlanmıştır. Nesne yönelimli model, nesneler olarak adlandırılan karmaşık veri yapılarını depolamaya odaklanır. Bu, basit veri kayıtlarında basit

ilişkilerle kullanıldığında daha az etkili hale getirir. Bu modelin bir diğer dezavantajı, saf uygulamanın zor olmasıdır. Bu doğrudur çünkü nesne yönelimli modeller, ilişkisel modellerin aksine, tablolar ve ilişkili dizinler gibi basit yapılara ihtiyaç duyan karmaşık veri türleri kullanmaktadır. İlişkisel veritabanları matematiksel küme teorisinin bir sonucudur, ancak nesne yönelimli tasarımlar için güçlü bir matematiksel temel yoktur (Mostafa vd., 2020, Sharma, 2017). Tablo 2'de varitabanı modellerinin ayrıntılı karşılaştırılması verilmektedir.

Tablo 2. Veritabanı modellerinin karşılaştırılması (Mostafa vd., 2020).

	Hiyerarşik	**Ağ**	**İlişkisel**	**Nesne yönelimli**
Tanımlanan Standart	Bilgi Yönetim Sistemi IMS (Information Management System)	Tümleşik Veri Deposu *Integrated Data Store (IDS)* ve *CA-IDMS (Integrated Database Management System)* Veri Tabanı Görev Grubu, DBTG (Data Base Task Group)	Yapısal Sorgulama Dili SQL (Structured Query Language) MySQL, Oracle, MS SQL Server, PostgreSQL	Nesne Veri Yönetimi *ObjectDB, db4o* (Database for Objects), *Versant Object Database* ODMG (Object Data Management Group)
Veri Organizasyonu	Dosyalar, Kayıtlar	Dosyalar, Kayıtlar	Tablolar	Nesneler
İlişki Türleri	Bire Bir (1:1) ve Bire Çok (1:N). Bu modelde ebeveyn-çocuk ilişkisi kurulmuştur ancak Çoka Çok (M:N) ilişkisi kurulamaz.	Bire Bir (1:1), Bire Çok (1:N) ve Çoka Çok (M:N) ilişkileri uygulanabilir.	Bire Bir (1:1), Bire Çok (1:N) ve Çoka Çok (M:N) ilişkileri uygulanabilir.	Çoka çok (M:N) ilişkileri, nesneler arasında kurulmuş ilişkiye sahip nesneleri birbirine bağlamak için kullanılır.
Desteklenen Matematik Fonksiyonlar	Desteklenmiyor	Desteklenmiyor	Sqrt(), min(), Max() ve sum() gibi birçok fonksiyonu destekler.	Kullanılan programlama diline göre matematiksel fonksiyonları destekler.
Veri Bütünlüğü	• Ebeveyni olmayan bir çocuğun bilgileri eklenemez. • Güncelleme işlemi sırasında tutarsızlık sorunu meydana gelir. • Ebeveynin silinmesi, çocuk kayıtlarının silinmesine neden olur.	Ekleme, Silme ve Güncellemede herhangi bir tutarsızlık ya da beklenmeyen durum oluşmaz.	Ekleme, Silme ve Güncellemede herhangi bir tutarsızlık ya da beklenmeyen durum oluşmaz.	Uygulama tarafından kontrol edilir.

Yukarıdaki karşılaştırmadan hiyerarşik ve ağ veri modellerinin etkili olduğunu, ancak karmaşık, esnek olmayan ve yönetilmesi ve sürdürülmesi zor olduğu anlaşılmaktadır. İlişkisel veri modelinde karmaşık veri ilişkilerini modellemek zordur, ancak nesne yönelimli veri modelinde bunu kolayca yapabilirsiniz çünkü kullanıcı herhangi bir yapı üzerine yöntemler yazabilir. İlişkisel veri modeli, veri depolama için tablo yapısını kullanır ve anlaşılması kolaydır, ancak nesne yönelimli veri modeli verileri depolamak için nesne kullanır ve bunu yalnızca mükemmel bir geliştirici anlayabilir. Nesne yönelimli veritabanı tamamen uygundur ve nesne yönelimli programlama diline uygun olarak yüksek hızda çalışır (Mostafa vd., 2020, Sharma, 2017).

İlişkisel ve ilişkisel olmayan (NoSQL) VTYS'ler

Dört VTYS modeli arasında, yapısal verilerin bulunduğu veritabanlarında en yüksek performansı ilişkisel VTYS'ler gösterir. Ancak, günümüzde giderek daha fazla yapısal olmayan veya düşük yapısal düzeyde veriyi barındıran veritabanlarında ilişkisel VTYS'lerin performansı azalmaktadır. Oracle, MySQL, Microsoft SQL Server ve PostgreSQL, günümüzde en popüler ilişkisel veritabanı sistemleri arasındadır. Yapısal olmayan verilerle çalışan Büyük Veri sistemlerine yönelik talebin artması, ilişkisel veritabanlarının depolama ve performans açısından bazı sınırlamalarla karşılaşmasına yol açmıştır (Vural ve Sağıroğlu, 2010). Bu zorlukları aşmak için, NoSQL (Non SQL) modelleri popüler VTYS çözümleri olarak öne çıkmaktadır (Samaraweera ve Chang, 2019). Şekil 3'te ilişkisel ve ilişkisel olmayan VTYS modellerinin ayrımı gösterilmektedir.

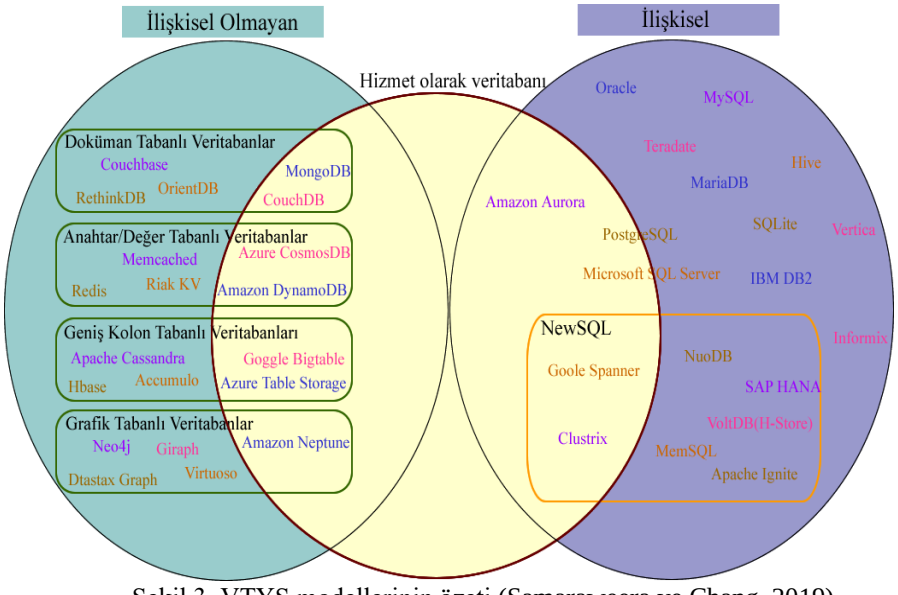

Şekil 3. VTYS modellerinin özeti (Samaraweera ve Chang, 2019).

NoSQL sistemleri, ilişkisel VTYS'lere göre birçok avantaj sunar; düşük gecikme süresi, yüksek ölçeklenebilirlik, esneklik ve eşzamanlı işlem yeteneği gibi özelliklere sahiptir. İlk kez 1980'lerde kullanılan "NoSQL" terimi, başlangıçta arayüzü olmayan ilişkisel veritabanlarını tanımlıyordu; ancak 2009 itibarıyla ilişkisel olmayan VTYS'leri tanımlamak için yeniden popüler hale geldi. NoSQL sistemleri, dört temel türe ayrılmaktadır.

Tablo 3. İlişkisel ve ilişkisel olmayan VTYS'lerin karşılaştırılması (Garba ve Abubakar, 2020).

Parametreler	İlişkisel Veritabanları	İlişkisel OlmayanVeritabanları
Veritabanı modeli	Bu model veritabanı, İlişkisel veritabanı (RDBMS) olarak da bilinen İlişkisel yaklaşıma dayanmaktadır.	Modelsiz yaklaşıma dayanan bu veritabanı modeli, ilişkisel olmayan veya NoSQL veritabanı olarak da bilinir.
Veri Biçimi	Yapılandırılmış verileri, birleşimler veya tablolar arasındaki ilişkilerle birlikte tablo biçiminde (sütunlar, satırlar) depolar.	Grafik veritabanı, Anahtar-değer çiftleri, Belge deposu veya Sütun Ailesi gibi çeşitli depolama türleriyle yapılandırılmamış veri yaklaşımını depolar.
Şema	Tüm veriler önceden tanımlanmış tablo veya yapılara sığmalıdır.	NoSQL şeması yüksek esnekliğe ve dinamiğe sahiptir.
Ölçekleme	İlişkisel veritabanları dikey olarak ölçeklenebilirdir, yani donanımın (CPU, RAM, sabit disk vb.) gücünü artırırlar.	Bunlar yatay olarak ölçeklenebilirdir, yani makineleri veya veritabanı sunucularını artırarak kapasiteyi artırırlar.
Sorgulama Dili	Yapısal Sorgulama Dili (SQL), verilerin işlenmesi ve tanımlanması için kullanılan veritabanı dilidir.	NoSQL için özel bir sorgu dili yoktur. Bazen NoSQL'de Yapısız Sorgu Dili (UnQL) kullanılır. Sözdizimi de veritabanları için farklıdır. Çoğu NoSQL veritabanı üreticisi kendi ürünleri için sorgu dilleri oluşturmuştur.
İşlemsel Operasyon	SQL, veri silme, ekleme ve güncelleme işlemlerinin yüksek olduğu durumlarda en iyisidir.	Veri seçimi konusunda NoSQL veritabanları daha iyidir.
İşlemsel Özellikler	SQL veritabanları Atomiklik, Tutarlılık, Yalıtım ve Dayanıklılık (ACID) özelliklerini kullanır.	NoSQL veritabanlarında Tutarlılık, Erişilebilirlik ve Bölümleme Toleransı (CAP teorisi) kullanılmaktadır.
Tutarlılık	İlişkisel veritabanlarında, tüm kullanıcıların işlem yaptıktan sonra aynı verileri görüntülemesi gerekir. Bu, ilişkisel olmayan veritabanlarına göre daha iyi tutarlılık sağlar.	Nihai Tutarlılık, işlemlerden sonra okuma ve yazmayı garanti eder. Tüm veritabanı varlıkları anında tutarlı olacaktır.
Normalizasyon / Ters Normalizasyon	Normalizasyon ilişkisel veritabanlarında kullanılır. Performans iyileştirmesi için tek bir tablo birkaç küçük tabloya bölünür.	Ters normalizasyon ilişkisel olmayan bir veritabanıyla uygulanır. Kayıt depolaması için tek bir tablo kullanılır. Seçme, Güncelleme, Silme ve Ekleme gibi işlemler kolay olmayacaktır.
Veri Bütünlüğü	İlişkisel veritabanlarında karşılaştırma yapmak, tutarsız verilerin veritabanında depolanmasını önleyecek ve tüm yinelenen kayıtları kaldıracaktır.	İlişkisel olmayan veritabanlarında veri çoğaltma yoktur. Düz veritabanları her adresi manuel olarak günceller ve tutarlılığı sağlar.
Veri Alma	İlişkisel veritabanlarında, birincil anahtar tablosu aracılığıyla istenen kayda erişen SQL kullanılır.	Kayda erişmek için birden fazla ölçüt kullanmak verimsizdir. Bu, ilişkisel olmayan bir veritabanında bulunabilir. Eşleşmeler için kayıt incelenmeden önce birkaç geçiş gerekir.
Veri İşleme	İlişkisel veritabanı, verileri işlemek için Veri İşleme dilini (DDL) kullanır.	HTTP PUT, DELETE ve POST, JSON, Thrift ve RDF gibi çeşitli formatlara sahip İlişkisel Olmayan Veritabanları tarafından kullanılan RESTful arayüzlerdir. Ayrıca, Google veri deposu gibi Veri işleme API'leri de kullanılmaktadır.
Özellikler	İlişkisel VTYS'nin temel bir olanağı olan bakım, veritabanı yöneticisine	Hiçbir şeyi paylaşmamak NoSQL veritabanının temel bir özelliğidir. Verilerin birkaç sunucu arasında yatay

	araçlar sunarak onarım, yedekleme ve test işlemlerini kolaylaştırır.	ölçeklenmesi, bölümlenmesi ve çoğaltılması yoluyla çalışır

VTYS Yaklaşımların Güvenlik Açısından Karşılaştırılması

Veritabanındaki verilere doğrudan erişim kesinlikle engellenmeli ve veriler en üst düzey güvenlik önlemleriyle korunmalıdır. Kişi veya kuruluşların izinsiz olarak veritabanına erişimi ciddi bir güvenlik açığı olarak değerlendirilir (Latchoumi vd., 2020). Güvenlik açısından, tüm VTYS yaklaşımlarının benzer önlemler sağlaması beklenir. VTYS seçiminde ise güvenlik, hız ve maliyet faktörleri dikkate alınarak karar verilmelidir (Samaraweera ve Chang, 2019). Tablo 4'te İlişkisel ve ilişkisel olmayan VTYS'lerin güvenlik servisleri kıyaslanmaktadır.

Tablo 4. İlişkisel ve ilişkisel olmayan VTYS'lerin karşılaştırılması (Garba ve Abubakar, 2020, Ayata ve Seyyarer, 2022).

Parametreler	İlişkisel Veritabanları	İlişkisel Olmayan Veritabanları
Kimlik doğrulama	İlişkisel veritabanları genellikle, uygulandığında kullandıkları bir kimlik doğrulama mekanizmasına sahiptir	Çoğu NoSQL veritabanı varsayılan olarak kimlik doğrulama mekanizmasına sahip olmayacak şekilde ayarlanmıştır ancak bunu başarmak için harici yöntemler kullanır.
Veri Bütünlüğü	İlişkisel veritabanlarında veri bütünleştirme ACID özellikleri kullanılarak gerçekleştirilir.	NoSQL'de veri bütünlüğüne kolayca ulaşılamıyor. BASE özellikleri tek tutarlı ilkedir.
Gizlilik	İlişkisel veritabanlarında verilerin gizliliği, verilerin saklanmasında şifreleme teknikleri kullanılarak sağlanır.	Verilerin açık bir şekilde depolanmaktadır. Veri gizliliği yok.
Denetim	Verilerin syslog veya xml dosyalarına yazılmasına izin veren denetim olanağı mevcuttur.	NoSQL veritabanları çoğunlukla denetim sağlamaz. Bazıları sağlar, ancak kullanıcı adı ve parolalar bir günlük dosyasında saklandığından ve bu bir güvenlik açığı olduğundan sorunlarla karşılaşılabilir.
Kullanıcı iletişimi	Güvenli kullanıcı iletişim mekanizmasının sağlanması şifreleme ve SSL protokolü ile yapılmaktadır.	Çoğu NoSQL veritabanında bu sağlanmaz.

SONUÇ

Dinamik sorgular yapabilmek ve veri geçerliliğinde gerekli olan ACID sorunlarını çözmek için İlişkisel VTYS'ler öne çıkmaktadır. İlişkisel olmayan VTYS'lerde ise veriye hızlı erişim ön plana çıkmaktadır. Gereksinimlere veya imkanlara göre VTYS seçilmesi gerekmektedir. İlişkisel VTYS'lere olan ilgi yakın zamanda bitmeyecektir. Şirketler ilişkisel VTYS'lerin yanında İlişkisel olamayan VTYS çözümlerini de deneyimleyeceklerdir. Hatta ikili çözümler ya da hibrit yapılar üzerinde duracaklardır. Belirli bir VTYS'ye karar vermeden önce, ihtiyaç duyduğu veri deposunu göz önünde bulundurarak var olan çeşitli VTYS teknolojilerinin farklı yönlerini gözden geçirmek akıllıca

olacaktır. Özellikle büyük şirketlerin veri gizliliği ve güvenliliği konusuna önem vermeleri gerekmektedir. Saldırılara karşı etkili bir koruma sağlamak için, seçilen VTYS modelinin güvenlik özelliklerine ek olarak kapsamlı bir güvenlik politikası oluşturulmalı, bu politika alanında uzman kişiler tarafından yönetilmeli, verilerin kayıpsız yedeklenmesi sağlanmalı ve sistem saldırıya uğradığında yedek sistemin farklı bir lokasyonda devreye girebilmesi gibi önlemler alınmalıdır. Günümüzde en yaygın kullanılan ilişkisel VTYS modelleri arasında Oracle, Microsoft SQL Server ve PostgreSQL öne çıkmaktadır. Büyük veri sistemlerinde ise performans avantajı sunması nedeniyle NoSQL VTYS modellerinin tercih edilmesi önemli bir seçenektir.

REFERANSLAR

Afteracademy. (2019). "What is a Database and DBMS?". (Erişim Tarihi: 25.10.2024). https://afteracademy.com/blog/what-is-a-database-and-dbms/.

Aktaş, C. (2007). Enformasyon toplumu bağlamında Türkiye. Selçuk İletişim, 4(4), 181-193.

Ayata, F., ve Seyyarer, E., (2022). The Most Important Defense System of the Technology Age: Cyber Security. Yenilenebilir Kaynaklardan Elde Edilen Malzemeler ve Uygulamaları (pp.131-141), İstanbul: Artikel Akademi.

Aydın, H., Mutlu, M. E., Karadağ, N., Usta, İ., Aydın, S., Çalışkan, H., ... ve Okur, M. R. (2015). Temel Bilgi Teknolojileri. Anadolu Üniversitesi Yayınları. Eskişehir.

Elvira, N. I. C. A., Dusmanescu, D. M., Popescu, G., ve Breaz, L. A. M. (2019). Databases Security Issues-A Short Analysis on The Emergent Security Problems Generated by NoSQL Databases.

Garba, M., ve Abubakar, H. (2020). A comparison of NoSQL and relational database management systems (rdbms). Kasu Journal of Mathematical Sciences, 1(2), 61-69.

Geeksforgeeks. (2024). "Difference Between Database and DBMS". (Erişim Tarihi: 20.10.2024). https://www.geeksforgeeks.org/difference-between-database-and-dbms/.

Latchoumi, T. P., Reddy, M. S., ve Balamurugan, K. (2020). Applied machine learning predictive analytics to SQL injection attack detection and prevention. European Journal of Molecular & Clinical Medicine, 7(02), 2020.

Mostafa, S. A., AbuSalim, S. W., ve Saringat, M. Z. (2020). A Comparative Study of Data Management Systems. Journal of Soft Computing and Data Mining, 1(1), 10-16.

Palanisamy, S., ve SuvithaVani, P. (2020, January). A survey on RDBMS and NoSQL Databases MySQL vs MongoDB. In 2020 International Conference on Computer Communication and Informatics (ICCCI) (pp. 1-7). IEEE.

Samaraweera, G. D., ve Chang, J. M. (2019). Security and privacy implications on database systems in Big Data era: A survey. IEEE Transactions on Knowledge and Data Engineering, 33(1), 239-258.

Sharma, N. (2017). Overview of the Database Management System. International Journal of Advanced Research in Computer Science, 8(4).
Seyyarer, E., ve Ayata, F. (2023). Veritabanı Güvenliği. Nobel Yayınevi, ss.123-144.
Taipalus, T. (2024). Database management system performance comparisons: A systematic literature review. Journal of Systems and Software, 208, 111872.
Tonta, Y. (1999). Bilgi Toplumu ve Bilgi Teknolojisi. Türk Kütüphaneciliği, 13(4), 363–375.
UKEssays. (November 2018). The Evolution of Database Management System. Retrieved from https://www.ukessays.com/essays/information-technology/the-evolution-of-database-management-system-information-technology-essay.php?vref=1.
Vural, Y., ve Sağıroğlu, Ş. (2010). Veritabanı yönetim sistemleri güvenliği: tehditler ve korunma yöntemleri. Politeknik dergisi, 13(2), 71-81.

Dinamik Özellik Seçimi Problemlerinde Meta-Sezgisel Yaklaşımlar

Emrullah GAZİOĞLU[1]

1- Dr. Öğr. Üyesi.; Şırnak Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü. gazioglu@sirnak.edu.tr ORCID No: 0000-0002-7615-305X

ÖZET

Bu çalışmada, dinamik özellik seçimi problemleri ve bu problemlerin çözümünde meta-sezgisel yaklaşımların kullanımı detaylı bir şekilde ele alınmıştır. Dinamik özellik seçimi, değişken ve zamanla değişen veri yapılarında, belirli bir görev için en uygun özellik alt kümesini belirlemeyi hedefleyen karmaşık bir optimizasyon problemidir. Özellikle gerçek zamanlı veri kaynakları ve sürekli güncellenen dinamik veri ortamları, bu alandaki geleneksel yöntemlerin yetersizliğini ortaya koymuştur. Meta-sezgisel algoritmalar, geniş çözüm uzaylarında etkili bir şekilde arama yapabilme, değişen koşullara hızla adapte olma ve global optimuma ulaşma yetenekleriyle bu problemleri çözmede güçlü bir araç olarak öne çıkmaktadır. Meta-sezgisel algoritmaların kullanımını destekleyen en önemli faktörlerden biri, bu yöntemlerin değişen veri koşullarında esneklik ve yüksek performans sunabilmesidir. Özellikle dinamik özellik seçimi gibi sürekli adaptasyon gerektiren senaryolarda, geleneksel yaklaşımların eksik kaldığı durumlarda meta-sezgisel yöntemler, uyarlanabilirlikleriyle öne çıkmaktadır. Çalışmada, genetik algoritmalar, parçacık sürü optimizasyonu ve tabu arama gibi meta-sezgisel yöntemlerin dinamik veri ortamlarındaki etkinlikleri incelenmiştir. Dinamik veri kümelerinin doğası, özellik seçimi süreçlerinde karşılaşılan zorluklar ve meta-sezgisel yöntemlerin bu bağlamdaki adaptasyon teknikleri detaylı bir şekilde değerlendirilmiştir. Ayrıca, sağlık, finans, IoT ve doğal dil işleme gibi çeşitli uygulama alanlarında meta-sezgisel yaklaşımların nasıl kullanıldığına dair örnekler sunulmuştur. Bu yöntemlerin teorik ve pratik katkıları, dinamik özellik seçimi problemlerinin çözümünde sağladıkları faydalarla vurgulanmıştır. Çalışma, aynı zamanda hibrit yöntemlerin ve büyük veri ortamlarında kullanılabilecek çözümlerin geliştirilmesine yönelik öneriler sunmaktadır.

Anahtar Kelimeler - Dinamik Ortamlar, Evrimsel Algoritmalar, Meta-Sezgisel Yaklaşımlar, Dinamik Özellik Seçimi, Zaman Serileri.

GİRİŞ

Dinamik özellik seçimi, değişken veya zamanla değişen veri yapılarında belirli bir görev için en uygun özellik alt kümesini belirlemeyi amaçlayan bir optimizasyon problemidir. Özellik seçimi, makine öğrenimi ve veri madenciliği süreçlerinde kritik bir adımdır. Yüksek boyutlu veri kümeleri üzerinde yapılan analizlerde gereksiz veya etkisiz özelliklerin bulunması, modellerin hem hesaplama maliyetini artırabilir hem de performansını düşürebilir. Bu nedenle, özellikle karmaşık ve büyük veri setlerinde özellik seçimi hem teorik hem de pratik açıdan önemli bir araştırma alanıdır. Ancak, bu süreç statik veri kümelerinde uygulanmak üzere geliştirilmiş geleneksel

yöntemlerle sınırlandırıldığında, dinamik ve değişken veri ortamlarının ihtiyaçlarına yanıt vermede yetersiz kalabilir (Gazioğlu & Etaner-Uyar, 2022).

Dinamik özellik seçimi, zamanla değişen veri kaynaklarında sürekli olarak güncellenen bir özellik alt kümesi belirlemeyi içerir. Dinamik ortamlar, veri dağılımlarının değiştiği, yeni özelliklerin ortaya çıktığı veya mevcut özelliklerin önem derecelerinin zaman içinde farklılık gösterebildiği senaryoları kapsar. Örneğin, gerçek zamanlı sağlık verileri, finans piyasalarındaki dalgalanmalar veya IoT cihazlarından sürekli gelen veri akışları gibi durumlar, dinamik veri ortamlarının yaygın örneklerindendir. Bu tür ortamlarda, geleneksel yöntemlerin sınırlılıkları, özellikle çözümün uyarlanabilirliği ve hesaplama verimliliği açısından belirginleşir (Dokeroglu vd., 2022).

Meta-sezgisel algoritmalar, bu bağlamda güçlü bir araç olarak öne çıkar. Bu algoritmalar, geniş bir çözüm uzayında etkili bir şekilde arama yapabilme ve değişen koşullara adapte olabilme yetenekleriyle dinamik özellik seçimi problemlerinde umut vaat etmektedir. Özellikle Genetik Algoritmalar, Parçacık Sürü Optimizasyonu (PSO) ve tabu arama gibi yöntemler, dinamik problemlere uyarlanabilmeleri sayesinde geniş bir uygulama alanına sahiptir. Bu yöntemlerin bir diğer avantajı, lokal optimumlarda takılmadan global optimum çözümlere ulaşma potansiyeline sahip olmalarıdır (Reeves & Rowe, 2002).

Bu bölümde, dinamik özellik seçimi probleminin temel zorlukları ve meta-sezgisel yaklaşımların bu zorluklara nasıl çözümler sunduğu incelenmektedir. Öncelikle, dinamik veri kümelerinin özellik seçimi üzerindeki etkisi detaylandırılmakta, ardından meta-sezgisel yöntemlerin bu bağlamdaki adaptasyon teknikleri ele alınmaktadır. Son olarak, bu yöntemlerin performans ölçütleri ve farklı uygulama alanlarındaki başarıları değerlendirilmektedir. Dinamik ortamların doğasına uygun optimize edilmiş çözümler geliştirmek hem akademik araştırmalar hem de gerçek dünya uygulamaları için önemli bir hedef olarak karşımıza çıkmaktadır. Bu çalışmada, özellikle dinamik problemlerde meta-sezgisel yöntemlerin kullanımıyla sağlanan katkılar vurgulanmaktadır.

ÖZELLİK SEÇİMİ PROBLEMLERİ VE DİNAMİK ORTAMLAR

Özellik Seçiminin Temel Kavramları

Özellik seçimi, bir veri kümesindeki en uygun alt özellik kümesini belirlemeye yönelik bir optimizasyon sürecidir ve makine öğrenimi ile veri madenciliği uygulamalarında temel bir adımdır. Yüksek boyutlu veri kümelerinde, tüm özelliklerin modele dahil edilmesi, hesaplama maliyetlerini artırabilir ve aşırı öğrenme gibi sorunlara yol açabilir. Özellikle gereksiz veya önemsiz özelliklerin veri setinde yer alması, modelin genelleme yeteneğini

olumsuz etkileyebilir. Bu nedenle, en uygun özellik alt kümesinin seçilmesi, modellerin hem doğruluğunu artırmak hem de işlem süresini azaltmak için kritik öneme sahiptir.

Özellik seçimi yöntemleri genellikle üç ana kategoriye ayrılır: filtre yöntemleri, sarmalayıcı yöntemler ve gömülü yöntemler. **Filtre yöntemleri**, modelden bağımsız olarak çalışır ve genellikle istatistiksel ölçütler veya skorlar kullanılarak özelliklerin sıralanmasını sağlar. Bu yöntemler hızlı ve hesaplama açısından düşük maliyetlidir, ancak özellikler arasındaki etkileşimleri dikkate almazlar (Rodriguez-Galiano vd., 2018). **Sarmalayıcı yöntemler**, özellik alt kümelerini değerlendirirken belirli bir öğrenme algoritmasını kullanır. Daha yüksek doğruluk oranları sağlasa da bu yöntemler genellikle daha fazla hesaplama gücü gerektirir (Kohavi & John, 1997). **Gömülü yöntemler** ise öğrenme sürecine entegre edilen bir özellik seçimi stratejisi sunar ve genellikle düzenlileştirme teknikleriyle birlikte kullanılır.

Tüm bu yöntemler, statik veri kümeleri için geliştirilmiştir ve genellikle sabit bir veri yapısına uyum sağlar. Ancak, dinamik özellik seçimi gerektiren durumlarda, bu yöntemlerin sınırlılıkları ortaya çıkar. Özellik seçimi sürecinin, değişen veri yapısına adaptasyon gerektirdiği senaryolar için geliştirilmesi, bu alandaki en önemli zorluklardan biridir.

Statik ve Dinamik Özellik Seçimi Arasındaki Farklar

Statik ve dinamik özellik seçimi yöntemleri, veri yapısının zaman içindeki değişimine verdikleri tepki açısından farklılık gösterir. **Statik özellik seçimi**, sabit veri kümeleri üzerinde çalışır ve bir kez seçilen özelliklerin analiz boyunca değişmeden kaldığını varsayar. Bu yöntemler, veri dağılımlarının sabit olduğu durumlarda etkili olsa da zamanla değişen veya dinamik veri kaynaklarında yetersiz kalabilir. Örneğin, finans piyasalarından alınan bir veri kümesi incelendiğinde, piyasa koşullarının zamanla değişebileceği göz önüne alınmalıdır. Ancak statik yöntemler, bu değişimleri yakalamaktan acizdir (Restrepo vd., 2020).

Buna karşın, **dinamik özellik seçimi**, veri yapısının sürekli olarak güncellendiği durumlarda çalışır. Bu yöntemler, veri akışı sırasında özelliklerin önem derecelerinin değişebileceğini, yeni özelliklerin ortaya çıkabileceğini veya bazı özelliklerin artık geçerli olmayabileceğini dikkate alır. Örneğin, gerçek zamanlı sağlık verileri üzerinde yapılan bir analizde, hastanın mevcut durumuna bağlı olarak belirli biyolojik sinyallerin önemi değişebilir. Dinamik yöntemler, bu değişikliklere adapte olarak her bir durumda en uygun özellik alt kümesini seçmeye çalışır (Gazioğlu & Etaner-Uyar, 2022).

Dinamik özellik seçimi, veri analizi süreçlerine daha fazla esneklik katarken, aynı zamanda algoritmaların daha karmaşık ve hesaplama açısından maliyetli olmasına neden olabilir. Özellikle veri dağılımlarındaki değişikliklerin hızlı bir şekilde algılanması ve bu değişimlere uygun çözümler geliştirilmesi, dinamik yöntemlerin başarısı için kritik bir rol oynar.

Dinamik Veri Kümelerinin Doğası

Dinamik veri kümeleri, zaman içinde değişen veri kaynaklarını temsil eder ve özellik seçimi problemlerinde önemli zorluklar doğurur. Bu tür veri kümeleri, genellikle akış hâlinde gelen verilerden oluşur ve belirli bir zaman diliminde özellikler arasındaki ilişkiler değişebilir. Örneğin, hava durumu tahmini, finansal piyasa analizleri veya IoT cihazlarından gelen gerçek zamanlı veriler gibi durumlarda, verilerin istatistiksel özellikleri sabit kalmaz. Bu, özellik seçimi süreçlerinde sürekli bir güncellemeyi gerektirir (Allioui & Mourdi, 2023).

Dinamik veri kümelerinde karşılaşılan önemli bir zorluk, veri yapısının heterojen ve belirsiz olabilmesidir. Bu tür veri ortamlarında, bazı özellikler zamanla daha önemli hâle gelirken, diğerleri önemsizleşebilir veya tamamen ortadan kalkabilir. Ayrıca, yeni özelliklerin eklenmesi ya da mevcut özelliklerdeki eksiklikler gibi durumlar da analiz sürecini etkiler. Örneğin, bir akıllı şehir sisteminde, trafik sensörlerinden gelen veriler günün saatine göre farklı özelliklerin önemini ortaya koyabilir. Sabah saatlerinde trafik yoğunluğu belirleyici bir özellik olurken, gece saatlerinde bu özellik önemsizleşebilir. Dinamik yöntemler, bu değişimlere uyum sağlayarak optimal özellik alt kümesini belirlemeyi hedefler.

Dinamik veri kümelerinin bir diğer önemli özelliği, veri hacmindeki sürekli artış ve veri akışındaki düzensizliktir. Bu durum hem hesaplama maliyetlerini artırır hem de özellik seçimi süreçlerini daha karmaşık hâle getirir. Özellikle gerçek zamanlı analizlerde, bu veri akışını etkili bir şekilde işleyebilecek yöntemler geliştirilmesi kritik bir gereklilik olarak karşımıza çıkar (Song vd., 2024).

Dinamik Özellik Seçimi Problemlerinin Zorlukları

Dinamik özellik seçimi, değişken veri yapılarında sürekli güncellenen bir çözüm sunmayı hedeflediği için birçok zorluğu beraberinde getirir. Bu zorluklar, algoritmaların hem adaptasyon yeteneğini hem de hesaplama verimliliğini test eder. Dinamik veri ortamlarında karşılaşılan temel zorluklar şunlardır:

Veri Akışındaki Ani Değişikliklere Hızlı Adaptasyon: Dinamik veri kümelerinde, veri dağılımı beklenmedik şekilde değişebilir. Bu durum, modellerin geçmişte etkili olan bir özellik alt kümesi ile gelecekte de aynı başarıyı sağlayamayacağı anlamına gelir. Algoritmaların, bu ani değişiklikleri hızlı bir şekilde algılayarak çözüm sürecini güncellemeleri gerekir. Örneğin, bir e-ticaret platformunda kullanıcı davranışlarının mevsimsel olarak değişmesi, özelliklerin önem sırasını etkileyebilir.

Hesaplama Kaynaklarının Sınırlı Olduğu Durumlarda Etkinlik Sağlama: Dinamik özellik seçimi algoritmalarının çoğu, hesaplama açısından yoğun işlemler gerektirir. Ancak gerçek zamanlı analizlerde, özellikle **düşük** güçlü cihazlar veya sınırlı işlem kapasitesine sahip sistemlerde, algoritmaların hızlı ve verimli olması önemlidir. Bu durum, algoritma tasarımında

dengeleyici bir yaklaşım gerektirir: hem yüksek doğruluk hem de düşük hesaplama maliyeti.

Değişen Özelliklerin ve Hedef Değişkenle İlişkilerinin Yeniden Değerlendirilmesi: Dinamik veri ortamlarında, belirli bir özellik ile hedef değişken arasındaki ilişki zamanla değişebilir. Örneğin, bir hava durumu tahmin ***modelinde*** nem oranı yaz aylarında kritik bir özellik olabilirken, kış aylarında daha az önemli olabilir. Algoritmaların bu ilişkileri düzenli olarak değerlendirmesi ve önem sırasını yeniden belirlemesi gereklidir.

Çözüm Kararlılığı ve Sonuçların Tutarlılığı: Dinamik ortamlarda sürekli değişen veri yapısı, algoritmanın çözüm kararlılığı üzerinde olumsuz etki yapabilir. Her değişiklikte tamamen farklı bir çözüm önermek yerine, önceki çözümlere benzer ancak optimize edilmiş sonuçlar sunmak, sistemin tutarlılığı açısından önemlidir. Çözüm kararlılığı, kullanıcı deneyimini ve modelin güvenilirliğini artırır.

Bu zorlukların üstesinden gelmek, dinamik özellik seçimi yöntemlerinin başarısı için kritik öneme sahiptir. Algoritmalar, bu sorunları çözmek için adaptif ve esnek mekanizmalar geliştirmelidir.

META-SEZGİSEL ALGORİTMALAR: GENEL BİR BAKIŞ

Meta-Sezgisel Yöntemlerin Temel Özellikleri

Meta-sezgisel algoritmalar, geniş ve karmaşık çözüm uzaylarında etkili bir şekilde arama yapma yetenekleriyle öne çıkar. Dinamik özellik seçimi problemleri gibi değişken ortamlarda, bu algoritmaların esneklik ve adaptasyon yetenekleri büyük avantaj sağlar. Geleneksel optimizasyon yöntemleri genellikle lokal optimumlarda takılı kalabilirken, meta-sezgisel algoritmalar, global optimum çözümleri arayarak daha başarılı sonuçlar sunabilir (Agrawal vd., 2021).

Dinamik ortamlarda, uygunluk yüzeyi (fitness landscape) adı verilen çözüm uzayının sürekli değiştiği durumlarla karşılaşılır. Uygunluk yüzeyi, bir çözümün kalitesini ifade eden değerlerin, çözüm uzayındaki diğer noktalara göre nasıl değiştiğini gösteren bir yüzey olarak düşünülebilir. Statik problemlerde uygunluk yüzeyi sabittir ve algoritma bu yüzeyde en iyi noktayı bulmaya odaklanır. Ancak dinamik problemlerde, uygunluk yüzeyi zamanla değişir; yeni zirveler ortaya çıkabilir, mevcut zirveler kaybolabilir veya hareket edebilir. Bu durum, algoritmaların adaptasyon yeteneklerini test eder ve çözümün sürekli olarak yeniden optimize edilmesini gerektirir.

Meta-sezgisel yöntemler, dinamik uygunluk yüzeyleriyle başa çıkmak için çeşitli stratejiler kullanır:

Popülasyon Çeşitliliğinin Korunması: Algoritmalar, çözüm uzayında geniş bir arama yaparak farklı bölgeleri keşfeder ve değişikliklere hızla adapte olabilir. Bu, özellikle genetik algoritmaların mutasyon mekanizmasıyla sağlanır.

Bellek Mekanizmaları: Algoritmalar, önceki çözüm süreçlerinden elde edilen bilgileri saklayarak değişen uygunluk yüzeyine daha hızlı uyum sağlar.

Reactiveness (Tepkisellik): Algoritma, uygunluk yüzeyindeki değişiklikleri algılayıp arama stratejilerini dinamik olarak güncelleyebilir. Bu, parçacık sürü optimizasyonu (PSO) gibi algoritmalarda sıkça kullanılır.

Meta-sezgisel yöntemlerin bu adaptif özellikleri, onları dinamik veri ortamlarında etkin ve esnek bir çözüm aracı hâline getirir. Dinamik optimizasyon problemlerinde bu yöntemlerin başarısı hem teorik hem de uygulamalı çalışmalarda geniş bir kullanım alanı bulmaktadır.

Yaygın Meta-Sezgisel Algoritmalar

Dinamik özellik seçimi problemlerinde meta-sezgisel algoritmalar, esneklik ve uyum sağlama yetenekleri ile öne çıkar. Bu yöntemler, karmaşık çözüm uzaylarında etkili arama stratejileri sunar ve dinamik veri ortamlarında önemli avantajlar sağlar. Bu bağlamda, literatürde yaygın olarak kullanılan bazı meta-sezgisel algoritmalar şunlardır:

Genetik Algoritmalar (GA): Evrimsel prensiplere dayanan genetik algoritmalar, popülasyon tabanlı bir arama mekanizması sunar. Çaprazlama ve mutasyon gibi biyolojik ilhamlı operatörler, geniş bir çözüm uzayında arama yapmayı mümkün kılar. Özellikle dinamik problemlerde, mutasyon oranının adaptif olarak ayarlanması, algoritmanın değişen veri koşullarına hızlı tepki vermesine olanak tanır.

Parçacık Sürü Optimizasyonu (PSO): Sürü tabanlı bir yaklaşım olan PSO, parçacıkların belirli bir çözüm uzayı içinde hareket ederek optimum noktayı bulmasını sağlar. Her bir parçacık, kendi deneyimlerinden ve sürünün en iyi bireyinden öğrenerek konumunu günceller. Dinamik veri ortamlarında, parçacık hızlarının çevresel değişikliklere duyarlı şekilde optimize edilmesi, yöntemin etkinliğini artırır.

Tabu Arama (TS): Tabu arama algoritması, önceki çözümleri hafızasında tutarak tekrar aynı çözümleri değerlendirmeyi engeller. Bu mekanizma, yerel optimumlardan kaçınmayı kolaylaştırır ve dinamik veri ortamlarında daha etkili sonuçlar elde edilmesine yardımcı olur.

Karınca Kolonisi Optimizasyonu (Ant Colony Optimization, ACO): Doğadan ilham alan bir diğer yöntem olan karınca kolonisi optimizasyonu, karıncaların yiyecek arama davranışlarını taklit eder. Karıncalar, feromon izlerini kullanarak en kısa yolu bulmaya çalışır. Dinamik özellik seçimi problemlerinde, feromonların yoğunluğunun güncel verilere göre adapte edilmesi, yöntemin doğruluğunu artırabilir.

PBIL (Population-Based Incremental Learning): PBIL algoritması, genetik algoritmaların popülasyon tabanlı yapısını olasılık modelleri ile birleştirir. Olasılık dağılımları, çözümlerin evrimini yönlendiren temel bir bileşendir. Dinamik veri yapılarında, olasılık dağılımlarının sürekli güncellenmesi, yöntemin çevresel değişikliklere uyum sağlamasını sağlar.

Diferansiyel Evrim (DE): Diferansiyel evrim algoritması, popülasyon içindeki çözüm adaylarını sürekli olarak güncelleyerek optimize eder. Çaprazlama ve mutasyon operatörleri, dinamik veri kümelerindeki hızlı değişimlere adapte olabilen bir yapı sunar.

Ateşböceği Algoritması (Firefly Algorithm): Ateşböceği algoritması, bireyler arasındaki çekim kuvvetlerine dayalı olarak optimize eder. Çekim kuvveti, çözüm kalitesine göre belirlenir ve dinamik problemlerde uyarlanabilir parametrelerle daha etkin hale getirilebilir.

Bu algoritmalar, değişen veri ortamlarına hızlı adaptasyon sağlayarak, özellikle dinamik özellik seçimi problemlerinde etkili sonuçlar sunar. Bununla birlikte, algoritmaların seçimi, problem özelliklerine ve veri yapısına bağlı olarak değişkenlik gösterebilir.

Meta-Sezgisel Algoritmaların Avantajları ve Kısıtları

Meta-sezgisel algoritmalar, geniş çözüm uzaylarını etkili bir şekilde keşfetme ve yerel optimumlarda takılmadan global optimum çözümler bulma potansiyelleri nedeniyle dinamik özellik seçimi problemlerinde sıklıkla tercih edilir. Bu yöntemler hem karmaşık hem de değişken veri yapılarında esnek ve genelleştirilebilir bir çözüm çerçevesi sunar. Özellikle, dinamik veri kümelerindeki değişimlere hızlı uyum sağlayabilmeleri ve çeşitli optimizasyon problemlerine kolaylıkla uygulanabilmeleri önemli avantajları arasında yer alır. Ayrıca, meta-sezgisel yöntemlerin paralel işleme olanakları, büyük veri kümeleri üzerinde hesaplama süresini azaltarak verimliliği artırabilir (Agrawal vd., 2021).

Bununla birlikte, bu algoritmaların bazı kısıtları da bulunmaktadır. Hesaplama maliyetleri, özellikle dinamik ortamlarda sürekli optimizasyon gereksinimi nedeniyle artabilir. Ayrıca, algoritmaların performansı, genellikle doğru parametre ayarlarına bağlıdır ve bu parametrelerin belirlenmesi zaman alıcı ve karmaşık bir süreç olabilir. Örneğin, genetik algoritmalarda çaprazlama ve mutasyon oranlarının uygun şekilde ayarlanması, sonuçların doğruluğunu doğrudan etkiler. Aynı şekilde, parçacık sürü optimizasyonunda parçacık hızının yanlış seçilmesi, algoritmanın lokal optimumlara sıkışmasına neden olabilir.

Sonuç olarak, meta-sezgisel algoritmalar, dinamik özellik seçimi problemlerinde güçlü araçlar olarak öne çıksa da avantajlarının yanı sıra dikkatle ele alınması gereken sınırlamaları da bulunmaktadır.

DİNAMİK ÖZELLİK SEÇİMİ İÇİN META-SEZGİSEL YAKLAŞIMLAR

Dinamik Ortamlara Uyarlanmış Teknikler

Dinamik özellik seçimi problemlerinde, meta-sezgisel algoritmaların başarısı büyük ölçüde bu yöntemlerin çevresel değişimlere uyum sağlama

kapasitesine bağlıdır. Bu bağlamda, çeşitli adaptasyon teknikleri geliştirilmiştir.

Adaptif algoritmalar, parametrelerini çevresel değişikliklere göre dinamik olarak değiştirebilir. Örneğin, Genetik Algoritmalar (GA) kullanılırken mutasyon oranının adaptif bir şekilde ayarlanması, dinamik veri kümelerindeki değişimlere daha hızlı uyum sağlanmasına olanak tanır (Ye vd., 2010). Benzer şekilde, Parçacık Sürü Optimizasyonu (PSO) algoritmasında parçacıkların hız parametrelerinin çevresel değişimlere göre güncellenmesi, algoritmanın performansını artırabilir (Hu vd., 2024).

Bellek tabanlı yaklaşımlar, önceki optimizasyon süreçlerinden elde edilen bilgileri saklayarak, algoritmaların geçmiş deneyimlerini kullanmasına olanak tanır. Örneğin, Karınca Kolonisi Optimizasyonu (ACO) algoritmasında feromon izleri, önceki çözümlerden elde edilen başarıyı yansıtarak yeni çözüm yollarının belirlenmesinde rehberlik eder (Dorigo vd., 2006). Bu mekanizma, sürekli değişen uygunluk yüzeylerinde daha istikrarlı sonuçlar elde edilmesini sağlar.

Çevresel değişim tespiti, algoritmaların çevresel değişiklikleri algılayarak arama stratejilerini güncellemesini içerir. Özellikle Diferansiyel Evrim (DE) algoritmasında, çözüm popülasyonlarının periyodik olarak yeniden başlatılması veya güncellenmesi, değişen veri ortamlarına hızlı yanıt verilmesini mümkün kılar (Deng vd., 2021).

Bu teknikler, dinamik özellik seçimi problemlerinde çözüm kararlılığını ve performansı artırarak meta-sezgisel algoritmaların etkinliğini büyük ölçüde iyileştirir.

Dinamik Problemlerde Kullanılan Meta-Sezgisel Teknikler

Dinamik özellik seçimi problemlerinde kullanılan teknikler, yalnızca algoritmaların kendisini değil, aynı zamanda bu algoritmaların dinamik veri ortamlarına uyum sağlama yöntemlerini de kapsar. Bu teknikler, algoritmaların esnekliğini ve etkinliğini artırarak dinamik problemlerde daha iyi performans göstermelerini sağlar.

Popülasyon Çeşitliliğinin Korunması, dinamik ortamların doğası gereği önemli bir stratejidir. Bu teknik, özellikle genetik algoritmalar ve parçacık sürü optimizasyonu gibi popülasyon tabanlı yöntemlerde, çözüm uzayının farklı bölgelerinin keşfedilmesini garanti eder. Çeşitliliğin sağlanması, algoritmanın hem yerel optimumlardan kaçınmasını hem de çevresel değişikliklere daha hızlı adapte olmasını mümkün kılar (Gazioğlu & Etaner-Uyar, 2022).

Uygunluk (Fitness) Yeniden Değerlendirme bir diğer önemli tekniktir. Dinamik ortamlarda, bir çözümün kalitesi zamanla değişebilir. Bu nedenle, uygunluk değerlerinin periyodik olarak güncellenmesi ve bu değerlere göre çözümlerin yeniden sıralanması, daha uyumlu bir optimizasyon süreci sağlar (Yazdani vd., 2021). Örneğin, çevresel değişimlerin sık

yaşandığı problemler için, mevcut çözümlerin geçmişe değil, mevcut duruma uygunluğuna göre değerlendirilmesi kritik önem taşır.

Bellek Kullanımı, algoritmaların geçmişten öğrendiği bilgileri yeni durumlara uyarlamasını sağlayan bir başka etkili tekniktir. Örneğin, önceki iterasyonlardan elde edilen çözümleri saklayan bir mekanizma, aynı çevresel değişimlerin tekrarlandığı durumlarda algoritmanın daha hızlı çözüm üretmesine olanak tanır (Jiang vd., 2023).

Bu teknikler, algoritmaların sadece dinamik veri ortamlarına uyum sağlamasını değil, aynı zamanda değişen koşullarda daha kararlı ve etkili sonuçlar üretmesini sağlar.

PERFORMANS ÖLÇÜTLERİ VE KARŞILAŞTIRMA

Dinamik Özellik Seçimi Problemleri için Değerlendirme Kriterleri

Dinamik özellik seçimi problemlerinde kullanılan meta-sezgisel algoritmaların başarısını değerlendirmek için çeşitli kriterler uygulanır. Bu kriterler, algoritmanın hem bireysel hem de karşılaştırmalı performansını analiz etmek için bir çerçeve sağlar. Örneğin, bir algoritmanın global optimuma ulaşma yeteneği, dinamik veri kümelerine adaptasyonu ve çözüm süreçlerindeki kararlılığı gibi faktörler dikkate alınır.

Hesaplama Süresi

Bir algoritmanın çevresel değişikliklere verdiği tepki süresi ve çözüm oluşturma hızı, dinamik problemlerde büyük önem taşır. Hesaplama süresi özellikle büyük veri kümelerinde, gerçek zamanlı uygulamalarda ve sık değişikliklerin yaşandığı ortamlarda kritik bir başarı ölçütüdür. Örneğin, genetik algoritmaların popülasyon boyutuna bağlı olarak değişen işlem süreleri, performansı etkileyebilir.

Çözüm Kalitesi

Algoritmaların ürettiği çözümlerin doğruluğu ve optimalite derecesi, çözüm kalitesini belirler. Bu, meta-sezgisel yöntemlerin lokal optimumlardan kurtularak global optimuma ulaşma kabiliyetiyle doğrudan ilişkilidir. Örneğin, parçacık sürü optimizasyonunun hız vektörlerini çevresel değişimlere uyarlama kapasitesi, yüksek kaliteli çözümler üretmesine katkı sağlar.

Çözüm Kararlılığı

Kararlılık, algoritmanın değişen veri koşulları altında önceki çözümlere ne kadar yakın sonuçlar ürettiğini ifade eder. Bu özellik, özellikle sürekli değişim yaşayan ortamlarda kullanıcının güvenilir çözümler elde etmesini sağlar. Tabu arama algoritması gibi yöntemlerde, çözüm kararlılığı, algoritmanın belleğini etkili bir şekilde kullanmasıyla sağlanabilir.

Simülasyon ve Deney Sonuçlarının Analizi

Algoritmaların performansı, çeşitli veri kümeleri üzerinde yapılan deneyler ve simülasyonlarla ölçülür. Bu analizler, farklı tekniklerin

avantajlarını ve sınırlamalarını karşılaştırmaya olanak tanır. Örneğin, Karınca Kolonisi Optimizasyonu ve Diferansiyel Evrim Algoritması, farklı veri kümeleri üzerinde karşılaştırıldığında, biri hız avantajı sunarken diğeri daha tutarlı çözümler sağlayabilir.

UYGULAMA ALANLARI

Sağlık Sektörü: Gerçek Zamanlı Tanı Sistemleri

Dinamik özellik seçimi, sağlık sektöründe gerçek zamanlı tanı ve izleme sistemleri için kritik öneme sahiptir. Hastane ortamlarında, yoğun bakım üniteleri gibi yerlerde, hastaların yaşamsal belirtileri sürekli olarak değişir. Örneğin, kan basıncı, oksijen seviyeleri ve kalp atış hızı gibi parametreler zaman içinde dalgalanabilir ve bu özelliklerin önemi durumun seyrine göre değişebilir. Geleneksel statik yöntemler, bu tür dinamik verilere adapte olamazken, meta-sezgisel algoritmalar sürekli değişen özelliklerin önemini değerlendirerek en doğru alt küme seçimlerini yapabilir (Beebe-Wang vd., 2023).

Ayrıca, gerçek zamanlı veri analizi, doktorların hızlı ve doğru karar vermesine yardımcı olur. Örneğin, bir sepsis erken uyarı sisteminde dinamik özellik seçimi, doğru parametrelerin seçilerek erken müdahale sağlanmasını mümkün kılar. Bu tür yaklaşımlar hem hastaların sağlık sonuçlarını iyileştirir hem de sağlık sistemindeki kaynak kullanımını optimize eder.

Finans: Zaman Serisi Analizi ve Tahmin

Finans sektöründe, zaman serisi verilerinin analizi ve tahmini, dinamik özellik seçimine dayalı karar alma süreçlerini içerir. Döviz kurları, borsa hareketleri ve ekonomik göstergeler gibi veriler, sürekli değişen bir yapıya sahiptir. Örneğin, piyasa koşulları, bir hisse senedinin fiyatını etkileyen özelliklerin zaman içinde değişmesine neden olabilir. Bu nedenle, dinamik özellik seçimi, verilerdeki değişimleri takip ederek en uygun özellik alt kümesini belirleyebilir (Dong vd., 2021).

Meta-sezgisel algoritmalar, finansal tahminlerde esnekliği ve doğruluğu artırır. Örneğin, bir yatırım portföyünün risk analizinde, piyasadaki dalgalanmalara bağlı olarak dinamik bir şekilde güncellenen özellikler, karar verme sürecini iyileştirebilir. Ayrıca, bu tür sistemler, finansal modellerin doğruluğunu artırarak yatırımcıların stratejik kararlarını destekler.

IoT ve Akıllı Sistemler: Gerçek Zamanlı Veri Analizi

Nesnelerin interneti (IoT) sistemleri, gerçek zamanlı olarak sürekli veri akışı sağlayan sensörlerden oluşur. Akıllı şehirler, endüstriyel otomasyon sistemleri ve çevresel izleme platformları, bu tür sistemlere örnek olarak verilebilir. IoT verilerinde, belirli özelliklerin önemi zamanla değişebilir. Örneğin, bir akıllı trafik yönetim sisteminde, trafik yoğunluğu sabah

saatlerinde kritik bir özellikken, gece saatlerinde farklı özellikler ön plana çıkabilir (Shi & Abdel-Aty, 2015).

Dinamik özellik seçimi, IoT sistemlerinde verilerin verimli bir şekilde işlenmesini ve analiz edilmesini sağlar. Bu da enerji tüketiminin azaltılmasından ağ performansının iyileştirilmesine kadar çeşitli faydalar sunar. Meta-sezgisel algoritmalar, değişken veri ortamlarında esnek ve adaptif bir şekilde çalışarak, IoT sistemlerinin karar alma süreçlerini optimize edebilir.

Doğal Dil İşleme: Değişken Özellikli Metin Sınıflandırma

Doğal dil işleme (NLP) uygulamalarında, metin verilerindeki özellikler genellikle bağlama ve zamanla değişen dil kullanımlarına göre farklılık gösterebilir. Örneğin, sosyal medya verilerinde kullanılan dil, zamanla yeni kelimeler ve ifadeler içerebilir. Dinamik özellik seçimi, bu tür verilerde, sınıflandırma ve analiz için en uygun özelliklerin belirlenmesini sağlar.

Meta-sezgisel algoritmalar, metin sınıflandırma, duygu analizi ve konu modelleme gibi görevlerde, değişen veri yapısına adapte olarak daha doğru sonuçlar üretir. Örneğin, bir duygu analizinde, kullanıcıların kullandığı ifadelerin zamanla değişmesi durumunda, algoritmanın bu değişikliklere uyum sağlaması performansı artırabilir (Baydogan & Alatas, 2021).

GELECEK ÇALIŞMALAR VE ARAŞTIRMA YÖNLERİ

Dinamik Değişimlerin Daha Etkin Modellenmesi

Dinamik veri ortamlarında, çevresel değişimlerin daha etkin bir şekilde modellenmesi, dinamik özellik seçimi problemlerinin çözümünde büyük önem taşır. Mevcut yaklaşımlar genellikle veri değişimlerini belirlemek için basit ölçütler kullanırken, daha sofistike değişim algılama yöntemleri geliştirilmesi gereklidir. Örneğin, zaman serisi verilerinde ani değişiklikleri veya eğilim kaymalarını algılayabilen istatistiksel ve makine öğrenimi tabanlı algoritmalar, dinamik problemlerde daha iyi sonuçlar elde edilmesini sağlayabilir. Bu kapsamda, dinamik değişimlerin daha doğru modellenmesi, meta-sezgisel algoritmaların performansını artıracak ve daha hızlı adaptasyon mekanizmaları geliştirilmesine olanak tanıyacaktır.

Hibrit Meta-Sezgisel Yaklaşımlar

Hibrit meta-sezgisel yaklaşımlar, farklı optimizasyon algoritmalarının güçlü yönlerini birleştirerek daha etkili çözümler sunmayı amaçlar. Örneğin, genetik algoritmaların keşif yetenekleri ile parçacık sürü optimizasyonunun hızlı yakınsama özellikleri birleştirilebilir (Ghamisi & Benediktsson, 2015). Bu tür hibrit yöntemler, dinamik veri ortamlarında hem çözüm kalitesini hem de işlem süresini optimize edebilir. Ayrıca, hibrit yaklaşımlar, farklı veri türleri ve problemler için daha esnek çözümler sunar. Gelecekte, dinamik

özellik seçimi problemleri için özel olarak tasarlanmış hibrit algoritmaların geliştirilmesi, bu alandaki araştırmaların yönünü belirleyecektir.

Büyük Veri Ortamlarında Dinamik Özellik Seçimi

Büyük veri ortamları, dinamik özellik seçimi problemleri için yeni zorluklar ve fırsatlar sunar. Veri hacminin büyüklüğü ve çeşitliliği, geleneksel yöntemlerin etkinliğini sınırlayabilir. Bu nedenle, büyük veri üzerinde çalışabilen paralel ve dağıtık meta-sezgisel algoritmaların geliştirilmesi gerekmektedir. Ayrıca, büyük veri analitiğinde gerçek zamanlı çözümler sunabilmek için algoritmaların hem veri hacmini azaltmaya hem de en uygun özellikleri seçmeye odaklanması önemlidir. Örneğin, Apache Spark gibi büyük veri platformlarıyla entegre edilebilen meta-sezgisel yöntemler, bu alandaki araştırmaların ilerlemesine katkı sağlayabilir.

Derin Öğrenme ile Meta-Sezgisel Yöntemlerin Entegrasyonu

Meta-sezgisel algoritmalar ile derin öğrenme yöntemlerinin birleştirilmesi, dinamik özellik seçimi problemleri için güçlü bir yaklaşım sunabilir. Derin öğrenme modelleri, büyük ve karmaşık veri kümelerinden anlamlı temsiller çıkarabilirken, meta-sezgisel algoritmalar, bu modellerin hiperparametre ayarlarını optimize etmek veya en uygun özellik alt kümelerini belirlemek için kullanılabilir. Örneğin, bir doğal dil işleme probleminde, derin öğrenme modelleri tarafından çıkarılan özelliklerin meta-sezgisel yöntemlerle optimize edilmesi, daha doğru sonuçlar elde edilmesine olanak tanıyabilir. Bu entegrasyonun gelecekteki araştırmalarda daha fazla ilgi görmesi beklenmektedir.

SONUÇ

Ele Alınan Konunun Genel Bir Özeti

Bu bölümde, dinamik özellik seçimi problemleri ve bu problemleri çözmek için kullanılan meta-sezgisel yaklaşımlar kapsamlı bir şekilde ele alınmıştır. Dinamik özellik seçimi, modern veri analitiği ve makine öğrenimi uygulamalarında kritik bir öneme sahiptir. Değişen veri ortamlarının doğası gereği, geleneksel statik yöntemlerin yetersiz kaldığı durumlarda, meta-sezgisel algoritmalar, esneklikleri ve adaptasyon yetenekleri sayesinde etkili çözümler sunar. Bu çalışmada, dinamik veri kümelerinin karakteristik özellikleri, meta-sezgisel algoritmaların temel prensipleri ve bu yöntemlerin çeşitli uygulama alanlarındaki rolü detaylı bir şekilde incelenmiştir. Bu kapsamlı değerlendirme, dinamik problemler için optimize edilmiş yaklaşımların geliştirilmesine ışık tutmaktadır.

Meta-Sezgisel Yöntemlerin Dinamik Özellik Seçimi Problemlerindeki Önemi

Meta-sezgisel yöntemler, geniş çözüm uzaylarında global optimuma ulaşma yetenekleriyle dinamik özellik seçimi problemlerinde güçlü bir araç olarak öne çıkmaktadır. Bu algoritmalar, çevresel değişimlere hızlı uyum sağlama, kararlı çözümler üretme ve farklı veri ortamlarına uygulanabilme gibi avantajlar sunar. Özellikle genetik algoritmalar, parçacık sürü optimizasyonu ve diferansiyel evrim gibi teknikler, değişken veri yapılarında başarıyla kullanılmaktadır. Bununla birlikte, meta-sezgisel yaklaşımlar yalnızca teorik bir katkı sunmakla kalmamakta, aynı zamanda sağlık, finans ve IoT gibi uygulama alanlarında somut faydalar sağlamaktadır. Bu yöntemlerin gelecekteki gelişimi, dinamik problemlerin çözümünde yeni ufuklar açacaktır.

Bölümün Genel Çıkarımları ve Katkıları

Bu çalışmada, dinamik özellik seçimi problemlerinin çözümünde meta-sezgisel algoritmaların uygulanabilirliği ve potansiyeli ortaya konulmuştur. Bölüm, yalnızca mevcut yaklaşımları değerlendirmekle kalmamış, aynı zamanda hibrit yöntemler, büyük veri analitiği ve derin öğrenme ile entegrasyon gibi gelecekteki araştırma yönlerini de vurgulamıştır. Dinamik özellik seçimi, değişken veri ortamlarına uyum sağlama yeteneği gerektiren problemler için etkili bir çözüm sunmakta ve bu süreçte meta-sezgisel yaklaşımlar, yenilikçi yöntemler geliştirilmesine olanak tanımaktadır. Bu bölümün sunduğu katkılar hem akademik çevrelerde hem de uygulamalı alanlarda rehber niteliği taşımaktadır.

REFERANSLAR

Agrawal, P., Abutarboush, H. F., Ganesh, T., & Mohamed, A. W. (2021). Metaheuristic Algorithms on Feature Selection: A Survey of One Decade of Research (2009-2019). *IEEE Access, 9,* 26766-26791. IEEE Access.

Allioui, H., & Mourdi, Y. (2023). Exploring the Full Potentials of IoT for Better Financial Growth and Stability: A Comprehensive Survey. *Sensors*, *23*(19), Article 19. https://doi.org/10.3390/s23198015

Baydogan, C., & Alatas, B. (2021). Metaheuristic Ant Lion and Moth Flame Optimization-Based Novel Approach for Automatic Detection of Hate Speech in Online Social Networks. *IEEE Access, 9,* 110047-110062. IEEE Access. https://doi.org/10.1109/ACCESS.2021.3102277

Beebe-Wang, N., Qiu, W., & Lee, S.-I. (2023, Temmuz 19). *Explanation-guided dynamic feature selection for medical risk prediction*. ICML 3rd Workshop on Interpretable Machine Learning in Healthcare (IMLH). https://openreview.net/forum?id=1itfhff53V#all

Deng, W., Shang, S., Cai, X., Zhao, H., Song, Y., & Xu, J. (2021). An improved differential evolution algorithm and its application in optimization problem.

Soft Computing, *25*(7), 5277-5298. https://doi.org/10.1007/s00500-020-05527-x

Dokeroglu, T., Deniz, A., & Kiziloz, H. E. (2022). A comprehensive survey on recent metaheuristics for feature selection. *Neurocomputing*, *494*, 269-296. https://doi.org/10.1016/j.neucom.2022.04.083

Dong, S., Wang, J., Luo, H., Wang, H., & Wu, F.-X. (2021). A dynamic predictor selection algorithm for predicting stock market movement. *Expert Systems with Applications*, *186*, 115836. https://doi.org/10.1016/j.eswa.2021.115836

Dorigo, M., Birattari, M., & Stutzle, T. (2006). Ant colony optimization. *IEEE Computational Intelligence Magazine*, *1*(4), 28-39. IEEE Computational Intelligence Magazine. https://doi.org/10.1109/MCI.2006.329691

Gazioğlu, E., & Etaner-Uyar, A. S. (2022). Experimental analysis of a statistical multiploid genetic algorithm for dynamic environments. *Engineering Science and Technology, an International Journal*, *35*, 101173. https://doi.org/10.1016/j.jestch.2022.101173

Ghamisi, P., & Benediktsson, J. A. (2015). Feature Selection Based on Hybridization of Genetic Algorithm and Particle Swarm Optimization. *IEEE Geoscience and Remote Sensing Letters*, *12*(2), 309-313. IEEE Geoscience and Remote Sensing Letters. https://doi.org/10.1109/LGRS.2014.2337320

Hu, G., Guo, Y., Zhao, W., & Houssein, E. H. (2024). An adaptive snow ablation-inspired particle swarm optimization with its application in geometric optimization. *Artificial Intelligence Review*, *57*(12), 332. https://doi.org/10.1007/s10462-024-10946-5

Jiang, S., Zou, J., Yang, S., & Yao, X. (2023). Evolutionary Dynamic Multi-objective Optimisation: A Survey. *ACM Computing Surveys*, *55*(4), 1-47. https://doi.org/10.1145/3524495

Kohavi, R., & John, G. H. (1997). Wrappers for feature subset selection. *Artificial Intelligence*, *97*(1), 273-324. https://doi.org/10.1016/S0004-3702(97)00043-X

Reeves, C., & Rowe, J. E. (2002). *Genetic Algorithms: Principles and Perspectives: A Guide to GA Theory*. Springer Science & Business Media.

Restrepo, N., Uribe, J. M., & Manotas, D. F. (2020). Dynamic capital structure under changing market conditions in the oil industry: An empirical investigation. *Resources Policy*, *69*, 101808. https://doi.org/10.1016/j.resourpol.2020.101808

Rodriguez-Galiano, V. F., Luque-Espinar, J. A., Chica-Olmo, M., & Mendes, M. P. (2018). Feature selection approaches for predictive modelling of groundwater nitrate pollution: An evaluation of filters, embedded and wrapper methods. *Science of The Total Environment*, *624*, 661-672. https://doi.org/10.1016/j.scitotenv.2017.12.152

Shi, Q., & Abdel-Aty, M. (2015). Big Data applications in real-time traffic operation and safety monitoring and improvement on urban expressways. *Transportation Research Part C: Emerging Technologies*, *58*, 380-394. https://doi.org/10.1016/j.trc.2015.02.022

Song, X., Ma, H., Zhang, Y., Gong, D., Guo, Y., & Hu, Y. (2024). A Streaming Feature Selection Method Based on Dynamic Feature Clustering and Particle Swarm Optimization. *IEEE Transactions on Evolutionary Computation*, 1-

1. IEEE Transactions on Evolutionary Computation. https://doi.org/10.1109/TEVC.2024.3451688

Yazdani, D., Cheng, R., Yazdani, D., Branke, J., Jin, Y., & Yao, X. (2021). A Survey of Evolutionary Continuous Dynamic Optimization Over Two Decades—Part B. *IEEE Transactions on Evolutionary Computation*, *25*(4), 630-650. IEEE Transactions on Evolutionary Computation. https://doi.org/10.1109/TEVC.2021.3060012

Ye, Z., Li, Z., & Xie, M. (2010). Some improvements on adaptive genetic algorithms for reliability-related applications. *Reliability Engineering & System Safety*, *95*(2), 120-126. https://doi.org/10.1016/j.ress.2009.09.001

Derin Öğrenmede Genetik Algoritmalar ile Hiperparametre Optimizasyonu

Emrullah GAZİOĞLU[1]

1- Dr. Öğr. Üyesi.; Şırnak Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü. gazioglu@sirnak.edu.tr ORCID No: 0000-0002-7615-305X

ÖZET

Bu çalışma, derin öğrenme modellerinin hiperparametre optimizasyonunda Genetik Algoritmaların rolünü ve önemini kapsamlı bir şekilde incelemektedir. Derin öğrenme modellerinin artan karmaşıklığı, hiperparametre seçimini zorlaştırmakta ve geleneksel optimizasyon yöntemlerinin yetersiz kalmasına neden olmaktadır. Genetik Algoritmalar, doğal seleksiyon prensiplerini temel alan meta-sezgisel yöntemler olarak bu zorluğun üstesinden gelmede etkili çözümler sunmaktadır. Çalışmada, Genetik Algoritmaların çalışma prensipleri, seçim, çaprazlama ve mutasyon gibi temel operatörleri detaylı olarak ele alınmış, Derin Öğrenme modellerinin hiperparametre optimizasyonundaki uygulamaları incelenmiştir. Genetik Algoritma tabanlı hiperparametre optimizasyonu yaklaşımı, özellikle Evrişimsel Sinir Ağları ve Tekrarlayan Sinir Ağları gibi karmaşık mimarilerde üstün performans göstermektedir. Araştırma sonuçları, Genetik Algoritmaların paralel hesaplama yetenekleri ve adaptif özellikleri sayesinde, model performansını artırırken hesaplama maliyetlerini düşürdüğünü göstermektedir. Sağlık, finans, robotik ve görüntü işleme gibi çeşitli alanlardaki uygulamalar, Genetik Algoritma tabanlı optimizasyon stratejilerinin pratik değerini ortaya koymaktadır. Gelecekte, kuantum hesaplama ve federe öğrenme gibi yeni teknolojilerle Genetik Algoritmaların entegrasyonu, daha etkili optimizasyon çözümleri vaat etmektedir. Bu çalışma, Derin Öğrenme ve Genetik Algoritmaların sinerjik birleşiminin, yapay zekâ alanındaki optimizasyon problemlerinin çözümünde güçlü bir araç olduğunu göstermektedir.

Anahtar Kelimeler - Genetik Algoritma, Derin Öğrenme, Hiperparametre Optimizasyonu, Evrişimsel Sinir Ağları, Meta-Sezgisel Optimizasyon, Doğa Esinli Hesaplama.

GİRİŞ

Genetik Algoritmaların Tanımı ve Tarihçesi

Genetik Algoritmalar (GA), doğadaki evrimsel mekanizmalardan esinlenilerek geliştirilmiş meta-sezgisel yöntemlerdir. Bu algoritmalar, çözümü zor ya da karmaşık problemler için alternatif bir yöntem sunar. Temelinde, doğal seleksiyon prensibi yer alır ve 'en uygun bireylerin' hayatta kalması fikrine dayanır. John Holland tarafından 1970'lerde ortaya atılan bu yöntem, bilgisayar biliminde önemli bir yere sahiptir. GA'ların ilk uygulamaları, çok sayıda olası çözümün, çözüm uzayında etkin bir şekilde aranmasını sağlamak için kullanılmıştır. Günümüzde ise özellikle optimizasyon problemlerinde yaygın olarak tercih edilmektedir ve birçok varyasyonu gerçeklenmiştir. (Holland, 1975).

Derin Öğrenme Modellerinin Temel Prensipleri

Derin öğrenme, yapay zêka ve makine öğrenmesinin alt bir dalı olarak, verilerden karmaşık örüntüleri öğrenmek için yapılandırılmış bir metodolojidir. Derin öğrenme modelleri, Yapay Sinir Ağlarının (ANN) birden fazla gizli katmana sahip olmasıyla geleneksel yaklaşımlardan ayrılır. Bu katmanlar, girdiden çıktıya kadar hiyerarşik bir şekilde çalışarak, çok boyutlu verilerin anlaşılmasını sağlar. Derin öğrenme, özellikle görüntü işleme, doğal dil işleme ve robotik gibi alanlarda başarıyla kullanılmaktadır. Modelin başarısı, genellikle öğrenme parametrelerinin hassas ayarına ve gözetimli bir şekilde öğretilmesine bağlıdır (Schmidhuber, 2015).

Hiperparametre Ayarlamanın Önemi ve Zorlukları

Derin öğrenme modellerinin başarısında hiperparametrelerin doğru bir şekilde belirlenmesi büyük bir rol oynamaktadır. Hiperparametreler, bir modelin mimarisini ve öğrenme sürecini yöneten ayarları ifade eder. Örneğin, öğrenme oranı, katman sayısı ve aktivasyon fonksiyonları hiperparametreler arasında yer alır. Ancak, bu parametrelerin uygun değerlerini bulmak genellikle zaman alıcı ve hesaplama yükü ağır bir süreçtir. Geleneksel yöntemler, rastgele arama veya grid (ızgara) arama gibi stratejiler kullanırken, GA'lar gibi meta-sezgisel yöntemler daha etkin çözümler sunabilir (Falkner vd., 2018).

Bölümün Amacı ve Yapısı

Bu bölüm, GA'ların derin öğrenme modellerindeki hiperparametre ayarlamalarına katkısını detaylandırmayı amaçlamaktadır. Öncelikle GA'ların temel prensipleri ve tarihsel gelişimi ele alınacak, sonrasında derin öğrenme modellerinin yapısal özellikleri ve hiperparametre optimizasyonunun kritik rolü tartışılacaktır. Ayrıca, bu yaklaşımın getirileri ve mevcut zorlukları da değerlendirilerek okuyucuya GA'ların etkin kullanımı için bir temel sağlanacaktır. Bölümün sonunda, okuyucu hem GA'ları hem de derin öğrenme modellerini hiperparametre optimizasyonu perspektifinden kavramış olacaktır.

GENETİK ALGORİTMALARIN TEMEL KAVRAMLARI

Genetik Algoritmaların Çalışma Prensibi

GA'lar, evrimsel bir hesaplama yöntemi olarak çalışır ve genellikle bir çözüm uzayında optimal ya da kabul edilebilir bir çözüm bulmayı amaçlar. Bu algoritmalar, popülasyon tabanlı bir yaklaşımla bireyler üzerinde genetik operatörler uygular. Seçim, çaprazlama ve mutasyon gibi temel adımlar, evrimsel mekanizmaları taklit ederek bireylerin şekillendirilmesini sağlar. Seçim işlemi, daha uygun bireylerin bir sonraki nesle geçmesini garanti ederken, çaprazlama yeni bireylerin oluşturulmasını sağlar. Mutasyon ise

genetik çeşitliliği koruyarak lokal minimumlara takılma riskini azaltır. GA'lar, bu yöntemler sayesinde karmaşık çözüm uzaylarında etkili bir arama yapabilir (Forrest, 1996).

Genetik Algoritmaların Bileşenleri: Seçim, Çaprazlama ve Mutasyon

Seçim, GA'ların kritik bir bilesenidir ve bireylerin uygunluk seviyelerine göre gelecek nesillere aktarılmasını sağlar. Seçim yöntemleri arasında rulet tekerleği, turnuva seçimi ve dereceli seçim gibi çeşitli stratejiler bulunur. Çaprazlama, iki ebeveyn bireyin genetik materyallerinin birleştirilmesiyle yeni bireyler oluşturur ve genellikle çaprazlama oranı ile kontrol edilir. Mutasyon ise bireylerin genetik materyalinde rastgele değişiklikler yaparak çeşitliliği arttırır ve arama sürecinin çok yönlü olmasını sağlar. Bu üç bilesen, GA'ların dinamik yapısını oluşturur ve algoritmanın etkinliğini belirler.

Genetik Algoritmaların Avantajları ve Dezavantajları

GA'lar, çözüm uzayının geneli üzerinde arama yapma kapasitesine sahip oldukları için yerel minimumlara takılma olasılığını azaltır. Bunun yanında, paralel hesaplama potansiyeli sunarak büyük verilerle etkin bir şekilde başa çıkabilirler. Ancak, GA'ların dezavantajları da vardır. Hesaplama maliyetleri yüksek olabilir ve bazen optimal olmayan çözümlere ulaşılabilir. Bunun ötesinde, hiperparametrelerin (popülasyon büyüklüğü, çaprazlama oranı gibi) doğru bir şekilde ayarlanması, algoritmanın başarısını önemli ölçüede etkileyebilir.

Genetik Algoritmaların Uygulama Alanları

GA'lar, çeşitli endüstriyel ve akademik alanlarda kullanılmaktadır. Mühendislik optimizasyonu, makina öğrenmesi, biyoinformatik ve finansal modelleme gibi alanlar bu algoritmaların başarıyla uygulandığı başlıca sahalardır. Örneğin, şirketler lojistik süreçlerini optimize etmek için GA'ları kullanabilirken, biyoinformatik uzmanları DNA dizilimlerini analiz etmek için bu yöntemden yararlanabilir. Bu geniş uygulama alanları, GA'ların esnek ve çok yönlü bir yöntem olduğunu göstermektedir (Katoch vd., 2021).

DERİN ÖĞRENME VE HİPERPARAMETRE AYARLAMA

Derin Öğrenme Modelleri ve Mimari Seçimi

Derin öğrenme modelleri, girdi verilerini çok katmanlı bir yapıda işleyen ANN'lerden oluşur. Bu modellerin tasarımında kullanılan mimari, veri türüne ve problemin doğasına bağlı olarak değişiklik gösterebilir. Örneğin, Evrişimsel Sinir Ağları (CNN) genellikle görüntü işleme problemlerinde kullanılırken, Tekrarlayan Sinir Ağları (RNN) doğal dil işleme ve zaman serisi analizlerinde tercih edilir. Mimari seçimi, öğrenme

hızı, hesaplama maliyeti ve çıktı performansı gibi faktörleri etkiler. Uygun bir mimari, modelin genelleşme kapasitesini artırarak daha başarılı sonuçlar elde edilmesini sağlar (Bengio vd., 2021).

Hiperparametre Ayarlamanın Rolü ve Önemi

Hiperparametre ayarlama, derin öğrenme modellerinin etkinliğini önemli ölçüde etkiler. Hiperparametreler, modelin çalışma prensiplerini yöneten değişkenlerdir ve genellikle model eğitimi öncesinde belirlenir. Bu parametreler arasında öğrenme oranı, optimizasyon algoritması, gizli katman sayısı ve mini-batch boyutu gibi unsurlar bulunur. Yanlış ayarlanan hiperparametreler, aşırı uyum ya da yetersiz öğrenme gibi sorunlara yol açabilir. Doğru hiperparametre kombinasyonu ise model performansını önemli ölçüde artırabilir ve daha iyi genelleşme yeteneği sağlar (Yu & Zhu, 2020).

Geleneksel Yöntemlerle Hiperparametre Ayarlama

Hiperparametre ayarlamak için geleneksel yöntemler, genellikle ızgara arama ve rastgele arama gibi teknikleri kapsar. Izgara arama, tüm olası hiperparametre kombinasyonlarını sistematik olarak denerken, rastgele arama sadece belirli bir kombinasyon alt kümesini test eder. Bu yöntemler basit ve uygulanabilir olmalarına rağmen, çok büyük hiperparametre alanlarında verimsiz hale gelebilir. Özellikle karmaşık ve çok katmanlı modellerde, bu yöntemlerin hesaplama maliyeti oldukça yüksek olabilir. Alternatif olarak, meta-sezgisel algoritmalar ve otomatikleşmiş makine öğrenme teknikleri, bu süreçleri daha etkin hale getirebilir (Bergstra & Bengio, t.y.).

Hiperparametrelerin Etkisi ve Model Performansı

Hiperparametreler, model performansı üzerinde belirleyici bir rol oynar. Yanlış ayarlanan bir öğrenme oranı, modelin aşırı uyum yapmasına veya yeterince iyi bir çözüm bulamamasına neden olabilir. Benzer şekilde, mini-batch boyutunun çok büyük veya çok küçük seçilmesi, eğitim sürecinin dengesini bozabilir. Hiperparametre optimizasyonu, bu tür sorunları azaltarak daha tutarlı ve etkili bir eğitim süreci sağlar. Bu nedenle, hiperparametrelerin etkisini anlamak ve bunların uygun bir şekilde ayarlanması, derin öğrenme projelerinde kritik bir basamaktır.

GENETİK ALGORİTMALAR İLE HİPERPARAMETRE OPTİMİZASYONU

Genetik Algoritmaların Hiperparametre Ayarlamadaki Rolü

GA'lar, derin öğrenme modellerinin hiperparametre optimizasyonunda güçlü bir yaklaşım sunar. Geleneksel yöntemlerde karşılaşılan hesaplama yükü ve zaman kısıtlamaları, GA'ların paralel arama yetenekleri sayesinde aşılabilir. Hiperparametre uzayının karmaşıklığı ve boyutsallığı, GA'ların evrimsel mekanizmalarıyla daha etkili şekilde ele alınır. Özellikle öğrenme oranı, batch boyutu, katman sayısı ve nöron sayısı gibi kritik parametrelerin optimizasyonunda, GA'lar çözüm kalitesini önemli ölçüde artırır. GA'ların adaptif yapısı, farklı problem türlerine ve veri setlerine uyum sağlayabilme esnekliği sunar. Ayrıca, çaprazlama ve mutasyon operatörleri, hiperparametre uzayının daha geniş bir bölümünün keşfedilmesini sağlar. GA'ların popülasyon tabanlı yaklaşımı, farklı hiperparametre kombinasyonlarının paralel olarak değerlendirilmesine olanak tanır. Bu sayede, optimal veya optimale yakın çözümlere daha hızlı ulaşılabilir. Hiperparametre optimizasyonunda GA'ların başarısı, büyük ölçüde popülasyon büyüklüğü, çaprazlama oranı ve mutasyon oranı gibi kendi parametrelerinin doğru ayarlanmasına da bağlıdır.

Hiperparametrelerin Genetik Algoritmalarla Optimizasyonu

GA'lar ile hiperparametre optimizasyonu, kromozom yapısının tasarımından başlayarak sistematik bir süreç gerektirir. Her bir kromozom, derin öğrenme modelinin hiperparametrelerini temsil eden genlerden oluşur. Bu genler, sürekli, kesikli veya kategorik değerler alabilir. Örneğin, öğrenme oranı sürekli bir değer olarak kodlanırken, aktivasyon fonksiyonu seçimi kategorik bir değer olarak temsil edilir. GA'lar, bu farklı veri tiplerini aynı kromozom yapısında etkili bir şekilde işleyebilir. Optimizasyon sürecinde, başlangıç popülasyonu rastgele oluşturulur ve her bireyin uygunluğu, temsil ettiği hiperparametre setiyle eğitilen modelin performansına göre değerlendirilir. Çaprazlama operatörü, başarılı hiperparametre kombinasyonlarının özelliklerini bir araya getirerek yeni çözümler üretir. Mutasyon operatörü ise, çözüm uzayının yeni bölgelerinin keşfedilmesini sağlayarak yerel optimumlara takılma riskini azaltır. GA'ların çok amaçlı optimizasyon yetenekleri, model performansı, eğitim süresi ve hesaplama maliyeti gibi birden fazla kriterin eş zamanlı optimizasyonuna olanak tanır.

Genetik Algoritmalar ile Derin Öğrenme Modellerinin Hiperparametrelerinin Optimizasyonu

GA'lar, özellikle derin öğrenme modellerinin karmaşık hiperparametre uzaylarında etkili bir optimizasyon aracı olarak öne çıkar. CNN'lerde konvolüsyon katmanı sayısı, filtre boyutları ve havuzlama stratejileri gibi yapısal parametrelerin optimizasyonu için özel kodlama şemaları kullanılır.

RNN'lerde LSTM veya GRU birimlerinin sayısı, dizi (sequence) uzunluğu ve seyreltme (dropout) oranları gibi parametreler GA'lar ile optimize edilebilir. Transformer mimarilerinde, dikkat başı (attention head) sayısı, ileri beslemeli (feed-forward) katman boyutu ve gömme (embedding) boyutu gibi kritik parametreler için GA tabanlı optimizasyon stratejileri geliştirilmiştir. Her model türü için özelleştirilmiş uygunluk (fitness) fonksiyonları, doğruluk, hesaplama maliyeti ve model karmaşıklığı arasında uygun denge kurulmasını sağlar. GA'ların çok popülasyonlu varyantları, farklı model mimarilerinin paralel olarak optimize edilmesine olanak tanır. Transfer öğrenme senaryolarında, önceden eğitilmiş modellerin yeni görevlere adaptasyonu için gereken hiperparametrelerin optimizasyonunda GA'lar etkili sonuçlar verir (Ma vd., 2019).

Başarı Ölçütleri ve Performans Değerlendirmesi

GA tabanlı hiperparametre optimizasyonunun başarısı, çeşitli metrikler kullanılarak değerlendirilir. Doğruluk, hassasiyet, duyarlılık ve F1-skoru gibi geleneksel performans metrikleri, modelin tahmin yeteneğini ölçer. Eğitim süresi, bellek kullanımı ve hesaplama maliyeti gibi operasyonel metrikler, optimizasyon sürecinin verimliliğini değerlendirir. Çapraz doğrulama teknikleri, GA ile optimize edilen modellerin genelleştirme performansının güvenilir şekilde ölçülmesini sağlar. ROC eğrisi ve AUC değeri, sınıflandırma problemlerinde model performansının kapsamlı analizi için kullanılır. Optimizasyon sürecinin yakınsama hızı ve çözüm kalitesi, GA'ların etkinliğini değerlendirmede önemli kriterlerdir. Çok amaçlı optimizasyon senaryolarında, Pareto-optimal çözüm setinin çeşitliliği ve dağılımı analiz edilir. Modelin farklı veri setleri ve problem türleri üzerindeki performansı, optimizasyonun sağlamlığını gösterir. Ayrıca, model karmaşıklığı ve yorumlanabilirlik gibi nitel faktörler de değerlendirmede dikkate alınır (Lee vd., 2011).

GENETİK ALGORİTMALARIN İYİLEŞTİRİLMESİ VE YENİ YÖNTEMLER

Genetik Algoritmaların Performansını Artırmak İçin Yapılan İyileştirmeler

GA'ların performansını artırmak için yapılan çalışmalar, algoritmanın temel bileşenlerinin iyileştirilmesine odaklanmıştır. Adaptif parametre ayarlama stratejileri, algoritmanın çalışma sürecinde dinamik olarak değişen parametrelerin kullanılmasını sağlar. Örneğin, çaprazlama ve mutasyon oranları, popülasyonun çeşitliliğine ve uygunluk değerlerine bağlı olarak otomatik olarak ayarlanabilir. Bu yaklaşım, algoritmanın farklı optimizasyon aşamalarında daha etkili çalışmasını sağlar. Seçim mekanizmalarının iyileştirilmesi de önemli bir rol oynar. Örneğin, elitizm stratejisi ile en iyi

bireylerin bir sonraki nesle doğrudan aktarılması, çözüm kalitesinin korunmasını sağlar. Ayrıca, yerel arama teknikleri ile hibrit yaklaşımlar, GA'ların keşif ve sömürü dengesi arasında daha iyi bir denge kurmasına yardımcı olur (Gazioğlu & Etaner-Uyar, 2022).

Yenilikçi Genetik Algoritma Yaklaşımları

GA'ların geleneksel yapısı üzerine inşa edilen yenilikçi yaklaşımlar, algoritmanın etkinliğini artırmak için çeşitli stratejiler sunar. Çok amaçlı optimizasyon problemleri için geliştirilen NSGA-III (Deb & Sundar, 2006) ve MOEA/D (Q. Zhang & Li, 2007) gibi algoritmalar, karmaşık problemlerin çözümünde başarılı sonuçlar vermektedir. Kuantum GA'ları (Narayanan & Moore, 1996; G. Zhang vd., 2006), kuantum hesaplama prensiplerini genetik operatörlere entegre ederek, daha geniş bir arama uzayını keşfetme imkânı sunar. Coğrafi izolasyon modelleri, popülasyonun alt gruplara ayrılarak paralel evrimleşmesini sağlar ve genetik çeşitliliği artırır. Diferansiyel evrim ve GA'ların birleştirilmesiyle oluşturulan melez yaklaşımlar (M. Zhang vd., 2006), her iki algoritmanın güçlü yönlerini bir araya getirir. Bu yenilikçi yaklaşımlar, özellikle büyük ölçekli ve karmaşık optimizasyon problemlerinde geleneksel GA'lara göre daha iyi performans gösterir.

Hibrit Modeller: Genetik Algoritmalar ve Derin Öğrenme

GA'lar ve derin öğrenme modellerinin birleştirilmesi, her iki yaklaşımın güçlü yönlerinden faydalanma imkânı sunar. Neuro-Evrimsel yaklaşımlar, ANN'lerin topolojisini ve ağırlıklarını optimize etmek için GA'ları kullanır (Ding vd., 2010). Bu hibrit modeller, özellikle karmaşık örüntü tanıma ve tahmin problemlerinde etkili sonuçlar verir. GA'lar, derin öğrenme modellerinin mimarisini otomatik olarak tasarlamak için de kullanılabilir. Bu süreçte, katman sayısı, nöron sayısı ve bağlantı yapısı gibi parametreler evrimsel olarak optimize edilir. Ayrıca, transfer öğrenme stratejileri ile birleştirilen GA'lar, önceden eğitilmiş modellerin yeni görevlere adaptasyonunu sağlar. Bu hibrit yaklaşımlar, özellikle sınırlı veri setleri ile çalışırken model performansını artırır (Nagae vd., 2020).

Paralel ve Dağıtık Genetik Algoritmaların Uygulamaları

Paralel ve dağıtık GA'lar, büyük ölçekli optimizasyon problemlerinin çözümünde hesaplama verimliliğini artırır. Ada modeli yaklaşımı, popülasyonun alt popülasyonlara bölünerek farklı işlemcilerde paralel olarak evrimleşmesini sağlar. Bu alt popülasyonlar arasında belirli aralıklarla göç operatörleri uygulanarak genetik çeşitlilik korunur. Izgara tabanlı paralel GA'lar, coğrafi olarak dağıtık hesaplama kaynaklarını kullanarak büyük ölçekli problemlerin çözümünü mümkün kılar. Bulut bilişim platformları üzerinde çalışan dağıtık GA'lar, ölçeklenebilir ve maliyet etkin çözümler sunar. Master-Slave mimarisi ile tasarlanan paralel GA'lar, uygunluk değerlendirmesi gibi işlem yükü ağır görevleri farklı işlemcilere dağıtarak

zaman verimliliği sağlar (Xue vd., 2008). Bu yaklaşımlar, özellikle endüstriyel ölçekte optimizasyon problemlerinin çözümünde yaygın olarak kullanılır.

UYGULAMA ALANLARI VE GERÇEK DÜNYA ÖRNEKLERİ

Sağlık ve Biyomedikal Alanında Hiperparametre Ayarlama

Sağlık ve biyomedikal alanda GA'lar, özellikle hastalık teşhisi ve ilaç keşfi süreçlerinde kullanılan derin öğrenme modellerinin optimizasyonunda kritik rol oynar. Tıbbi görüntü analizi için geliştirilen CNN modellerinde, GA'lar katman sayısı, filtre boyutu ve aktivasyon fonksiyonları gibi hiperparametrelerin optimizasyonunu sağlar. Örneğin, MR görüntülerinden tümör tespiti yapan modellerde, GA tabanlı hiperparametre optimizasyonu ile teşhis doğruluğu önemli ölçüde artırılabilir. Genetik dizileme ve protein yapı tahmininde kullanılan derin öğrenme modellerinde, GA'lar model mimarisinin otomatik tasarımını gerçekleştirir. Klinik veri analizi ve hasta risk değerlendirmesi için kullanılan tahmin modellerinde, GA'lar ile optimize edilmiş hiperparametreler, modelin genelleştirme performansını artırır.

Finansal Piyasalar ve Tahmin Modelleri

Finansal piyasalarda GA'lar, karmaşık zaman serisi verilerini analiz eden derin öğrenme modellerinin optimizasyonunda kullanılır. Özellikle LSTM ve GRU gibi RNN mimarilerinde, hiperparametre seçimi model performansını doğrudan etkiler. GA'lar, bu modellerin gizli katman sayısı, seyreltme oranı ve öğrenme hızı gibi parametrelerini optimize eder. Portföy optimizasyonu için geliştirilen derin öğrenme modellerinde, GA tabanlı hiperparametre ayarlama stratejileri risk-getiri dengesini iyileştirir. Algoritmik ticaret sistemlerinde kullanılan modellerin hiperparametreleri, piyasa koşullarına adaptif olarak ayarlanır. Kredi risk değerlendirmesi ve dolandırıcılık tespiti uygulamalarında, GA'lar ile optimize edilmiş modeller yüksek doğruluk oranları sağlar (Mehdary vd., 2024).

Robotik ve Otonom Sistemlerde Kullanım

Robotik sistemlerde GA'lar, hareket planlama ve kontrol algoritmalarının optimizasyonunda etkin rol oynar. Otonom araçlarda kullanılan derin pekiştirmeli öğrenme modellerinin hiperparametreleri, GA'lar aracılığıyla optimize edilerek daha güvenli ve verimli sürüş davranışları elde edilir. Endüstriyel robotların yörünge planlaması ve manipülasyon görevlerinde, GA tabanlı optimizasyon stratejileri enerji verimliliğini artırır. İnsansı robotların hareket kontrolünde kullanılan derin öğrenme modellerinin hiperparametreleri, GA'lar ile ayarlanarak daha doğal ve akıcı hareketler sağlanır. Sürü robotik sistemlerinde, çoklu robot koordinasyonu için

kullanılan modellerin optimizasyonu, GA'lar ile gerçekleştirilir (Trauth vd., 2024).

Görüntü İşleme ve Nesne Tanıma

Görüntü işleme ve nesne tanıma uygulamalarında GA'lar, derin öğrenme modellerinin performansını optimize etmek için yaygın olarak kullanılır. Özellikle CNN mimarilerinde, konvolüsyon katmanlarının sayısı, filtre boyutları ve havuzlama stratejileri gibi hiperparametreler, GA'lar ile optimize edilir. Gerçek zamanlı nesne takibi uygulamalarında, model mimarisinin GA tabanlı optimizasyonu işlem hızı ve doğruluk arasında optimal denge sağlar. Yüz tanıma sistemlerinde kullanılan derin öğrenme modellerinin hiperparametreleri, GA'lar aracılığıyla ayarlanarak tanıma doğruluğu artırılır. Medikal görüntü segmentasyonu ve anomali tespiti uygulamalarında, GA tabanlı hiperparametre optimizasyonu ile hassas ve güvenilir sonuçlar elde edilir (Khouy vd., 2023).

GELECEK YÖNELİMLER VE ARAŞTIRMA ALANLARI

Genetik Algoritmaların Geleceği ve Derin Öğrenme ile Entegrasyonu

GA'ların derin öğrenme ile entegrasyonu, gelecekte yapay zêka alanında önemli gelişmelere yol açabilir. Özellikle otomatik makine öğrenmesi (AutoML) alanında GA'lar, model mimarisi tasarımı ve hiperparametre optimizasyonunu tamamen otomatikleştirebilir. Büyük ölçekli derin öğrenme modellerinde, hesaplama kaynaklarının verimli kullanımı için GA tabanlı optimizasyon stratejileri geliştirilmektedir. Transfer öğrenme ile birleştirilen GA'lar, farklı problem alanları arasında bilgi aktarımını optimize ederek model performansını artırır. Quantum hesaplama ile entegre edilen GA'lar, geleneksel hesaplama sınırlarını aşarak daha karmaşık optimizasyon problemlerini çözebilir. Edge computing (Uç Bilişim) uygulamalarında, kaynak kısıtlı cihazlar için GA tabanlı model optimizasyonu giderek önem kazanmaktadır (Li & Zhu, 2020).

İleri Seviye Genetik Algoritma Yöntemleri

GA'ların gelişmiş versiyonları, karmaşık optimizasyon problemlerinin çözümünde yeni fırsatlar sunar. Çok popülasyonlu GA'lar, farklı arama stratejilerini paralel olarak uygulayarak çözüm uzayını daha etkin şekilde keşfeder. Adaptif operatör seçimi mekanizmaları, algoritma parametrelerinin optimizasyon sürecinde dinamik olarak ayarlanmasını sağlar. Bellek tabanlı GA'lar, önceki nesillerde elde edilen bilgileri kullanarak arama sürecini hızlandırır. Hibrit meta-sezgisel yaklaşımlar, GA'ları diğer optimizasyon algoritmaları ile birleştirerek daha güçlü çözümler üretir. Çok kriterli karar verme problemlerinde, GA'ların Pareto-optimal çözümler üretme yeteneği geliştirilmektedir.

Yeni Araştırma Alanları ve Potansiyel Gelişmeler

GA'ların uygulama alanları sürekli genişlemekte ve yeni araştırma fırsatları ortaya çıkmaktadır. Büyük dil modellerinin (LLM) hiperparametre optimizasyonunda GA'ların kullanımı, model performansını ve hesaplama verimliliğini artırabilir (Pluhacek vd., 2023). Federe öğrenme sistemlerinde, GA'lar farklı veri kaynaklarından gelen bilgilerin optimizasyonunu sağlar (Huang vd., 2023). Sürdürülebilir yapay zêka uygulamalarında, enerji verimliliği odaklı GA tabanlı optimizasyon stratejileri geliştirilmektedir (Hidalgo vd., t.y.). Biyoinformatik alanında, GA'lar protein yapı tahmini ve ilaç keşfi süreçlerinde yeni yaklaşımlar sunar (Paiardini, 2023). Nöro-sembolik yapay zêka sistemlerinde, GA'lar sembolik ve alt-sembolik öğrenme arasında köprü görevi görür (Sarker vd., 2021).

Genetik Algoritmaların Otomatikleşmesi ve Uygulama Kolaylıkları

GA'ların kullanımını kolaylaştırmak için geliştirilen otomatik sistemler, optimizasyon süreçlerini daha erişilebilir hale getirir. Kullanıcı dostu arayüzler ve yazılım kütüphaneleri, GA tabanlı optimizasyon projelerinin hızlı bir şekilde uygulanmasını sağlar. Bulut tabanlı GA platformları, hesaplama kaynaklarının esnek kullanımını ve ölçeklenebilirliği destekler. Otomatik problem modelleme araçları, optimizasyon problemlerinin GA'lar için uygun formatta tanımlanmasını kolaylaştırır. Açık kaynak GA kütüphaneleri ve uygulama çerçeveleri, araştırmacıların ve geliştiricilerin algoritmaları özelleştirmesine ve geliştirmesine olanak tanır.

SONUÇ

Genetik Algoritmaların Derin Öğrenme Modellerindeki Yeri ve Önemi

GA'lar, derin öğrenme modellerinin optimizasyonunda vazgeçilmez bir araç haline gelmiştir. Geleneksel hiperparametre ayarlama yöntemlerinin sınırlamalarını aşan GA'lar, özellikle karmaşık model mimarilerinin optimizasyonunda üstün performans gösterir. Derin öğrenme modellerinin artan karmaşıklığı ve hesaplama gereksinimleri, GA tabanlı optimizasyon stratejilerinin önemini daha da artırmıştır. Bu algoritmalar, model mimarisi tasarımından hiperparametre seçimine kadar geniş bir yelpazede optimizasyon imkânı sunar. GA'ların paralel hesaplama yetenekleri ve adaptif özellikleri, büyük ölçekli derin öğrenme projelerinde zaman ve kaynak verimliliği sağlar.

Hiperparametre Optimizasyonu ve Performans Artışı

GA tabanlı hiperparametre optimizasyonu, derin öğrenme modellerinin performansında önemli iyileştirmeler sağlar. Otomatik hiperparametre ayarlama süreçleri, manuel deneme yanılma yaklaşımlarına göre daha tutarlı ve verimli sonuçlar üretir. GA'ların çok boyutlu arama uzayında etkin keşif

yapabilme yeteneği, optimal hiperparametre kombinasyonlarının bulunmasını kolaylaştırır. Model performansının yanı sıra, eğitim süresinin optimizasyonu ve hesaplama kaynaklarının verimli kullanımı da GA'lar sayesinde mümkün olur. Özellikle endüstriyel uygulamalarda, GA tabanlı optimizasyon stratejileri maliyet-etkin çözümler sunar.

Gelecek Çalışmalar İçin Öneriler

Gelecekteki araştırma ve geliştirme çalışmaları için birçok potansiyel alan bulunmaktadır. GA'ların kuantum hesaplama ile entegrasyonu, optimizasyon süreçlerinin verimliliğini artırabilir. Federe öğrenme sistemlerinde GA tabanlı optimizasyon stratejilerinin geliştirilmesi, dağıtık veri setleri üzerinde daha etkili model eğitimi sağlayabilir. Uç Bilişim uygulamaları için özelleştirilmiş GA varyantları, sınırlı kaynaklı cihazlarda model optimizasyonunu mümkün kılabilir. Nöro-sembolik sistemlerde GA'ların kullanımı, sembolik ve alt-sembolik öğrenme arasında daha güçlü bağlantılar kurabilir. Sürdürülebilir yapay zêka için enerji-verimli GA tabanlı optimizasyon yöntemlerinin geliştirilmesi, çevresel etkileri minimize edebilir.

KAYNAKLAR

Bengio, Y., Lecun, Y., & Hinton, G. (2021). Deep learning for AI. *Commun. ACM*, *64*(7), 58-65. https://doi.org/10.1145/3448250

Bergstra, J., & Bengio, Y. (t.y.). *Random Search for Hyper-Parameter Optimization*.

Deb, K., & Sundar, J. (2006). Reference point based multi-objective optimization using evolutionary algorithms. *Proceedings of the 8th annual conference on Genetic and evolutionary computation*, 635-642. https://doi.org/10.1145/1143997.1144112

Ding, S., Xu, L., Su, C., & Zhu, H. (2010). Using Genetic Algorithms to Optimize Artificial Neural Networks. *JCIT*, *5*, 54-62. https://doi.org/10.4156/jcit.vol5.issue8.6

Falkner, S., Klein, A., & Hutter, F. (2018). *Practical Hyperparameter Optimization for Deep Learning*. https://openreview.net/forum?id=HJMudFkDf

Forrest, S. (1996). Genetic algorithms. *ACM Computing Surveys*, *28*(1), 77-80. https://doi.org/10.1145/234313.234350

Gazioğlu, E., & Etaner-Uyar, A. S. (2022). Experimental analysis of a statistical multiploid genetic algorithm for dynamic environments. *Engineering Science and Technology, an International Journal*, *35*, 101173. https://doi.org/10.1016/j.jestch.2022.101173

Hidalgo, I., Fenández-de_Vega, F., Ceberio, J., Garnica, O., Velasco, J. M., Cortés, J. C., Villanueva, R., & Díaz, J. (t.y.). *Sustainable Artificial Intelligence Systems: An Energy Efficiency Approach*. Geliş tarihi 13 Aralık 2024, gönderen https://www.authorea.com/doi/full/10.36227/techrxiv.24610899.v1?commit=753d5bcddf6464fba9c02c829dd778ff1fdcbf47

Holland, J. H. (1975). Adaptation in natural and artificial systems. *Ann Arbor*.

Huang, Y., Tang, Z., & Li, A. (2023). Personalized Federated Learning with Genetic Algorithm. *2023 International Conference on Computers, Information Processing and Advanced Education (CIPAE)*, 577-583. https://doi.org/10.1109/CIPAE60493.2023.00114

Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm: Past, present, and future. *Multimedia Tools and Applications*, *80*(5), 8091-8126. https://doi.org/10.1007/s11042-020-10139-6

Khouy, M., Jabrane, Y., Ameur, M., & Hajjam El Hassani, A. (2023). Medical Image Segmentation Using Automatic Optimized U-Net Architecture Based on Genetic Algorithm. *Journal of Personalized Medicine*, *13*(9), Article 9. https://doi.org/10.3390/jpm13091298

Lee, J. S., Choi, L. C., & Park, S. C. (2011). Multi-Objective Genetic Algorithms, NSGA-II and SPEA2, for Document Clustering. Içinde T. Kim, H. Adeli, H. Kim, H. Kang, K. J. Kim, A. Kiumi, & B.-H. Kang (Ed.), *Software Engineering, Business Continuity, and Education* (ss. 219-227). Springer. https://doi.org/10.1007/978-3-642-27207-3_22

Li, Z., & Zhu, Q. (2020). Genetic Algorithm-Based Optimization of Offloading and Resource Allocation in Mobile-Edge Computing. *Information*, *11*(2), Article 2. https://doi.org/10.3390/info11020083

Ma, H., Shen, S., Yu, M., Yang, Z., Fei, M., & Zhou, H. (2019). Multi-population techniques in nature inspired optimization algorithms: A comprehensive survey. *Swarm and Evolutionary Computation*, *44*, 365-387. https://doi.org/10.1016/j.swevo.2018.04.011

Mehdary, A., Chehri, A., Jakimi, A., & Saadane, R. (2024). Hyperparameter Optimization with Genetic Algorithms and XGBoost: A Step Forward in Smart Grid Fraud Detection. *Sensors*, *24*(4), Article 4. https://doi.org/10.3390/s24041230

Nagae, S., Kawai, S., & Nobuhara, H. (2020). Transfer Learning Layer Selection Using Genetic Algorithm. *2020 IEEE Congress on Evolutionary Computation (CEC)*, 1-6. https://doi.org/10.1109/CEC48606.2020.9185501

Narayanan, A., & Moore, M. (1996). Quantum-inspired genetic algorithms. *Proceedings of IEEE International Conference on Evolutionary Computation*, 61-66. https://doi.org/10.1109/ICEC.1996.542334

Paiardini, A. (2023). Protein Structure Prediction in Drug Discovery. *Biomolecules*, *13*(8), Article 8. https://doi.org/10.3390/biom13081258

Pluhacek, M., Kazikova, A., Kadavy, T., Viktorin, A., & Senkerik, R. (2023). Leveraging Large Language Models for the Generation of Novel Metaheuristic Optimization Algorithms. *Proceedings of the Companion Conference on Genetic and Evolutionary Computation*, 1812-1820. https://doi.org/10.1145/3583133.3596401

Sarker, M. K., Zhou, L., Eberhart, A., & Hitzler, P. (2021). Neuro-symbolic artificial intelligence: Current trends. *AI Communications*, *34*(3), 197-209. https://doi.org/10.3233/AIC-210084

Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, *61*, 85-117. https://doi.org/10.1016/j.neunet.2014.09.003

Trauth, R., Hobmeier, A., & Betz, J. (2024). A Reinforcement Learning-Boosted Motion Planning Framework: Comprehensive Generalization Performance

in Autonomous Driving. *2024 IEEE Intelligent Vehicles Symposium (IV)*, 2413-2420. https://doi.org/10.1109/IV55156.2024.10588750

Xue, S., Guo, S., & Bai, D. (2008). The Analysis and Research of Parallel Genetic Algorithm. *2008 4th International Conference on Wireless Communications, Networking and Mobile Computing*, 1-4. https://doi.org/10.1109/WiCom.2008.1275

Yu, T., & Zhu, H. (2020). *Hyper-Parameter Optimization: A Review of Algorithms and Applications* (arXiv:2003.05689). arXiv. https://doi.org/10.48550/arXiv.2003.05689

Zhang, G., Li, N., Jin, W., & Hu, L. (2006). Novel Quantum Genetic Algorithm and Its Applications. *Frontiers of Electrical and Electronic Engineering in China*, *1*(1), 31-36. https://doi.org/10.1007/s11460-005-0014-8

Zhang, M., Geng, H., Luo, W., Huang, L., & Wang, X. (2006). A Hybrid of Differential Evolution and Genetic Algorithm for Constrained Multiobjective Optimization Problems. Içinde T.-D. Wang, X. Li, S.-H. Chen, X. Wang, H. Abbass, H. Iba, G.-L. Chen, & X. Yao (Ed.), *Simulated Evolution and Learning* (ss. 318-327). Springer. https://doi.org/10.1007/11903697_41

Zhang, Q., & Li, H. (2007). MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition. *IEEE Transactions on Evolutionary Computation*, *11*(6), 712-731. IEEE Transactions on Evolutionary Computation. https://doi.org/10.1109/TEVC.2007.892759

Quantum Machine Learning ile Siber Güvenlik: Yeni Nesil Tehditlerle Mücadelede Yenilikçi Yaklaşımlar

Faruk AYATA

Dr. Öğr. Üyesi; Van Yüzüncü Yıl Üniversitesi Başkale Meslek Yüksekokulu Bilgisayar Teknolojileri Bölümü. farukayata@yyu.edu.tr ORCID No: 0000-0003-2403-3192

ÖZET

Yapay zekâ (AI) ve kuantum makine öğrenimi (QML) teknolojilerinin siber güvenlik alanındaki entegrasyonu, yeni nesil tehditlere karşı güçlü bir savunma sağlar. Geleneksel güvenlik sistemleri, sürekli gelişen siber tehditlerle başa çıkmakta zorlanırken, yapay zekâ destekli sistemler tehditleri daha hızlı ve etkin bir şekilde tanıyabilir. Bu bağlamda, YZ ve QML, tehdit algılama, veri güvenliği ve kimlik doğrulama gibi kritik güvenlik süreçlerinde önemli roller üstlenmektedir. Özellikle QML'in kuantum hesaplama yetenekleri, büyük veri setleri üzerinde daha yüksek performans sunarak karmaşık saldırıların tespiti ve önlenmesinde avantaj sağlar. Kuantum teknolojisi ile güçlendirilmiş şifreleme yöntemleri, siber güvenlik stratejilerinin geleceğinde büyük önem taşıyacak ve hassas verilerin korunmasını daha güvenilir hale getirecektir süreçlerinin daha otomatik ve esnek hale gelmesine katkı sunarken, güvenlik uzmanlarının karmaşık tehditlere karşı hızlı ve proaktif çözümler üretmesine olanak tanır. Özellikle QML tabanlı algoritmalar, sıfırıncı gün saldırılarına karşı etkili savunma ve hızlı analiz sağlayarak, saldırganların davranışlarını tahmin etme konusunda yenilikçi çözümler sunmaktadır. Gelecekte QML'in siber güvenlik alanında daha geniş bir kullanım alanı bulması beklenmektedir. Bu çalışma, AI ve QML'in siber güvenlikteki potansiyel uygulamalarını ve sunduğu avantajları ortaya koyarak, bu teknolojilerin ilerleyen yıllarda daha güçlü ve etkili savunma stratejileri geliştirmede önemli katkılar sunabileceğini vurgulamaktadır.

Anahtar Kelimeler: Siber Güvenlik, Kuantum Makine Öğrenimi, Yapay Zekâ, Makine Öğrenimi, Kuantum Teknolojisi.

GİRİŞ

Hızla gelişen dijital çağ siber güvenlik uygulamalarını her zamankinden daha önemli bir hale getirmektedir. Siber saldırıların çeşitliliği arttıkça geleneksel güvenlik çözümleri yetersiz kalabilmektedir. Bu durumda AI, Makine öğrenmesi (ML) ve Derin öğrenme (DL) gibi teknolojiler güvenlik stratejilerine büyük katkı sağlamaktadır. Özellikle QML gibi yeni nesil teknolojiler, siber tehditlerle mücadelede daha güçlü ve etkin çözümler sunma potansiyeline sahiptir.

Siber Güvenlik ve Yapay Zekâ

Siber güvenlik, dijital dünyada verilerin korunması, ağların ve sistemlerin güvenliğinin sağlanması amacıyla sürekli olarak gelişen ve karmaşıklaşan bir alandır. Siber saldırılar daha karmaşık hale geldikçe, işletmeler kötü aktörlerin önünde kalmak için gelişmiş teknolojilerden yararlanmalıdır. İşte bu noktada AI devreye girer. AI, kuruluşların siber tehditleri tespit etmelerini,

yönetmelerini ve korunmalarını sağlayan güçlü bir araçtır. Siber güvenlik ekipleri sistemlerine AI'yı dahil ederek kritik içgörüler elde edebilir ve zaman alıcı süreçleri otomatikleştirebilir, böylece daha hızlı ve daha doğru karar alma sağlanabilir.
Siber güvenlikteki AI, ML ve DL gibi yapay zeka teknolojilerini güvenlik sistemlerine entegre eder. Bu teknolojiler, siber güvenlik sistemlerinin çok miktarda veriyi analiz etmesini, kalıpları tanımasını ve asgari düzeyde insan müdahalesiyle yeni ve gelişen tehditlere uyum sağlamasını sağlar. Tehditleri tespit etmek için önceden tanımlanmış kurallara dayanan geleneksel siber güvenlik araçlarının aksine, AI destekli sistemler deneyimden ders alarak bilinen ve bilinmeyen tehditleri daha etkili bir şekilde tahmin etmelerine, tespit etmelerine ve bunlara yanıt vermelerine olanak tanır.

Quantum Machine Learning (QML) Nedir?

QML (Quantum Machine Learning), klasik makine öğrenimi algoritmalarını hızlandırmak, desteklemek veya geliştirmek amacıyla kuantum bilgisayarlar gibi kuantum cihazları üzerinde çalışan algoritmaları kullanır. Kuantum destekli makine öğrenimi olarak da bilinen bu yöntem, makine öğrenimi modellerini optimize etmek ve daha hızlı sonuçlar elde etmek için kuantum teknolojilerinin yüksek bilgi işlem gücünden yararlanır (Coursera, 2024)
Klasik bilgisayarlar sınırlı depolama ve işlem kapasiteleriyle kısıtlıdır. Buna karşın, kuantum destekli sistemler katlanarak artan depolama ve işlem kapasitesi sunar. Kuantum bilgisayarlarının bu özellikleri, çok büyük veri kümelerini analiz edebilme yeteneğini artırır ve klasik yöntemlerin çok daha uzun sürede tamamlayabileceği işlemleri hızlıca gerçekleştirme imkânı sağlar (Khan ve Robles-Kelly, 2020).

Siber Güvenlikte QML'in Potansiyeli

Siber güvenlikte QML'in potansiyeli, veri işleme hızındaki dramatik artış ve kuantum bilgisayarların sunduğu benzersiz özelliklerle yakından ilişkilidir. Geleneksel bilgisayar sistemleri belirli bir sınıra kadar performans gösterebilirken, kuantum bilgisayarlar, qubit adı verilen temel hesaplama birimlerini kullanarak daha karmaşık hesaplamalar yapabilmektedir. Bu durum, özellikle büyük veri setleriyle uğraşıldığında, QML'in siber güvenlik alanında devrim yaratabileceğini göstermektedir.
QML, saldırı tespit sistemlerinden kimlik doğrulama süreçlerine kadar birçok alanda kullanılma potansiyeline sahiptir. Özellikle siber saldırıların giderek daha sofistike hale geldiği günümüzde, klasik yöntemlerle bu saldırılara karşı koymak zorlaşmaktadır. QML, karmaşık veri yapılarını daha hızlı analiz edebilme ve bu verilerdeki anormallikleri erken tespit edebilme yeteneği sayesinde, geleceğin siber güvenlik uygulamalarında merkezi bir rol oynayabilir (Han ve ark., 2024).
Bu teknoloji, aynı zamanda veri şifreleme ve güvenli veri iletimi gibi kritik güvenlik süreçlerinde de önemli katkılar sağlayabilir. QML tabanlı

algoritmalar, günümüzde kullanılan şifreleme yöntemlerinden daha güçlü ve daha güvenli sistemlerin oluşturulmasını mümkün kılabilir. Bu da siber tehditlerin ve saldırıların sürekli olarak geliştiği bir ortamda, verilerin daha iyi korunmasını sağlayarak güvenlik açıklarını minimize edebilir (Mehmood ve ark., 2024).

SİBER GÜVENLİKTE GELENEKSEL YAKLAŞIMLAR

Saldırı Tespiti ve Önleme Sistemleri

Uluslararası kabul görmüş tanımlara göre, siber güvenliğin temel hedefleri arasında verilerin bütünlüğünü, gizliliğini ve erişilebilirliğini sağlamak yer alır. Bu nedenle, sistemlere yapılacak saldırıların doğru bir şekilde tespit edilmesi ve etkisiz hale getirilmesi kritik bir öneme sahiptir. Siber saldırılara karşı korunmak amacıyla genellikle imza tabanlı çalışan antivirüs yazılımları, zafiyet tarama araçları ve güvenlik duvarları gibi çeşitli yazılımsal ve donanımsal çözümler kullanılmaktadır. Ancak, yalnızca bir güvenlik duvarına ya da antivirüs yazılımına güvenmek, sistemlerin güvende kalması için çoğu zaman yeterli olmamaktadır (Kaya ve Yıldız, 2014). Özellikle "sıfırıncı gün" saldırıları olarak bilinen ve veri tabanlarında imzaları bulunmayan saldırılar, klasik yöntemlerle tespit edilememektedir. Bu gibi durumlarda, özellikle ilk kez sistemlere sızmaya çalışan siber saldırganların davranışlarını analiz eden ve buna uygun profilleme yapan Saldırı Tespit Sistemleri (STS) devreye girmektedir.

STS, bilgisayar ya da ağ sistemlerinde gerçekleşen tüm aktiviteleri inceleyen, denetleyen ve kontrol eden güvenlik bileşenleri olarak tanımlanır. Güvenlik ihlali olasılığı belirdiğinde ilgili sistem yetkililerini ve ilgili departmanları uyararak alarm gönderen STS, olası güvenlik risklerini önemli ölçüde azaltmaktadır. Bace ve Mell (2011) STS'lerin çalışma döngüsünü üç ana başlık altında incelemişlerdir: bilgi toplama, değerlendirme-analiz motoru ve yanıt. STS, internet trafiğini ve sistemdeki veri alışverişini kontrol ederek, istemci ve sunucu arasındaki veri akışında herhangi bir anormallik olup olmadığını tespit etmeye çalışır. STS, önleyici bir sistem olmayıp, saldırganların sisteme zarar vermeden önce alarm veren ve güvenlik açıklarını erken tespit eden bir siber güvenlik önlemidir.

Yapay Zekâ ve Makine Öğrenimi Kullanımı

Siber güvenlik uygulamalarında AI tekniklerinin kullanımı, siber saldırılara karşı daha etkili ve dinamik bir savunma sağlamak için önemli bir potansiyele sahiptir. Geleneksel güvenlik araçları, güvenlik duvarları, antivirüs yazılımları ve giriş kontrol sistemleri gibi araçlar, siber saldırılara karşı temel savunma unsurlarıdır. Ancak, bu araçlar sınırlı bir kapasiteye sahip olup yeni ve hızla gelişen tehdit vektörlerine karşı her zaman yeterli olamamaktadır. Bu nedenle,

bu saldırılara ve tehditlere karşı hızlı bir şekilde yanıt vermek ve zararları en aza indirmek kritik bir önem taşır.
AI ve ML tabanlı teknolojilerin bu sistemlere entegrasyonu, güvenlik süreçlerini daha dinamik ve esnek hale getirir. Örneğin, AI destekli güvenlik duvarları ağ trafiğini analiz ederek anormal aktiviteleri belirleyebilir ve potansiyel saldırıları engelleyebilir. Makine öğrenimi algoritmaları kullanan antivirüs yazılımları, zararlı yazılımları daha etkili bir şekilde tespit edebilir ve yeni tehditlere karşı daha hızlı güncellenebilir. Giriş kontrol sistemleri, kullanıcı davranışlarını izleyerek yetkisiz erişim girişimlerini tespit edebilir ve otomatik olarak gerekli önlemleri alabilir. Böylece, AI ile desteklenen güvenlik sistemleri, mevcut tehditlere karşı daha güçlü ve esnek bir savunma sağlar, siber güvenlik uzmanlarının hızla değişen tehdit ortamına daha etkili bir şekilde yanıt vermesine olanak tanır. Bu yenilikçi yaklaşımlar, kurumların dijital varlıklarını daha güvenli hale getirirken, sürekli değişen siber tehditlere karşı proaktif bir koruma sağlar (Şeker, 2020).

QUANTUM HESAPLAMA VE QML'İN TEMELLERİ

Quantum hesaplama, klasik bilgisayarlardan farklı olarak verileri qubit adı verilen kuantum bitleriyle işleyerek hesaplama gücünde devrim niteliğinde bir artış sunar. QML ise, klasik makine öğrenimi algoritmalarının kuantum hesaplama altyapısında çalıştırılmasıyla elde edilen yeni bir yaklaşımı ifade eder.

Quantum Hesaplama Nedir?

Quantum hesaplama, klasik bilgisayarlardan farklı olarak verileri 0 ve 1'lerden oluşan ikili sistem yerine, kuantum mekaniği prensipleri üzerine inşa edilen qubitlerle işler. Qubitler, aynı anda hem 0 hem de 1 değerini alabilen süperpozisyon özelliğine sahip olduğu için, klasik bilgisayarlardan çok daha karmaşık hesaplamaları eşzamanlı olarak yapabilme yeteneğine sahiptir. Ayrıca, kuantum dolaşıklık gibi kavramlar sayesinde, kuantum bilgisayarlar paralel işlem yapabilme kapasitesini artırır ve hesaplamaları büyük ölçüde hızlandırır.
Qubitler, kuantum hesaplamada hem "süperpozisyon" hem de "kuantum dolanıklık" (entanglement) gibi özelliklere sahip olabilirler. Kuantum dolanıklık, iki veya daha fazla qubit'in birbirine bağlı olduğu ve bu qubitlerin bağımsız değil, birlikte hareket ettiği bir durumu ifade eder. Bu özellik, kuantum bilgisayarlarının paralel işlem yapabilme yeteneğini önemli ölçüde artırır. Klasik bilgisayarlar, bitlerin 0 ve 1 değerleri üzerinden işlem yaparken, kuantum bilgisayarlar süperpozisyon ve dolanıklık sayesinde aynı anda çok daha fazla olasılığı değerlendirebilir. Bu da bazı problemleri klasik

bilgisayarlardan çok daha hızlı bir şekilde çözebilme potansiyeline sahip olmalarını sağlar. Kuantum hesaplamanın temelinde, qubitlerin matematiksel olarak birleşmesi ve manipüle edilmesi yer alır ve bu işlemler kuantum kapıları ve kuantum devreleri kullanılarak gerçekleştirilir. Kuantum bilgisayarları, klasik bilgisayarların zorlandığı veya çözemediği bazı problemleri daha verimli şekilde çözmek için kuantum mekaniğinin temel özelliklerinden yararlanır. Ancak, bu teknoloji hala erken aşamadadır ve mevcut teknik zorluklar, kuantum bilgisayarlarının günlük hayatta yaygın olarak kullanılmasını engellemektedir (Değişmiş, 2024).

Quantum Bitler ve Qubitler

Bir kuantum biti veya kübit, klasik bilgisayarlardaki bitlerden farklı olarak, aynı anda hem 0 hem de 1 olabilen bir durumda bulunur. Bu özelliğe süperpozisyon denir ve kübitin ölçülene kadar birden fazla durumu aynı anda temsil etmesini sağlar. Klasik bilgisayarlarda bir bit yalnızca ya 0 ya da 1 olabilirken, kübit bu ikili durumu aynı anda var olma kapasitesine sahiptir. Bu içsel kuantum ikiliği, kuantum bilgisayarlarının birden fazla hesaplamayı eşzamanlı olarak yapmasını mümkün kılar. Sonuç olarak, klasik bilgisayarlarla karşılaştırıldığında, kuantum bilgisayarlarının işlem gücü üssel olarak artar ve büyük veri kümelerini işleme kapasitesi büyük ölçüde genişler. Bu, özellikle çok karmaşık matematiksel problemlerin ve büyük veri analizlerinin çözümünde kuantum bilgisayarlarını klasik bilgisayarların ötesine taşır (Alchieri, 2021).

Kübitlerin davranışını ve durumlarını anlamak için Bloch küresi adı verilen bir görselleştirme tekniği kullanılır (Şekil 1). Bloch küresi, tek bir kübitin kuantum durumunu üç boyutlu bir geometrik yapıda temsil eder. Kübitin durumu, Bloch küresinde herhangi bir noktaya karşılık gelir ve bu durum, iki boyutlu karmaşık bir vektör olarak ifade edilir. Bu gösterim, kübitin süperpozisyon durumunu daha somut bir şekilde anlamamıza ve görselleştirmemize yardımcı olur. Özellikle, çok kübitli sistemlerin davranışını anlamak ve bu sistemlerin içsel yapısını kavrayabilmek için Bloch küresinin sunduğu bu üç boyutlu temsil büyük önem taşır. Bu görselleştirme tekniği, kuantum algoritmalarının çalışma prensiplerini ve çoklu kübit sistemlerindeki kuantum dolaşıklık gibi olguları daha iyi analiz etmemize olanak tanır. Dolayısıyla, Bloch küresi yalnızca tek kübitli sistemleri anlamamıza değil, aynı zamanda çok kübitli ve daha karmaşık kuantum sistemlerini çözümlemek için de kritik bir araçtır (QNu Labs, 2024).

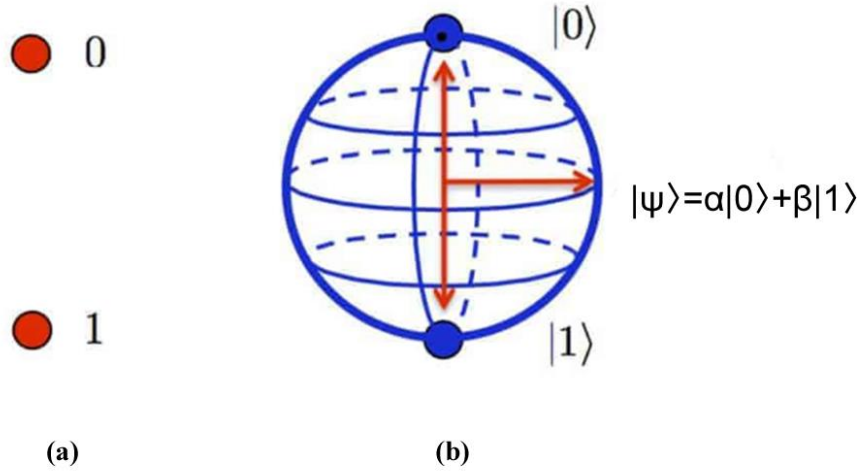

Şekil 1. (a) Klasik ve (b) Qubit yapılarının karşılaştırması

Klasik hesaplamada temel yapı taşı, 1 veya 0 olabilen ve dolayısıyla tek bir bilgi taşıyabilen bir durum olan bit'tir; kuantum hesaplamadaki karşılığı ise şu şekilde tanımlanan iki seviyeli bir kuantum durumu olan kübit'tir:

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (1)$$

Burada α, β ∈ ℂ ve $|\alpha|^2 + |\beta|^2 = 1$. Bit durumları $\{|0\rangle, |1\rangle\}$ 2 boyutlu Hilbert uzayında hesaplamalı baz adı verilen bir baz oluşturur ve karmaşık sayılar α ,β bilgiyi depolar: klasik bitin aksine, potansiyel olarak bir kübitin sonsuz miktarda bilgiyi depolayabileceği sonucu çıkar. Fiziksel bir bakış açısından, verilen hesaplamalı bazdaki bir ölçüm, süperpozisyon durumundan yalnızca iki olası sonuçtan birini, yani $|1\rangle$ veya $|0\rangle$, olasılıkla $p(0) = |\alpha|^2$ ve $p(1) = |\beta|^2$ verecektir. Gerçekte de, n -kübitli bir sistem için olasılık genliklerinin sayısının 2^n olduğu gösterilebilir; ancak hangi ölçümlerin yapılabileceği sistemden çıkarılabilecek bilgi miktarına bir sınır koyar: Buna Holevo sınırı denir ve n kübitin en fazla n durumu kodlayabileceğini belirtir (Holevo 1973).

Quantum Evrişimsel Sinir Ağları (QCNN)

Quantum Convolutional Neural Network (QCNN), klasik Convolutional Neural Networks (CNN) algoritmasının kuantum hesaplamanın gücüyle geliştirilmiş bir versiyonudur ve daha ileri düzey veri işleme görevlerini yerine getirmek için tasarlanmıştır. Şekil 2'de gösterildiği gibi, QCNN'ler klasik CNN'lerin temel yapı taşlarını, yani evrişim (convolution) katmanları, havuzlama (pooling) katmanları ve tam bağlantılı katmanları korur. Ancak, bu katmanlar kuantum işlemleri ile entegre edilmiştir, bu da QCNN'lere klasik CNN'lerden daha yüksek bir işlem gücü sağlar (Abreu ve ark., 2024; Kalinin ve Krundyshev, 2023).

QCNN'de evrişim katmanları, klasik CNN'lerdeki filtrelerle benzer işlevleri yerine getiren, komşu kübitlere uygulanan parametrelenmiş üniter işlemler ile oluşturulur. Bu kuantum evrişimleri, kübitlerin kuantum durumlarını analiz ederek, klasik CNN'lerde olduğu gibi pikseller yerine kuantum verileri üzerinde çalışır. Bu süreç, kuantum özelliklerinin tespit edilmesini ve çıkarılmasını sağlar, böylece QCNN, kuantum verilerinin işlenmesinde ve daha karmaşık veri yapılarına sahip problemlerin çözümünde güçlü bir araç haline gelir (Kalinin ve Krundyshev, 2023).

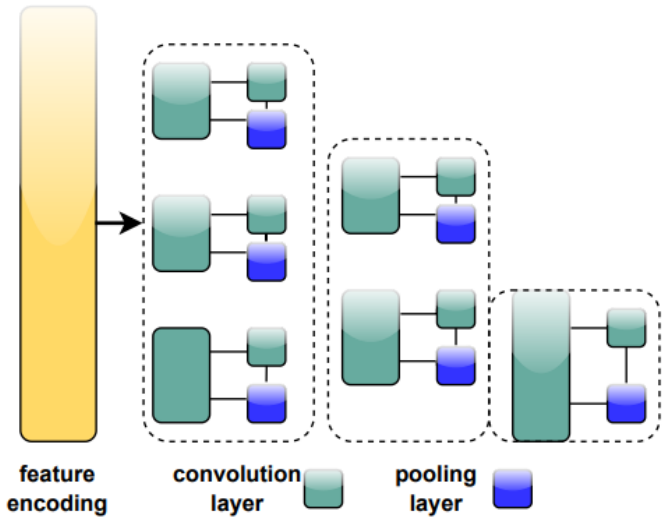

Şekil 2. Quantum Convolution Neural Network (CNN) yapısı (Abreu ve ark., 2024)

Quantum K-Nearest Neighbors (QKNN)

Quantum k-means (QKM), klasik k-means algoritmasının kuantum versiyonudur ve kümeleme görevlerinin verimliliğini ve etkinliğini artırmak amacıyla Kuantum Hesaplamanın benzersiz özelliklerinden yararlanmak üzere tasarlanmıştır. Klasik algoritmada olduğu gibi, QKM de verileri benzerliklerine göre farklı kümelere ayırmayı hedefler. QKM, veri noktalarını belirli kümelere ayırmak için aralarındaki benzerlikleri ve farkları tespit ederek bu kümeleri oluşturur (Abreu ve ark., 2024).

QKM'nin temel mekanizması, Şekil 3'te gösterildiği gibi, swap-test adı verilen bir kuantum devresine dayanır. Bu devre, veri noktaları ile küme merkezleri (centroid) arasındaki mesafeyi hesaplamak için kritik bir rol oynar. Kümeleme sürecinin en önemli aşamalarından biri olan bu mesafe hesaplama, kuantum teknolojisinin yardımıyla çok daha hızlı ve verimli bir şekilde gerçekleştirilebilir. Swap-test devresi, iki kuantum durumunu karşılaştırarak aralarındaki benzerlik veya farkları belirler ve bu sayede veri noktalarının hangi kümelere ait olduğunu daha kesin bir şekilde belirler (Abreu ve ark., 2024).

QKM'nin kuantum hesaplama yetenekleri, klasik k-means algoritmasına kıyasla büyük ölçekli veriler üzerinde daha hızlı sonuçlar elde edilmesini sağlar. Özellikle büyük veri kümelerinde, QKM klasik algoritmaların performansını aşarak verileri çok daha hızlı bir şekilde kümelere ayırabilir. Ayrıca, kuantum hesaplamanın sunduğu paralellik sayesinde aynı anda birden fazla işlem yapılabilir ve bu da algoritmanın verimliliğini önemli ölçüde artırır.

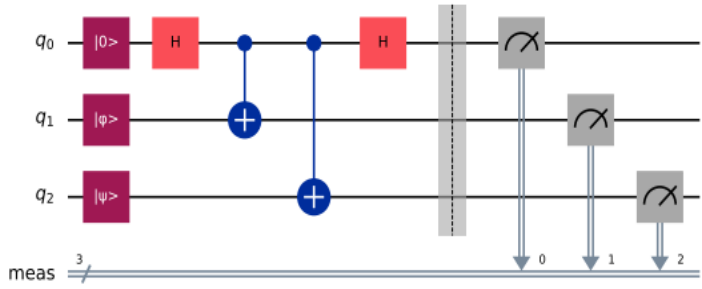

Şekil 3. QKNN'de kulanılan Swap-test yapısı (Abreu ve ark., 2024)

Quantum Support Vector Machines (QSVM)

Quantum Support Vector Machine (QSVM), klasik Support Vector Machine (SVM) algoritmasının bir uyarlamasıdır ve veri sınıflandırmasını geliştirmek amacıyla Kuantum Hesaplamanın avantajlarını kullanmak üzere tasarlanmıştır. Klasik SVM'den farklı olarak, QSVM girdi verilerini yüksek

boyutlu bir kuantum özellik uzayına yansıtarak çalışır (Şekil 4'de gösterildiği gibi). Bu kuantum özellik uzayı, başlangıçta doğrusal olarak ayrılması zor olan verilerin daha kolay ayrılmasına olanak tanır. QSVM, bu ayrımı, veriler arasındaki benzerliği kuantum uzayında ölçen bir kuantum çekirdeği oluşturarak gerçekleştirir. Bu kuantum çekirdeği, girdi verilerini temsil eden kuantum durumlarına uygulanan belirli kuantum dönüşümleriyle oluşturulur, bu da QSVM'nin, klasik yöntemlerin zorlanabileceği karmaşık sınıflandırma problemlerini çözmesini sağlar (Abreu ve ark, 2024; Kalinin ve Krundyshev, 2023).

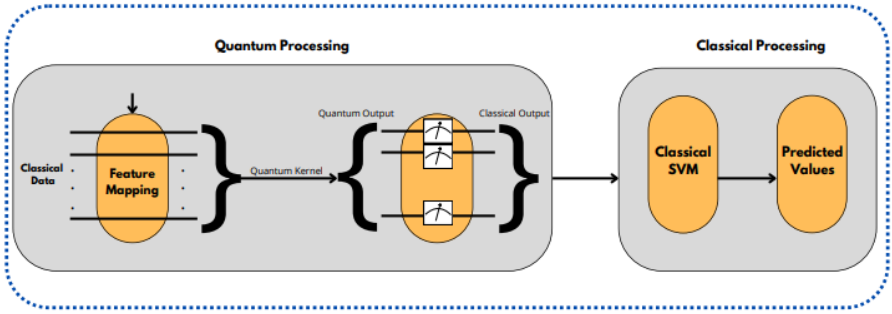

Şekil 4. Quantum Support Vector Machine (QSVM) süreci (Abreu ve ark., 2024)

SİBER GÜVENLİKTE QML KULLANIM ALANLARI

QML, kuantum hesaplamanın gücüyle makine öğrenimini birleştirerek, siber güvenlik alanında yenilikçi ve etkili çözümler sunar. Geleneksel güvenlik yöntemleri gelişen tehditlerle başa çıkmada yetersiz kalırken, QML'in sunduğu hesaplama avantajları sayesinde daha karmaşık saldırıların tespiti ve önlenmesi mümkün hale gelir. Bu bölümde, QML'in siber güvenlikteki başlıca kullanım alanları detaylandırılacaktır.

Saldırı Tespiti ve Tahmin Modelleri

QML, saldırı tespit sistemlerini daha etkin hale getirme potansiyeline sahiptir. Geleneksel makine öğrenimi teknikleriyle eğitilen sistemler, bilinen tehditler üzerinde oldukça etkili olsa da, QML ile geliştirilmiş modeller, kuantum paralelliği sayesinde bilinmeyen veya sıfırıncı gün saldırılarını daha hızlı tespit edebilir. QML'in büyük veri kümeleri üzerinde hızlı analiz yapma yeteneği, güvenlik sistemlerinin, saldırgan davranışlarını tespit ederek saldırıyı başlamadan önce önlemeye yönelik daha güçlü tahmin modelleri oluşturmasını sağlar. Bu avantaj, özellikle sürekli gelişen ve değişen siber tehditlerin daha erken tespit edilmesinde kritik rol oynar (Lloyd, 2014).

Verinin Güvenli Şifrelenmesi ve Deşifre Edilmesi

Siber güvenlikte en önemli unsurlardan biri veri güvenliğini sağlamaktır. Kuantum hesaplama, şifreleme algoritmalarını daha güçlü ve kırılması daha zor hale getirebilir. Kuantum şifreleme yöntemleri, klasik şifreleme sistemlerinin yetersiz kaldığı durumlarda daha güvenilir çözümler sunar. QML, kuantum şifreleme sistemlerinin gelişimini hızlandırarak daha güvenli veri iletim protokolleri geliştirilmesine yardımcı olabilir. Kuantum destekli algoritmalar, özellikle büyük ölçekli veri setlerinin korunmasında veri şifreleme ve deşifre işlemlerini daha verimli hale getirebilir (Shor, 1994).

Kimlik Doğrulama Sistemlerinde QML

Kimlik doğrulama sistemleri, bir sistemin güvenliğini sağlamak için kritik bir role sahiptir. Geleneksel sistemlerde biyometrik veriler veya parola tabanlı kimlik doğrulama yöntemleri kullanılır. Ancak, bu sistemler bazı durumlarda saldırıya açık olabilir. QML, kimlik doğrulama süreçlerini daha güvenli hale getirerek, kuantum tabanlı kimlik doğrulama yöntemleri geliştirebilir. Kuantum dolanıklık gibi özelliklerden faydalanan kimlik doğrulama sistemleri, sahtekarlık girişimlerine karşı çok daha güçlü bir koruma sunabilir. QML'in bu alandaki kullanımı, özellikle finansal sistemler, bankacılık ve hükümet ağları gibi hassas veri alanlarında önemli avantajlar sağlar (Ekert, 1991).

Veri Sızıntılarını Önleme

Veri sızıntıları, şirketlerin ve hükümetlerin karşı karşıya kaldığı en ciddi güvenlik tehditlerinden biridir. QML, veri sızıntılarını önlemek için gelişmiş analiz ve tespit algoritmaları sunar. Geleneksel veri sızıntısı önleme sistemleri, genellikle geçmişte bilinen tehditler ve veri hareketleri üzerinden çalışır. Ancak QML, büyük veri setlerini daha hızlı analiz ederek, normal dışı veri hareketlerini anında tespit edebilir. Bu, büyük sistemlerde sızıntıları daha erken fark etmeye ve önlemeye olanak tanır (Rebentrost et al., 2014).

QML Tabanlı Saldırı Simülasyonları

Siber güvenlikte en etkili savunma stratejilerinden biri, olası saldırı senaryolarını simüle etmektir. QML tabanlı saldırı simülasyonları, geleneksel yöntemlere göre çok daha detaylı ve etkili olabilir. Bu simülasyonlar, farklı saldırı türlerini ve saldırgan davranışlarını modelleyerek, sistemlerin ne kadar savunmasız olduğunu ortaya koyabilir. QML'in sunduğu hızlı işlem gücü ve derin öğrenme yetenekleri sayesinde, simülasyonlar gerçekçi ve kapsamlı sonuçlar üretebilir. Böylece siber güvenlik uzmanları, sistemlerin güvenlik açıklarını daha etkili bir şekilde tespit edebilir ve uygun savunma stratejilerini geliştirebilir (Wittek, 2014).

SONUÇ

Siber Güvenlikte QML'in Rolü

QML, siber güvenlikte önemli bir teknoloji olarak karşımıza çıkmaktadır. QML, kuantum hesaplama gücünü makine öğrenimi algoritmalarıyla birleştirerek siber güvenlik süreçlerini daha verimli hale getirme potansiyeline sahiptir. Özellikle büyük veri kümelerinin analiz edilmesi, karmaşık tehditlerin tespit edilmesi ve saldırıların önlenmesi gibi alanlarda QML, klasik yöntemlere kıyasla çok daha hızlı ve etkili çözümler sunabilir.

QML'in siber güvenlikteki en temel katkısı, gelişen ve sürekli değişen siber tehditlere karşı daha dinamik ve proaktif savunma stratejileri geliştirilmesine olanak tanımasıdır. Bu teknoloji, mevcut güvenlik sistemlerinin zayıf kaldığı noktalarda devreye girerek, siber güvenlik süreçlerinin güçlenmesine ve saldırılara karşı daha sağlam bir koruma sağlanmasına yardımcı olur. Siber güvenlik uzmanları, QML sayesinde daha karmaşık tehditlerin üstesinden gelebilecek ve siber savunma mekanizmalarını daha etkin hale getirebilecektir.

Gelecek Beklentileri ve Uygulama Alanları

QML'in siber güvenlikteki geleceği, kuantum hesaplama teknolojisinin gelişimine ve geniş çapta kullanılabilir hale gelmesine bağlıdır. QML, önümüzdeki yıllarda aşağıdaki beklentiler ve uygulama alanları ile siber güvenliğin temel taşlarından biri olabilir:

Daha Güçlü Tehdit Tespiti: QML, saldırganların davranışlarını öğrenme ve tahmin etme yetenekleriyle daha güçlü tehdit tespit sistemlerinin geliştirilmesine olanak sağlayacaktır. Özellikle büyük veri setlerinin hızla analiz edilmesi gereken durumlarda QML, klasik yöntemlerin çok daha ötesinde çözümler sunabilir. Bu sayede, gelecekteki tehditler daha hızlı tespit edilerek zararın en aza indirilmesi mümkün olacaktır (Wittek, 2014).

Kuantum Şifreleme ve Veri Güvenliği: Kuantum bilişim teknolojisinin gelişimi ile birlikte, kuantum destekli şifreleme yöntemleri geleceğin siber güvenlik stratejilerinde kritik rol oynayacaktır. Kuantum şifreleme, klasik şifreleme yöntemlerinden çok daha güvenli olacak ve günümüzde kullanılan birçok şifreleme protokolünün yerini alacaktır. Özellikle bankacılık, sağlık ve hükümet gibi hassas sektörlerde kuantum şifreleme sistemlerinin yaygın olarak kullanılacağı öngörülmektedir (Ekert, 1991).

Makine Öğrenimi ile Entegrasyon: QML'in diğer makine öğrenimi teknolojileriyle entegrasyonu, gelecekte siber güvenlikte önemli avantajlar sağlayacaktır. Özellikle büyük veri analizi ve siber tehdit modelleme gibi alanlarda, QML ile klasik makine öğrenimi algoritmalarının birlikte kullanılması, siber güvenliğin daha esnek ve dinamik olmasına olanak tanıyacaktır. Bu, gelecekte daha karmaşık tehditlerin daha hızlı bir şekilde öngörülmesini ve önlenmesini sağlayacaktır (Rebentrost et al., 2014).

Yapay Zekâ ve Otomasyon: QML'in yapay zekâ ile entegrasyonu, siber güvenlik süreçlerinin daha otomatik hale gelmesini sağlayacaktır. Otomatik saldırı tespiti ve önleme sistemleri, insan müdahalesine gerek kalmadan siber tehditlerle başa çıkabilecek ve bu sayede güvenlik açıklarının daha hızlı kapatılmasına yardımcı olacaktır. Bu tür sistemler, gelecekte otonom siber güvenlik yapılarının oluşturulmasında önemli bir rol oynayacaktır (Lloyd, 2014).

QML, gelecekte siber güvenlik alanında büyük yenilikler vaat eden bir teknoloji olarak öne çıkmaktadır. Kuantum bilgisayarların tam potansiyelini açığa çıkarabilmesi için donanım ve yazılım altyapısının geliştirilmesi gerekmektedir. Ancak, bu teknoloji olgunlaştığında, QML'in siber güvenlikte yaygın ve kritik bir rol oynayacağı kesinleşecektir.

REFERANSLAR

Abreu, D., Moura, D., Rothenberg, C. (2024). QuantumNetSec: Quantum Machine Learning for Network Security. *Advance.* September 03, 2024. DOI: 10.22541/au.172540693.31989215/v1.

Alchieri, L., Badalotti, D., Bonardi, P. (2021). An introduction to quantum machine learning: from quantum logic to quantum deep learning. *Quantum Mach. Intell.* Cilt **3**, Sayı 28. https://doi.org/10.1007/s42484-021-00056-8

Bace, R., and Mell, P. (2011). NIST Special Publication on Intrusion Detection Systems, Publications of National Institute of Standards and Technology, 1- 53.

Coursera S., (2024). Quantum Machine Learning: What It Is, How It Works, and More. https://www.coursera.org/articles/quantum-machine-learning. Erişim tarihi: 03.10.2024.

Değişmiş, A. (2024). Kuantum Hesaplama Nedir? Nasıl Çalışır? https://bilgi.zone/kuantum-hesaplama. Erişim tarihi: 04.10.2024.

Ekert, A. K. (1991). Quantum cryptography based on Bell's theorem. *Physical Review Letters*, 67(6), 661-663. https://doi.org/10.1103/PhysRevLett.67.661

Han, H., Yao, J., Wu, Y., Dou, Y., & Fu, J. (2024). Quantum communication based cyber security analysis using artificial intelligence with IoMT. *Optical and Quantum Electronics*, *56*(4), 565.

Holevo, A.S. (1973). Bir kuantum iletişim kanalı tarafından iletilen bilginin niceliği için sınırlar. Probl Pered Inf. Cilt 9, Sayı 3, S.3–11.

Kalinin, M., Krundyshev, V. (2023). Kuantum makine öğrenme tekniklerini kullanarak güvenlik ihlali tespiti. *J Comput Virol Hack Tech* 19, 125–136. https://doi.org/10.1007/s11416-022-00435-0

Kaya, Ç., ve Yıldız, O., 2014. Makine Öğrenmesi ile Saldırı Tespiti: Karşılaştırmalı Analiz, Marmara Fen Bilimleri Dergisi,3:89-104.

Khan, T. M., & Robles-Kelly, A. (2020). Machine learning: Quantum vs classical. *IEEE Access*, *8*, 219275-219294.

Lloyd, S. (2014). Quantum machine learning. *Nature Physics*, 10(9), 631-633. https://doi.org/10.1038/nphys3029

Mehmood, A., Shafique, A., Alawida, M., & Khan, A. N. (2024). Advances and vulnerabilities in modern cryptographic techniques: A comprehensive survey

on cybersecurity in the domain of machine/deep learning and quantum techniques. *IEEE Access*, *12*, 27530-27555.

QNu Labs, (2024). Quantum 101- What is a Qubit?. https://www.qnulabs.com/quantum-101-qubit. Erişim Tarihi: 04.10.2024.

Rebentrost, P., Mohseni, M., & Lloyd, S. (2014). Quantum support vector machine for big data classification. *Physical Review Letters*, 113(13), 130503. https://doi.org/10.1103/PhysRevLett.113.130503

Shor, P. W. (1994). Algorithms for quantum computation: Discrete logarithms and factoring. In *Proceedings of the 35th Annual Symposium on Foundations of Computer Science* (pp. 124-134). IEEE. https://doi.org/10.1109/SFCS.1994.365700

Şeker, E. (2020). Yapay Zekâ Tekniklerinin / Uygulamalarının Siber Savunmada Kullanımı, UBGMD, vol. 6, no. 2, pp. 108–115, 2020.

Wittek, P. (2014). *Quantum machine learning: What quantum computing means to data mining*. Academic Press.

Bilgisayar Destekli EEG Analiz Sistemleri

Gamzepelin AKSOY[1]
Murat KARABATAK[2]

1- Dr. Gamzepelin AKSOY; Isparta Uygulamalı Bilimler Üniversitesi Teknoloji Fakültesi Bilgisayar Mühendisliği Bölümü. gamzepelina@gmail.com ORCID No: 0000-0002-5328-2983
2- Prof. Dr. Murat KARABATAK; Fırat Üniversitesi Teknoloji Fakültesi Yazılım Mühendisliği Bölümü. mkarabatak@firat.edu.tr ORCID No: 0000-0002-6719-7421
Bu çalışma Gamzepelin AKSOY'un EEG Sinyallerinin Sınıflandırılmasında Kuantum Tabanlı Karar Destek Sisteminin Gerçekleştirilmesi isimli doktora tezinden üretilmiştir.

ÖZET

Elektroensefalografi (EEG), beynin elektriksel aktivitelerinin ölçülmesi ve değerlendirilmesi için önemli bir tekniktir. EEG sinyalleri, beynin farklı fonksiyonlarını ve hastalıklarını incelemek amacıyla analiz edilir ve özellikle nörolojik hastalıkların erken teşhisinde büyük rol oynar. Ancak EEG verilerinin analizinde sinyal gürültüsü ve bireysel farklılıklar gibi çeşitli zorluklar bulunmaktadır. Bu çalışma, EEG sinyallerinin analizinde kullanılan klasik yöntemlerin etkinliğini inceleyerek, bu yöntemlerin tıbbi teşhis süreçlerine nasıl katkı sağladığını ve karşılaşılan zorlukların nasıl aşılabileceğini tartışmaktadır. Ayrıca, EEG'nin tıbbi uygulamalardan nörorehabilitasyona kadar geniş bir kullanım alanına sahip olduğu vurgulanmaktadır. Çalışma, EEG'nin geçmişteki gelişim sürecinden günümüze kadar olan aşamalarını, kullanılan sinyal işleme tekniklerini ve modern teknolojilerle entegrasyonunu kapsamlı bir şekilde ele almaktadır.

Anahtar Kelimeler – Elektroensefalografi, Beyin Bilgisayar Arayüzleri, Sinyal İşleme, Biyomedikal Veriler, Otomatik Teşhis Sistemleri.

GİRİŞ

Elektroensefalografi, bilgisayar bilimleri ve nöroloji alanlarının kesişim noktasında, beyin aktivitelerinin detaylı bir şekilde incelenmesi ve bu aktivitelerden elde edilen verilerin analiz edilmesinde kullanılan invaziv olmayan temel bir yöntemdir. Beyindeki nöronların senkronize elektriksel aktivitelerinden kaynaklanan EEG sinyalleri, beynin işleyişine dair kapsamlı bilgiler sunmaktadır. Bu sinyaller, sinirsel aktivitelerdeki değişiklikleri milisaniyeler düzeyinde tespit etme yeteneğiyle nörolojik teşhis süreçlerinde kritik bir rol oynamaktadır.

İnsan beyni, elektriksel sinyaller aracılığıyla iletişim kuran milyarlarca nörondan oluşur ve bu sinyaller, sinir sistemi işlevlerinin temelini oluşturur. EEG, bu elektriksel aktiviteleri ölçerek nörolojik hastalıkların teşhisi ve beyin fonksiyonlarının anlaşılmasında kritik bir rol oynar (Holmes & Khazipov, 2007). EEG, Epilepsi (Vidyaratne & Iftekharuddin, 2017), Parkinson (Shi vd., 2019), Alzheimer (Sneddon vd., 2005), majör depresyon (Loh vd., 2022), uyku bozuklukları (Behzad & Behzad, 2021) gibi nörolojik hastalıkların yanı sıra sürücü yorgunluğunun tespiti (Tuncer vd., 2021), bağımlılık eğilimi analizi (Yarğı & Postalcıoğlu, 2021), duygu analizi (Alakus vd., 2020) ve yalan tespiti (Abootalebi vd., 2009) gibi farklı alanlarda yaygın olarak kullanılmaktadır. Bu geniş uygulama yelpazesi, EEG'nin çeşitli disiplinler için önemli bir araç haline gelmesini sağlamaktadır. EEG sinyallerinin gürültüye duyarlılığı ve bireyler arasındaki biyolojik farklılıklar, veri analiz

süreçlerinde çeşitli zorluklar yaratmaktadır. EEG sinyallerinden anlamlı bilgiler çıkarılabilmesi için bu verilerin işlenmesi ve analizinde kullanılan yöntemlerin etkinliği büyük önem taşımaktadır.

Bu çalışma, EEG sinyallerinin analizinde kullanılan klasik yöntemleri ele alarak, bu yöntemlerin tıbbi teşhis süreçlerine olan katkısını incelemeyi amaçlamaktadır. Çalışmada, EEG sinyallerinin analizi sırasında karşılaşılan zorluklar, bu zorlukları aşmak için kullanılan teknikler ve analiz yöntemlerinin performansları değerlendirilmektedir. Ayrıca, EEG'nin farklı uygulama alanlarındaki kullanımı ve bu alanlarda geliştirilebilecek yöntemler tartışılmaktadır. Sonuç olarak, bu çalışma, EEG sinyallerinin analizine yönelik mevcut yaklaşımların etkinliğini kapsamlı bir şekilde değerlendirirken, tıbbi teşhis süreçlerini iyileştirmek ve daha etkili analiz yöntemleri geliştirmek için stratejik bir yol haritası sunmayı hedeflemektedir.

EEG'nin Tarihsel Gelişimi

Elektroensefalografi alanındaki keşiflerin kökeni 18. yüzyıla kadar uzanmaktadır. Bu keşifler, beyin aktivitesinin elektriksel özelliklerini anlamamıza ve EEG'nin gelişimine yol açmıştır. EEG alanındaki keşiflerin öncülerinden biri Galvani'dir; 1791'de yayınladığı çalışmada elektriksel uyarılar kullanılarak hayvanlarda kas hareketi sağlanabileceğini belirtmiştir (Piccolino, 1998). Bu çalışma, nöronlar arası elektrik iletiminin keşfini gösteren önemli bir adımdır. Daha sonra, Caton'un 1875'te Britanya Tıp Birliği'ne sunduğu raporda, hayvan beyinlerinden elektriksel aktivitenin kaydedilebileceğini göstermiştir. Bu dönemde yapılan araştırmalar, EEG'nin erken evrelerine ışık tutmuş ve sinir sistemi üzerindeki elektriksel etkileşimlerin incelenmesine yol açmıştır. Hayvanlar üzerinde yaptığı araştırmalarda, uykunun ve göze ışık tutulması gibi duyusal uyarıların beyin sinyallerinin değişimini tetiklediğini keşfetmiştir (Ormerod, 2006). Beck, 1890'da yayınladığı çalışmada, elektrotları doğrudan beyin yüzeyine yerleştirerek duyusal uyarılara karşı elde edilen beyin dalgalarını incelemiştir. Elektriksel beyin aktivitesinde kendiliğinden oluşan dalgalanmaların duyusal uyarı sonrasında durduğunu vurgulamıştır (Coenen vd., 2014).

Forbes ve Thatcher 1920 yılında sinir impulslarını güçlendirmek için elektronik kondansatör bağlı cihazlar kullanarak yeni bir elektronik çağ başlatmıştır. Forbes vd. bir araştırmalarında kombine elektro-kimyasal sinaptik iletim teorisini oluşturmuştur (Stone & Hughes, 2013). Hans Berger, 1924'te insan beyin dalgalarını kaydetmeyi başarmıştır ve ilk defa 'Elektroensefalogram' ifadesini kullanmıştır. Beyin sinyallerinin incelenmesi alanında yaptığı çalışmalarda α ve β dalgaları gibi dalga modellerinin karakterizasyonunu tanımlamıştır. EEG'nin zihinsel aktivite ve hasar durumlarında normal ve anormal durumlarını belirlemiştir (Haas, 2003). Berger beyin yüzeyine elektrotları yerleştirerek intrakraniyal elektroensefalografi tekniğini kullanmıştır. Grass, 1935 yılında 3 kanallı EEG cihazını ilk kez kurmuştur (Grass, 1984). Adrian ve Matthews, beyin

korteksindeki potansiyel dalgaların yorumlanması konusunda çalışmalar gerçekleştirmiştir (Adrian & Matthews, 1934). Davis ve Jasper, 1934'te katot ışınlı osiloskoplar yardımıyla insan beyin aktivitesini kaydetmiştir. Böylece klinik uygulamalarda kullanılacak olan ekipmanların geliştirilmesinde öncü olmuştur. Grey Walter, tümörlerin EEG tarafından tespit edilebileceğine yönelik çalışmalar gerçekleştirmiştir. Tümör bulunan kişilerin EEG kayıtlarında yavaş aktivite varlığına yönelik bilgiler sunulmuştur. Walter, Dovey ile gerçekleştirmiş olduğu çalışmalarda, tümörlerin tanımlanmasında EEG'deki teta dalgasının rolünü incelemiştir. Walter aynı zamanda epilepsi hastalığı üzerine yaptığı araştırmalar ile beyin sinyallerinin bu hastalıkla değişimini gözlemlemiştir (Bladin, 2006).

Jasper ve Carmichael, 1935 yılında alfa dalgaları üzerine çalışmalar gerçekleştirmiştir. Beyin hasarı durumunun delta dalgaları ile ilişkili olduğunu ve elektroensefalogramların psikoloji ile klinik nöroloji alanlarında önemli olduğunu belirtmiştir. Aynı zamanda epilepsi üzerine yapılan cerrahi müdahale sırasında EEG sinyallerinden elde edilen beyin korteks haritasından faydalanmıştır. Rockefeller Vakfı tarafından 1939 yılında açılan ilk EEG laboratuvarında klinik elektroensefalografi çalışmaları yürütülmeye başlanmıştır. 1947'de kurulan Amerikan Elektroensefalografi Derneği, EEG'nin standardizasyonu ve klinik kullanımı üzerine çalışmalar başlatmıştır. 1961 yılında UNESCO'ya bağlı olarak kurulan Uluslararası Beyin Araştırma Örgütü (International Brain Research Organization - IBRO), beyin aktiviteleri üzerine yapılan araştırmaların kapsamını genişletmiştir. Ayrıca, 1958 yılında Jasper tarafından EEG elektrot yerleşiminde kullanılan standartlar tanımlanmıştır (Avoli, 2012). Jasper, aynı yıl EEG kayıtlarını standartlaştırmak amacıyla uluslararası 10-20 elektrot yerleştirme sistemini geliştirmiştir (Silverman, 1963). Lynch ve Paskewitz, alfa ritimlerinin öğrenilmiş kontrolünde, bu ritimlerin yoğunluğunu etkileyen faktörlerin yapısal, fizyolojik ve bilişsel-dikkat faktörleri olduğunu raporlamıştır. Bu bulgular, otonom sinir sistemi aktivitesinin öğrenilebilir kontrolünün mümkün olduğunu vurgulamaktadır (Lynch & Paskewitz, 1971).

Vogel, 1970 yılında EEG'nin genetik temellerini incelemiştir. Bu çalışma, alfa ve beta dalgalarının yaş ve cinsiyete göre farklılıklarını ortaya koymuştur (Vogel, 1970). Hjort, EEG'nin genel özelliklerini tanımlamak amacıyla zaman alanı ile frekans alanı arasında bir bağlantı kurmuştur. Bu sayede, zamana dayalı hesaplamalarla temel sinyal özelliklerinin çevrimiçi olarak ölçülmesine olanak sağlamıştır (Hjorth, 1970). Petersen ve Olofsson, klinik teşhis çalışmalarında çocuklarda farklı hastalık durumlarıyla ilişkilendirilebilecek EEG'nin değerlendirilmesi için referans değerleri sunmuş ve bu bağlamda EEG'nin yaş ve cinsiyete göre gelişimini tanımlamıştır (Petersén & Eeg-Olofsson, 1971). Lehmann, 1971 yılında protez kol cihazının kontrolünü sağlamak amacıyla EEG motor sinyal takibi gerçekleştirmiştir (Nirenberg vd., 1971). Sterman ve Friar, 1972 yılında yaptıkları araştırmada, günümüzde neurofeedback olarak bilinen ve kişilerin

beyin sinyallerini ölçerek kendi beyin aktivitelerini düzenlemelerine olanak tanıyan sistemin temelini atmıştır (Sterman & Friar, 1972). Grossberg tarafından alfa dalgalarının kontrolü üzerine yapılan çalışmalar, beynin ve zihnin nasıl çalıştığını anlamak ve bu süreçlerin bilinçli olarak kontrol edilebileceğini göstermek açısından önemli bir temel oluşturmuştur (Grossberg, 1972).

1980'li yıllarda EEG analizleri için bilgisayar sistemleri etkin bir şekilde kullanılmaya başlanmış ve manuel Fourier analizinin yerini Hızlı Fourier Dönüşümü (Fast Fourier Transform - FFT) temelli spektral analiz yöntemi almıştır (Isaksson vd., 1981). Teknolojik gelişmeler, analog EEG cihazlarının yerini dijital EEG cihazlarına bırakmasını sağlamıştır. Bu sayede daha fazla veri toplama kapasitesine sahip, verilerin depolanması, işlenmesi ve paylaşılması daha kolay olan cihazlar geliştirilmiştir. Gotman, 16 kanaldan alınan EEG verilerini kullanarak epilepsi nöbetlerinin otomatik tanımlanmasını sağlayan bilgisayar tabanlı bir sistem geliştirmiştir (Gotman, 1982). Farwell ve Donchin, P300 bileşenlerini kullanarak bilgisayar aracılığıyla iletişim kurulabilen bir sistem geliştirip test etmişlerdir (Farwell & Donchin, 1988). Klasik EEG cihazlarındaki kanal sayısının yetersiz kalmasıyla yüksek yoğunluklu EEG'ler geliştirilmiştir. Bu cihazlarda 64 ile 256 arasında değişen sayıda elektrot yer almıştır. Bu gelişme sayesinde beyin aktivitesinin daha ayrıntılı haritaları çıkarılabilmiş ve klinik çalışmalarda daha iyi sonuçlar elde edilmiştir (Seeck vd., 2017).

Tüm bu gelişmelerin ışığında, EEG alanındaki araştırmalar 18. yüzyılda başlamış ve günümüze kadar devam etmiştir. Özellikle beyin bilgisayar arayüzleri üzerine yapılan çalışmalar, makine öğrenimi ve yapay zekâ gibi gelişen teknolojilerle birleştirilerek önemli bir çeşitlilik kazanmıştır. Bu entegrasyon, gelecekte EEG'nin beyin aktivitesini anlama, analiz etme ve hatta belirli durumlarda kontrol etme yeteneğini daha da geliştirmeyi hedeflemektedir. Bu çalışmada, EEG sinyallerinin analizi ve sınıflandırılmasında kullanılan klasik yöntemler ele alınmıştır. Çalışma, bu yöntemlerin tıbbi teşhis süreçlerindeki katkılarını ve uygulama alanlarını detaylı bir şekilde incelemeyi amaçlamaktadır.

Elektroensefalografi ve Beyin Dalgaları

EEG sinyallerinin analizi sırasında, sinyallerin frekans bileşenleri incelenir. Bu frekans bileşenleri, beynin elektriksel aktivitesinin belirli ritmik haritalarını veya 'nöral salınımlarını' temsil eder. Nöral salınımlar, beynin farklı durumları ve işlevleri ile ilişkilendirilebilen belirli frekans bantlarında ortaya çıkar. EEG'nin spektral içeriği, bu frekans bileşenlerinin ve salınım türlerinin analiz edilmesi anlamına gelir. Karmaşık beyin yapısını daha anlaşılır hale getirmek için, sinyal frekansları farklı frekans aralıklarına ayrılır. Senkronize olan sinyaller, beyin durumlarını yansıtan farklı frekans bantları aracılığıyla gösterilir. Tablo 1'de beyin dalgalarının sinyal frekans aralıkları ve bu aralıkların açıklamaları sunulmuştur (Kumar & Bhuvaneswari, 2012).

Tablo 1: Beyin Dalgaları Frekansları Tablosu.

Bant Adı	**Frekans Aralığı**	**Açıklama**
Delta (δ)	0.2-4 Hz	Özellikle derin uyku evrelerinde görülen en yavaş beyin aktivitesidir. Uyanık olan yetişkinler için anormal bir durumun varlığına işaret eder.
Teta (θ)	4-8 Hz	Gevşeme ve meditasyon ile ilgili olan bilinçaltı aktiviteleri gösterir. Büyüme, serotonin ve öğrenmeyi arttıran kortikal hormonun salgılanmasını sağlar.
Alfa (α)	8-12 Hz	Genellikle gözlerin kapalı olduğu uyanık ama rahatlamış durumlarda tüm yaş gruplarında görülür. Başın arka bölümü ve ön bölgelerden kaydedilen düşük sinyal gücüne sahip, yavaş dalga aktivitesidir.
Beta (β)	13-30 Hz	Konuşma, problem çözme, yargılama ve karar verme gibi bilinçli durumlarda ortaya çıkan davranış ve eylemler ile ilgili olan dalgalardır.
Gamma (γ)	30-100 Hz	Duyular ve belleğin bir araya geldiği uyanıklık ve duyusal girdilerin birleşimi sonucu oluşan dalgalardır.

EEG işaretleri, zaman ve frekans eksenlerinde incelenir ve genellikle beyin aktivitesiyle ilişkilidir. Bu nedenle zaman içinde genlik, faz ve frekans açısından değişiklik gösterebilmektedir. Beyin aktivitelerinin düzeyleri yükseldikçe EEG dalga frekansları artmakta ve genlikleri azalmaktadır. Egemen olan frekansların yaşa göre yükseldiği yeni doğanlarda frekansın 3-4 Hz iken, yetişkinlerde bu frekansların 8-12 Hz arasında olduğu bilinmektedir. Şekil 1'de EEG bantlarının frekans spektrum grafiği verilmiştir.

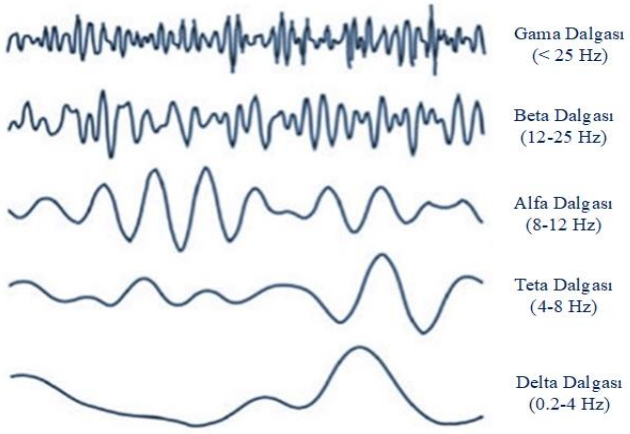

Şekil 1. EEG Bantlarının Frekans Spektrumu

EEG Sinyallerinin Ölçülmesi

Elektroensefalografi, kafa derisine yerleştirilen elektrotlar aracılığıyla beyindeki çeşitli dalgaları temsil eden sinyallerin ölçülmesi ve kaydedilmesini sağlayan bir tekniktir. Bu teknik, beyin aktivitelerinin haritalanmasını mümkün kılarak insan vücudunun davranışlarını kontrol etmeyi sağlayan süreçlerin anlaşılmasına katkıda bulunur. EEG cihazları, nöronlar arasında meydana gelen iyonik akımların yarattığı elektriksel akımı ölçmektedir.

Kafa derisine yerleştirilen elektrotlar, bir yükseltici aracılığıyla mikrovolt seviyesinde kayıt yapmaktadır. Kayıt süresi yapılan çalışmalara göre değişiklik gösterse de genellikle 20-40 dakika arasında sürmektedir. Kayıtların alınmasında uluslararası 10-20 sistemi kullanılmaktadır. Bu yöntem, beyin dalgalarından elde edilen sinyallerin standart bir şekilde kaydedilmesini sağlayarak, gerçekleştirilen deneysel süreçlerin zaman içinde karşılaştırılabilir olmasını mümkün kılar. Şekil 2'de EEG sisteminin gösterimine yer verilmiştir.

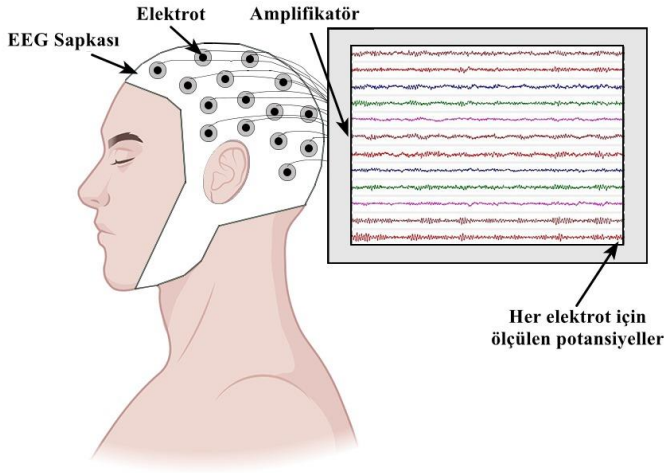

Şekil 2. EEG Sistemi

10-20 sistemi, elektrotların konumları ile beyin korteksi bölgeleri arasındaki ilişkiyi göstermektedir. Burun ile alnın birleştiği çukur noktadan (nasion) kafatasının arka alt kısmındaki çıkıntılı noktaya (inion) bir çizgi çekilir. Elektrotların kafa derisine yerleştirilmesi için kullanılan belirli noktalar vardır. Bunlar, beyin bölgelerine göre adlandırılmıştır ve Frontal Kutup (Fp), Frontal (F), Central (C), Parietal (P) ve Occipital (O) şeklinde ifade edilmektedir (Wong, 2004).

Fp, burun ile alnın birleştiği çukur noktadan %10 mesafe yukarısında yer alır. O ise kafatasının arka alt kısmındaki çıkıntılı noktadan %10 yukarıda bulunur. Diğer üç nokta ise Fp ile O noktaları arasında, eşit mesafe aralıklarıyla tanımlanır ve bu mesafeler, başlangıçta belirlenen aralığın %20'si olacak şekilde düzenlenir. Bu sistemde, tek sayılar sol yarımküreyi, çift sayılar ise sağ yarımküreyi temsil etmek için kullanılmaktadır (Wong, 2004). Şekil 3'te 10-20 sistemine göre yerleştirilmiş elektrotların konumları gösterilmiştir.

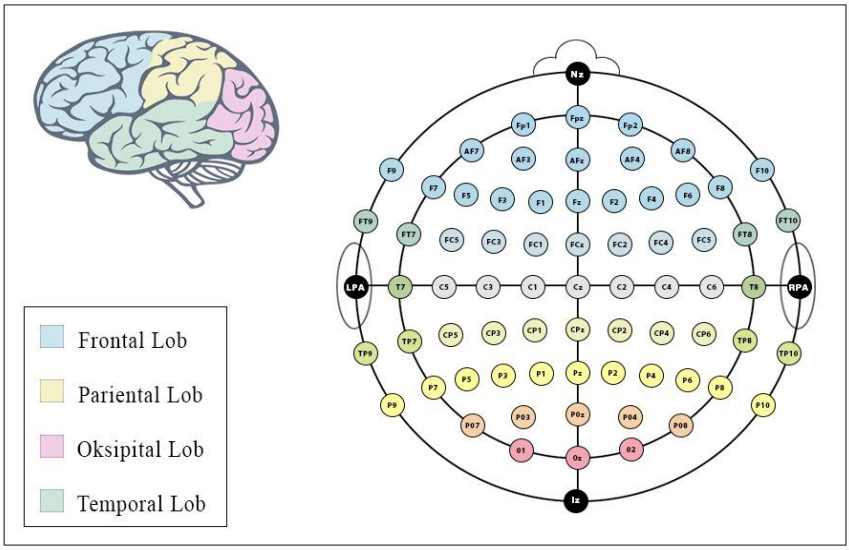

Şekil 3. EEG Sisteminde Kullanılan Elektrotların Konumu

Beyin Bilgisayar Arayüzleri

Beyin Bilgisayar Arayüzleri (BBA), beyin aktivitesinden elde edilen kontrol sinyallerini kullanarak insanların bilgisayarlar veya harici cihazlarla doğrudan ve gerçek zamanlı iletişim kurmasını sağlayan bir teknolojidir. Bu sistemler genellikle EEG gibi beyin aktivitesi ölçümleri kullanmaktadır. BBA, özellikle fiziksel engelli bireyler için büyük bir potansiyele sahiptir, çünkü kas hareketlerine ihtiyaç duymadan zihinsel işlevleri kontrol etmelerine olanak tanır. Ayrıca, bu sistemler zamanla sağlıklı bireylerin çeşitli yeteneklerini geliştirmek amacıyla da kullanılmıştır.

BBA'nın uygulandığı temel yöntemlerden biri, rehabilitasyon gerektirmeyen harici cihazları kontrol etmek için beyin aktivitesinin incelenmesidir. Diğer bir yöntem ise nörorehabilitasyon sürecinde kullanılan BBA sistemleridir; bu sistemlerde geri bildirim döngüsü, nöral plastisiteyi yeniden kazanmak veya beyin aktivitelerini düzenlemek için önemli bir rol oynamaktadır (Abiri vd., 2018).

Tıbbi alanlarda yapılan araştırmalar, BBA'nın hem teşhis ve tedavi süreçlerine odaklandığını hem de hastalık veya kaza sonucu merkezi sinir sisteminde oluşan hasarlar nedeniyle meydana gelen işlevsel kayıpların giderilmesini amaçladığını göstermektedir. Amyotrofik Lateral Skleroz (ALS), beyin sapı felci, serebral palsi ve omurilik yaralanması gibi durumlarda BBA'lar önemli bir rol oynamaktadır. Bu hastalıklara sahip bireyler için iletişim ve kontrol seçenekleri sunarak yaşam kalitesini artırabilmektedir. Bu doğrultuda, araştırmacılar beyin aktivitesini kullanarak robotik sistemlerin düşünme ve hayal etme yoluyla kontrol edilmesine olanak

tanıyan çalışmalar yapmaktadır. Ayrıca, beyindeki vücut kontrol mekanizmasının hasar almasından kaynaklanan sorunları olan hastalar için düşünce mekanizması ile kontrol edilebilen el protezleri üzerinde de çalışmalar yürütülmüştür (Nirenberg vd., 1971). Benzer şekilde, robotik bir kolun zihinsel komutlarla hareket ettirilmesini sağlayan yenilikçi sistemler de geliştirilmiştir (Bousseta vd., 2018). Yürüme engeli olan bireyler için, düşünce gücüyle kontrol edilebilen ve otomatik navigasyona dayalı tekerlekli sandalye sistemleri tasarlanmıştır (Iturrate vd., 2009). Felç geçiren hastaların, bilgisayarlar aracılığıyla insanlarla iletişim kurmalarını sağlamak amacıyla, düşünceleriyle hareket ettirebildikleri iki boyutlu imleç hareketine dayalı yöntemler oluşturulmuştur (Fabiani vd., 2004, Yu vd., 2019).

BBA'lar klinik uygulamalarda tanı sürecinde de etkin bir şekilde kullanılmaktadır. Örneğin, göğüs kanseri ve EEG sinyalleri üzerine yapılan bir çalışmada, kanser teşhisinin erken aşamaları için otomatik bir sistem önerilmiştir (Poulos vd., 2012). Parkinson hastalığının ileri aşamalarında, beyindeki anormal aktiviteyi değerlendirmek ve terapötik tedavi amacıyla düşük voltajlı elektriksel uyarıların ne zaman verilmesi gerektiğini belirlemek için bir BBA yöntemi tasarlanmıştır (Little vd., 2013). Şizofreni hastalığında görülen halüsinasyonların tedavisinde sanal/artırılmış gerçeklik ve BBA'ların kullanımının etkisi incelenmiştir. Bu yöntemler, geleneksel tedavilere alternatif olarak sunulmaktadır (Fernández-Caballero vd., 2017). BBA'nın bir diğer uygulama alanı rehabilitasyon süreçleridir. Bu süreçlerde, hastalardan belirli görevleri yerine getirmeleri istenmektedir. Bu sırada alınan EEG kayıtları, hastalara geri bildirim olarak sunulmakta ve böylece duyu-motor döngüsünün düzenlenmesine yardımcı olmaktadır (Van Dokkum vd., 2015). BBA sisteminin genel yapısı Şekil 4'te gösterilmiştir.

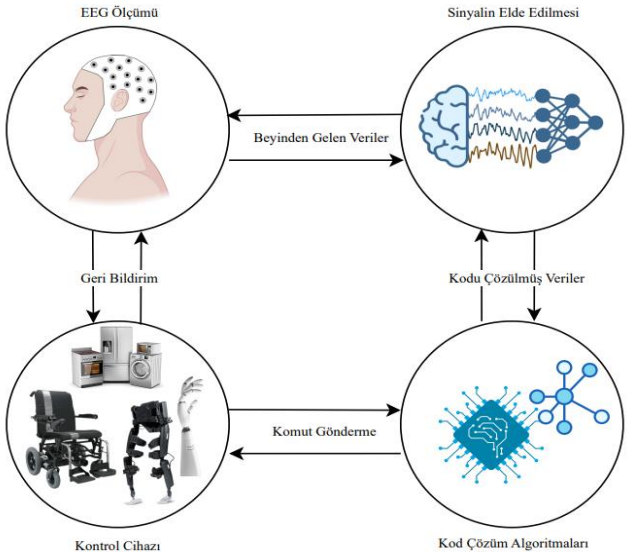

Şekil 4. BBA Sisteminin Temel Yapısı

Son yıllarda önemli bir araştırma alanı haline gelen Neurofeedback, beyin bilgisayar arayüzü uygulaması olarak kabul edilmektedir. Neurofeedback eğitimlerinde, bireylerin beyin dalgaları ölçülerek geri bildirim olarak sunulur ve hastalar kendi beyin dalgalarını kontrol etmeyi öğrenirler. Bu yöntem, otistik spektrum bozukluğu yaşayan bireylerde gözlemlenen anormal EEG nöbet aktiviteleri ve yüksek delta/teta aktivitesini hedef alarak, odaklanmayı artırmayı, nöropsikolojik işlevselliği iyileştirmeyi ve sosyal iletişimde gelişme sağlamayı amaçlamaktadır (Marzbani vd., 2016). Dikkat eksikliği ve hiperaktivite bozukluğu olan bireylerde 3 ay boyunca gerçekleştirilen eğitimler sonucunda nörolojik geri bildirimin olumlu olduğu raporlanmıştır (Fuchs vd., 2003). Dikkat eksikliği ve hiperaktivite bozukluğu olan bireylerde, 3 ay boyunca uygulanan eğitimler sonucunda nörolojik geri bildirimin olumlu olduğu raporlanmıştır (Tozzo vd., 1988). Aynı zamanda yapılan araştırmalar uzun süreli uyuşturucu kullanımının EEG sinyallerinde bozulmaya sebep olduğunu ve 12 saatlik bir eğitim süreciyle bu bağımlılığın azaltılabileceğini göstermiştir (Horrell vd., 2010).

Duygu analizi, EEG gibi tekniklerle incelenen önemli bir araştırma alanıdır. Bu analiz, duyguların beyindeki fizyolojik temsillerini anlamayı sağlayarak, insan davranışları ve zihinsel sağlık üzerinde derinlemesine bir anlayış sunabilmektedir. Örneğin, insan kişiliği ile EEG analizi arasındaki ilişkiyi inceleyen araştırmacılar, gerçek hayattaki duygusal deneyimleri karakterize ederek kişiliğin belirlenebileceğini belirtmiştir (Zhao vd., 2018). Başka bir incelemede, doğanın insan psikolojisi üzerindeki etkisini araştırmak amacıyla taşınabilir EEG cihazı takan katılımcılar, farklı üç bölgede yürütülmüştür. Bu süreçte, katılımcıların düşük hayal kırıklığı ve yüksek meditasyon gibi duygular hissettikleri sonucuna ulaşılmıştır (Aspinall vd.,

2015). İnsanlara çeşitli akustik müzikler dinletilerek yapılan bir araştırmada, müzik dinlemenin insanlarda yarattığı duygular analiz edilmiştir (Hsu vd., 2018).

BBA'nın tıbbi alanlar dışında farklı uygulama alanları da göze çarpmaktadır. Oyunlar ve sanal simülasyon ortamlarında, kullanıcının çeşitli fiziksel aktiviteleri gerçekleştirdiğini hayal etmesi istenerek çalışmalar yapılmıştır. Bu amaçla, el ve ayak hareketlerini temsil eden alanlara elektrotlar yerleştirilmiş ve katılımcılardan sadece ayaklarını hareket ettirdiklerini hayal etmeleri istenmiştir. Bu sayede, sanal bir ortamda kas hareketi olmadan hareket etmeleri sağlanmıştır (Pfurtscheller vd., 2006). Farklı bir çalışmada BBA kullanılarak bir beyin bilgisayar arayüzü ve sanal gerçeklik teknoloji birleştirilmiştir. Sadece motor görüntüleri kullanılarak sanal bir şehirde yürümenin fizibilitesi incelenmiştir (Leeb & Pfurtscheller, 2004). Geleneksel endüstriyel nesnelerin interneti sürecine EEG'nin entegre edilmesi, insan ve makine varlıklarının etkileşime girmesini sağlamaktadır. Endüstriyel robotların beyin sinyalleri ile kontrol edilmesi, insan sezgisinin teknolojiye uygulanmasına olanak tanımaktadır (Ajmeria vd., 2023).

BBA, kullanıcıların fiziksel olarak etkileşime girmeden çevrelerini kontrol etmelerine olanak tanıyarak daha bağımsız bir yaşam sürmelerine katkıda bulunmaktadır. Engelli bireyler için önemli bir iletişim ve kontrol aracı olarak yaşam kalitesini artırıcı bir etki yaratmaktadır. Ayrıca, beyin aktivitesinin daha iyi anlaşılmasını sağlayarak nörolojik hastalıkların teşhis ve tedavisinde potansiyel bir araç olarak kullanılmaktadır. Bunun yanı sıra, BBA sistemleri beyin aktivitesini kullanarak karmaşık görevleri gerçekleştirebilen robotlar gibi otonom sistemlerin geliştirilmesine de imkan sağlamaktadır.

Beyin aktiviteleri ile insan vücudu arasındaki ilişkilerin biyomedikal sistemlere uyarlanması oldukça karmaşık bir süreçtir. Bu karmaşıklık, oluşturulan sistemlerin beklenen performansı sergileyememesine sebebiyet verebilmektedir. Oluşturulan bu sistemlerin kullanımları genellikle kullanıcı eğitimi gerektirdiği için zaman alıcı ve maliyetlidir. Hazırlanan modellerde kullanılan EEG sinyallerinde bireysel farklılıklar oluşmaktadır. Aynı zamanda yeni gelişen teknolojilere uyarlanabilir olması da önem arz etmektedir.

BBA'nın temeli, beyin aktivitesinin kontrol sinyallerine dönüştürülmesine dayanmaktadır. Bu nedenle, beyin bilgisayar arayüzlerinin etkinliği ve güvenilirliği açısından, beyin kontrol sinyallerinin doğru bir şekilde anlaşılması ve yorumlanması kritik öneme sahiptir.

EEG Tabanlı Beyin Bilgisayar Araryüzü Kontrol Sinyalleri

BBA çalışmalarında yaygın olarak kullanılan EEG sinyalleri doğrudan beyinden gelen sinyal amplifikasyonuna dayanmaktadır. Bu sinyallerin daha belirgin bir şekilde görülmesine ve analiz edilmesine olanak sağlamaktadır. Kontrol sinyalleri üç grup altında toplanmaktadır: görsel uyarılmış potansiyeller, hibrit sinyaller ve kendiliğinden oluşan sinyaller. Şekil 5'te, BBA'larda kullanılan kontrol sinyallerinin şematik gösterimi yer almaktadır.

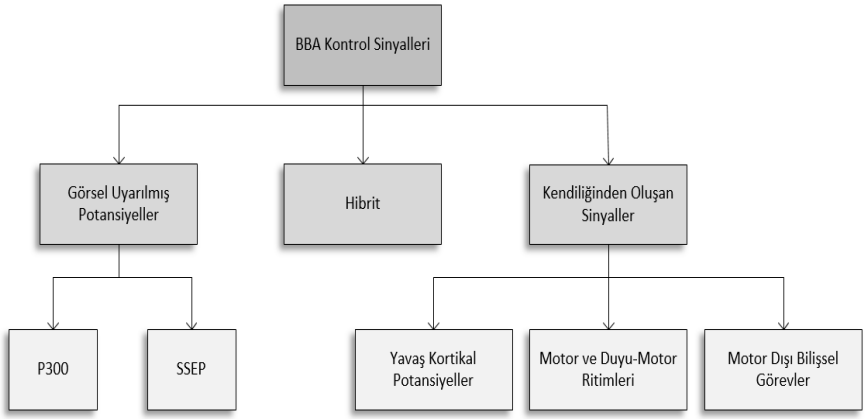

Şekil 5. BBA Kontrol Sinyalleri (Mridha vd., 2021).

Görsel Uyarılmış Potansiyeller

Görsel uyarılmış potansiyeller (Visual Evoked Potentials - VEP), gözlerin bir ışık veya desen gibi görsel bir uyarıcıya maruz kalması sonucu beyinde oluşan görsel bilgi işleme mekanizmalarını ifade etmektedir. Bu aktiviteler genellikle EEG kullanılarak ölçülmektedir. Işık, desen, renk olarak verilen bu uyaranlar gözler tarafından algılanarak, beyindeki görsel korteks tarafından işlenmektedir. Merkezi görsel alanın uyarılması, dışsal alanların uyarılmasından daha büyük VEP'lere sebep olmaktadır. Görsel uyarılmış potansiyeller tabanlı BBA'lar, deneğin görsel olarak odaklandığı hedef nesnenin EEG analizi yoluyla tanımlanmasını sağlamaktadır. Her hedef, beyinde özel bir yanıt oluşturur ve bu yanıt, hedefin algılanmasını sağlayan özel bir görsel uyaran dizisiyle ilişkilendirilir. Bu süreç, beyin tarafından üretilen elektriksel aktivitelerde farklılıklara yol açar (Bin vd., 2009).

P300 uyarılmış potansiyeller, Olayla İlgili Potansiyellerin (Event Related Potentials - ERP) bir bileşenidir. ERP belirli bir olay veya uyarana yanıt olarak beyinde üretilen elektriksel aktivitelerdir. P300, beklenmedik veya önemli bir uyaranın başlangıcından yaklaşık 300 ms sonra pik noktasına ulaşmaktadır. P300 bileşenleri; dikkat, uyaran işleme hızı, hata farkındalığı ve hafıza performansı ile ilişkili bilgi işlemeyi yansıtmaktadır. Yapılan çeşitli araştırmalar daha kısa P300 gecikmesi ve daha büyük P300 genliğinin, belirtilen bilişsel işlevlerde daha iyi performansla bağlantılı olduğunu ortaya koymaktadır (Fazel-Rezai vd., 2012).

Kararlı durum uyarılmış potansiyeller (Steady-State Evoked Potentials - SSEP), düzenli olarak değişen uyaranlara yanıt olarak ortaya çıkan ve beyin aktivitesinin frekans uzayında kolay analiz edilebilmesini sağlayan periyodik kafa derisi potansiyelleridir. Bu potansiyeller, genellikle hızlı bir

şekilde sunulan ve beyinden neredeyse sinüzoidal bir yanıt elde edilen uyaran dizilerine yanıt olarak ortaya çıkmaktadır. Ancak, her bir yanıt dizisi tek bir uyarana verilen yanıtı temsil ettiği için bu yanıtların yorumlanması bazen zor olabilir. Kısa kayıt süreleri, frekans alanında istatistiksel değerlendirmenin kolay olması nedeniyle elektrofizyolojik incelemelerde sıklıkla kullanılmaktadır. SSEP'lerin analizi, hem zaman alanında tepe yüksekliğinin ölçülmesi hem de frekans alanı spektrumunun değerlendirilmesi yoluyla gerçekleştirilir (Heinrich, 2010).

Kendiliğinde Oluşan Sinyaller

Herhangi bir dış uyaran etkisi olmadan kendiliğinden meydana gelen sinyaller olarak tanımlanmaktadır. Motor ve duyu-motor ritimleri, yavaş kortikal potansiyeller ve motor olmayan bilişsel görevler bu sinyal grubunda yer almaktadır.

Motor, duyu-motor sinyallerin kontrolü çeşitli bilişsel süreçlerin uyumlu bir şekilde organize edilmesini gerektirmektedir. Beyin, her an çeşitli duyusal bilgi kaynaklarını birleştirir, yaklaşan hareketleri seçer ve planlar, motor komutların sonuçlarını içsel olarak tahmin eder ve vücut ile çevredeki değişikliklere uyum sağlar. Duyu-motor kontrolünde, motor becerilerin zamanla kazanılabilir, uyarlanabilir ve iyileştirilebilir olması önemli bir özelliktir. Bu karmaşık ve birbiriyle bağlantılı süreçler, duyu-motor kontrolünün altında yatan nöral mekanizmaların daha derinlemesine anlaşılmasını zorlaştırmaktadır (Golub vd., 2016).

Yavaş kortikal potansiyeller (Slow Cortical Potentials - SCP), kortikal elektriksel aktivitelerdeki milisaniyelik kaymaları ifade eder. Bu sinyaller, dışarıdan tetiklenebileceği gibi kendiliğinden de oluşabilir ve bilgi işleme üzerinde düzenleyici bir rol oynar. Pozitif SCP'ler, zayıflamış irkilme refleksi gibi nöral yapılardaki kortikal uyarılmanın azaldığını gösterirken, negatif SCP'ler uyarılabilirliğin artması ya da beyin aktivitesinin yoğunlaştığı durumlarla ilişkilidir. SCP'ler, motor veya bilişsel görevlerin planlanması ve hazırlanması sırasında gözlemlenebilir (Gevensleben vd., 2014).

Motor dışı bilişsel görevlerde, kişiden genellikle fiziksel bir eylem gerçekleştirmesi değil, sadece bilişsel işlevlerini kullanması istenir. Bu görevler genellikle düşünme, dikkat veya hafıza gibi bilişsel süreçleri içermektedir. Bu tür görevler sırasında, kişinin beyin sinyalleri, belirli bir bilişsel sürecin gerçekleştirildiği anlarda ortaya çıkan beyin aktivitesini yansıtır.

Hibrit Sinyaller

Hibrit sinyaller, beyin tarafından üretilen farklı sinyal türlerinin bir kombinasyonunun kontrol amacıyla kullanılmasını ifade eder. Bu sistemde, beyinden elde edilen girdi sinyali tek bir türden değil, birden fazla türden oluşmaktadır. Bu yaklaşım, daha güvenilir bir kontrol sistemine olanak tanır ve her bir sinyal türünün dezavantajlarından kaçınılmasını sağlamaktadır (Mridha vd., 2021).

BBA sistemleri genellikle dört ana aşamadan oluşur. İlk aşama, beyin sinyallerinin elde edilmesidir. İkinci aşama, kaydedilen sinyallerin işlenmesidir; bu aşamada, sinyaller gürültüden arındırılır ve önemli özellikler çıkarılır. Üçüncü aşama, elde edilen bu özelliklerin bir modele verilerek sınıflandırılmasıdır. Sınıflandırma aşamasından sonra, uygulamaya geri bildirim gönderilir ve cihazların kontrolü sağlanır.

BBA Sistemlerinde Ön İşleme

BBA'larda kullanılan kontrol sinyallerinin doğasını anlamak oldukça önemlidir. Bu sistemlerde, kayıt esnasında çevresel faktörler, kullanılan elektrot veya yükselticiler, elektrotların yerleşim düzeni, kas ve göz hareketleri gibi unsurlar gürültü oluşumuna neden olabilir. Bu gürültüler, sinyalin doğru bir şekilde analiz edilmesini zorlaştırır. EEG sinyalleri, gürültü ve bozulmalara karşı oldukça hassas olduğundan, bu sinyalleri işlerken dikkatli olunması gerekmektedir. Gürültüyü azaltmak ve sinyal kalitesini artırmak için çeşitli filtreleme ve sinyal işleme teknikleri kullanılmaktadır. Bu aşamada, gürültüyü azaltmak için birkaç yöntem kullanılmaktadır:

Bağımsız Bileşen Analizi

Bağımsız Bileşen Analizi (Independent Component Analysis - ICA), özellikle biyomedikal alanda kullanılan kör kaynak ayırma yöntemlerinden biridir. Biyomedikal sinyaller genellikle birden fazla kaynaktan gelen sinyallerin bir kombinasyonunu içerir. ICA, bu karmaşık sinyal kombinasyonundan olabildiğince bağımsız olan orijinal EEG kaynak sinyallerini elde etme prensibine dayanır (Albera vd., 2012). ICA, çok kanallı EEG verilerini mekânsal olarak sabit ve zamansal olarak bağımsız bileşenlere ayırarak sinyalin kalitesini artırmak için kullanılır.

Yumuşatma Filtreleri

Yumuşatma filtreleri, analiz edilen sinyallerdeki gürültüyü azaltmak veya sinyalin belirli özelliklerini vurgulamak için kullanılır. Yumuşatma işlemi, sinyalin veri noktalarını değiştirerek gürültüyü azaltır ve aynı zamanda komşu noktalardan daha düşük olan noktaları artırarak daha düzgün bir sinyal elde edilmesini sağlar. Sıklıkla kullanılan çeşitleri şu şekilde açıklanabilir;

Savitzky-Golay filtresi, bir en küçük kareler yumuşatma filtresidir. Bu yöntemde, her bir veri noktası, polinom uyumundan elde edilen yeni bir değer ile değiştirilir. Elde edilen bu yeni değer, temel doğrusal en küçük kareler uyumu kullanılarak belirlenir. Böylece, veri setindeki her bir değer daha doğru ve daha düzgün bir şekilde temsil edilir.

Medyan filtresi, işlenen verilerin artan sıraya göre dizildiği ve bu diziden medyanın hesaplandığı doğrusal olmayan bir filtredir. Medyan filtresi, sinyalin düzgünleştirilmesi veya gürültünün azaltılması amacıyla kullanıldığında, ortalamadan çok farklı olan aşırı değerlerin etkisini azaltır.

Bu sayede, daha istikrarlı ve güvenilir bir çıktı elde edilir (Kawala-Sterniuk vd., 2020).

Ortak Ortalama Referansı

Ortak ortalama referanslama yönteminde, her elektrot bölgesindeki kayıtların ortalaması alınarak bu ortalamalar referans olarak kullanılır. Temel amaç, belirli bir bölgedeki EEG sinyalinin gerçek beyin aktivitesini yansıtmasını sağlamak için elektrotlardan gelen gürültüyü azaltmaktır. Bu yöntemle, sadece tüm elektrotlarda ortak olan sinyal ve gürültü korunurken, herhangi bir elektrotta izole edilen sinyaller görünmez hale gelir. Bu sayede, mikro elektrot dizilerinin konumundaki ilişkili gürültü doğru bir şekilde temsil edilir ve ilişkisiz gürültü kaynaklarının katkısı en aza indirilir (Ludwig vd., 2009).

Uyarlanabilir Filtreler

Uyarlanabilir filtreler, sinyalin belirli özelliklerini vurgulamak veya gürültüyü azaltmak amacıyla ayarlanabilen sistemlerdir. Sabit bir sistemin performansının yeterli olmayacağı, değişen şartlar altında kullanılmak üzere tasarlanmışlardır ve genellikle gerçek zamanlı uygulamalarda tercih edilirler. Bu filtreler, ortamdan gelen bilgilere veya işlenen sinyaldeki değişimlere göre kendilerini ayarlayabilir. Ortamdan gelen bilgi, gerçek zamanlı olarak algılanabilir veya giriş sinyalinin istatistiksel özelliklerine ilişkin önceden sağlanmış bir bilgi şeklinde olabilir (Nascimento & Silva, 2014).

Ampirik Mod Ayrışımı

Ampirik mod ayrıştırma, temel fonksiyonların sinyalden türetilmesinin sağlandığı adaptif bir yaklaşımdır. Sinyaldeki daha yüksek frekanslı ölçeklerden daha düşük frekanslı ölçeklere kadar değişen enerjiyi sıralı olarak çıkaran bir temele dayanır. Ampirik mod ayrıştırma işlemi sonucunda elde edilen zaman serisi bileşenleri, sinyalin farklı zaman ölçeklerindeki değişen bileşenlerini temsil eder ve sinyalin yapısının daha iyi anlaşılmasına katkı sağlar. Bu yöntem, sinyallerin değişken doğasına uyum sağlayabildiği için oluşan gürültünün giderilmesine de olanak tanır (Boudraa vd., 2005).

Kanonik Korelasyon Analizi

Kanonik korelasyon analizi, iki farklı çok boyutlu değişken arasındaki doğrusal ilişkiyi ölçmek için kullanılan bir istatistiksel tekniktir. Kör kaynak ayrıştırması tekniklerinden biri olan bu yöntem, iki değişken arasındaki en yüksek korelasyonu bulur ve bu korelasyona karşılık gelen temel vektörleri tespit eder. EEG sinyalleri ile kas hareketleri arasında belirgin bir ilişki olduğu mantığına dayanan bu yöntem, EEG sinyallerinde kas hareketlerinden kaynaklanan artefaktların düzeltilmesini sağlayabilir (Clercq vd., 2007).

Kuantum Yapay Sinir Ağı Tabanlı Filtre

Tekrarlayan sinir ağları ve kuantum kavramlarının birleştirilmesiyle oluşturulan hibrit bir yöntem olan tekrarlayan kuantum yapay sinir ağı (Recurrent Quantum Neural Network - RQNN), EEG sinyallerindeki gürültülerin giderilmesi ve sinyal kalitesinin artırılması için kullanılır. Bu yöntemin temeli Schrödinger dalga denklemine dayanmaktadır. RQNN filtresi, nöbet tahmini gibi tıbbi uygulamalar için uygun olmamakla birlikte, BBA oyun uygulamalarında kullanılan EEG sinyallerinin ön işlenmesi için uygundur (Elsayed & Bayoumi, 2017).

EEG sinyallerindeki gürültülerden arındırılması aşaması olan ön işleme aşaması sinyallerin kalitesini arttırarak analiz için hazır hale gelmesini sağlamaktadır. Ancak EEG sinyallerinden anlamlı bilgiler elde edilebilmesi için bu aşama tek başına yeterli değildir. Bu aşamadan sonra, sinyallere özellik çıkarımı yöntemleri uygulanmaktadır.

BBA Sistemlerinde Özellik Çıkarımı

EEG sinyallerinin belirli özelliklerinin tanımlanması ve bu özelliklerden daha anlamlı modellerin oluşturulmasına yönelik işlemler, özellik çıkarımı olarak adlandırılır. BBA sistemlerinin etkinliğini artıran bu adım, sinyal işleme sürecinde önemli bir rol oynar. Özellik çıkarımı, EEG sinyallerindeki karmaşık bilgilerin basitleştirilmesini ve sınıflandırma algoritmaları tarafından daha iyi analiz edilmesini sağlar. EEG tabanlı özellik çıkarımı genellikle zaman alanı, frekans alanı ve zaman-frekans alanı özelliklerine odaklanır.

Zaman Alanı Özellik Çıkarımı

EEG sinyalleri durağan olmayan sinyaller olma dezavantajına sahip olmasına rağmen, zaman alanı özelliklerinin incelenmesi ve çıkarılması nispeten kolaydır. Zaman alanındaki özelliklerin elde edilebilmesi için sinyalin genlik değerlerine, dalga şekillerine ve zamanla değişimine odaklanılır. Zaman alanında özellik çıkarımı için olayla ilgili potansiyeller, bağımsız bileşen analizi, temel bileşen analizi, Hjorth özellikleri, Higuchi fraktalı, yüksek dereceli geçişler ve çeşitli istatistiksel teknikler kullanılmaktadır (Torres vd., 2020).

Olayla ilgili potansiyeller, beynin belirli bir uyarana veya uyaranlara verdiği tepkidir. Sinyallerde küçük voltaj tepkileri olarak ortaya çıkmaktadır. Bu sinyaller, belirli uyaranlar sonucu üretilen çoklu EEG sinyallerinin tamamından tek bir bileşen elde edilerek analiz edilir. Özellik çıkarımında, ERP'nin genliği, tepki süresi ve ortalaması gibi sonuçlar elde edilir, böylece uyaranlara karşı verilen tepkinin etkisi ve hızı belirlenir. ERP'lerde farklı zaman dilimlerinde farklı bileşenler (P100, N100, P200, N200, P300) gözlemlenmektedir. Bu bileşenlerin her biri, farklı bilişsel süreçleri ve duyusal işlemleri ifade eder (Gostilovich vd., 2023).

Temel Bileşen Analizi (Principal Component Analysis - PCA), veri boyutunu azaltırken çoklu değişkenler arasındaki ilişkileri tanımlamak için kullanılan bir tekniktir. Bu yöntem, veri seti içindeki istatistiksel bilgiyi koruyarak analizdeki yorumlanabilirliği artırmayı ve bilgi kaybını minimuma indirmeyi hedefler. PCA'nın temel amacı, veri setindeki varyansı maksimum düzeyde tutan yeni ve ilişkisiz değişkenler oluşturmaktır. Bu yeni değişkenler, bir özdeğer/özvektör probleminin çözülmesiyle elde edilir ve 'temel bileşenler' olarak adlandırılır. PCA, temel bileşenlerin oluşturulmasında veri setinin yapısal özelliklerine dayandığı için dağılım varsayımlarına ihtiyaç duymaz ve veri setinin özelliklerine uyum sağlayabilir (Jolliffe & Cadima, 2016). PCA yönteminin temel aşamaları şu şekilde sıralanabilir;

- Veriler standart hale getirilir.
- Standartlaştırılmış veri seti üzerinde kovaryans matrisi hesaplanır.
- Kovaryans matrisinin özdeğerleri ve özvektörleri hesaplanır.
- Özvektörlerin seçilir, seçilen özvektörler kullanılarak temel bileşenler oluşturulur.
- Seçilen temel bileşenlerle orijinal veri setinin yeni bir uzayda temsi edilmesi sağlanır.

Higuchi fraktalı, zaman serilerinin fraktal boyutunu değerlendirmek için kullanılan bir yöntemdir. Bu yöntemin, zaman serisinin belirli bir zaman aralığı boyunca fraktal özelliklerini hesaplamak için kullanılan matematiksel bir çerçevesi vardır. Higuchi fraktalı, zaman serisinin zamansal ölçeğe özgü özelliklerini hesaba katmadan bu fraktal boyutu hesaplar. Ayrıca, fraktal boyut, zamansal ölçeğin artan maksimum değeriyle ilişkili bir yapıyı ortaya koymaktadır (Nobukawa vd., 2019).

Hjorth parametresi, sinyalin zaman alanındaki istatistiksel özelliklerinin çıkarılmasını sağlayan etkinlik, hareketlilik ve karmaşıklık olmak üzere üç parametresi olan niceliksel terimlerdir. Bu parametreler zaman bağlı olmasının yanı sıra güç spektrumu özellikleri kullanılarak da elde edilmektedir. Etkinlik parametresi, zaman bölgesinde sinyalin varyans değerini belirler ve sinyalin toplam enerjisini ölçer. Etkinlik parametresinin matematiksel olarak belirlenmesinde x(t) sinyali için kullanılan formül Denklem 1'de yer almaktadır.

$$\mathrm{E} = \mathrm{Varyans}\big(x(t)\big) \tag{1}$$

Hareketlilik, sinyalin değişim hızını ölçmektedir. Denklem 2'de frekans bölgesindeki sinyalin enerjisi temsil eden bu parametrenin formülü bulunmaktadır.

$$H = \sqrt{\frac{Varyans\left(\frac{dx(t)}{dt}\right)}{E}} \quad (2)$$

Karmaşıklık parametresi, sinyalin dalgalanma modelinin karmaşıklık derecesini ifade etmektedir. Bu parametrenin 1 değerine yaklaşması sinyalin saf sinüs dalgasına benzediğini göstermektedir. Hareketlilik parametresinin hesaplanması sonucu elde edilmektedir. Bu parametrenin matematiksel formülü Denklem 3'te yer almaktadır.

$$K = \sqrt{\frac{H\left(\frac{dx(t)}{dt}\right)}{H(x(t))}} \quad (3)$$

Hjorth parametreleri düşük hesaplama maliyetine sahip olması sebebi ile özellik çıkarımı için sıklıkla tercih edilmektedir. Ancak sinyal parametrelerinin hesaplanmasında bazı istatistiksel yanılmalara yol açabilmektedir. Bu parametrelerde frekans alanında güç spektrumu hesaplanmasına rağmen frekans alanıyla ilgili ayrıntılı bilgi sağlamamaktadır.

İstatistiksel özellik çıkarımı, zaman alanında çeşitli istatistiksel teknikler kullanılarak gerçekleştirilir. Kullanılan tekniklerin formülasyonu Tablo 2'de yer almaktadır (Mridha vd., 2021).

Tablo 1. Özellik Çıkarımı Aşamasında Kullanılan İstatistiksel Yöntemler

İstatistiksel Yöntemler	Formüller
Minimum değer	$\min = \min(\mathrm{X}[n])$
Maksimum değer	$\max = \max(\mathrm{X}[n])$
Sinyal aralığı	$\mathrm{SA} = \max(x[n]) - \min(x[n])$
Dalga biçimi uzunluğu	$\mathrm{DBU} = \sum_{n=1}^{N} \lvert X[n] - X[n-1] \rvert$
Ortalama genlik değişim değeri	$\mathrm{OGDG} = \frac{1}{\mathrm{N}} \sum_{n=1}^{N} \lvert X[n] - X[n-1] \rvert$
Standart sapmadaki mutlak fark	$\mathrm{SSMF} = \sqrt{\frac{1}{\mathrm{N}} \sum_{n=1}^{N} (x[n] - x[n-1])^2}$
Ortalama mutlak değer	$\mathrm{OMD} = \frac{1}{\mathrm{N}} \sum_{n=1}^{N} \lvert x_n \rvert$
Standart sapma	$\mathrm{SS} = \sqrt{\frac{1}{N} \sum_{n=1}^{N} (x(n) - \mu_n)}$
Varyans	$\sigma^2 = \frac{1}{\mathrm{N}} \sum_{i=1}^{N} (x_i - \mu)^2$
Kök ortalama kare	$KOK = \left(\frac{1}{N} \sum_{i=1}^{N} \sqrt{\mathrm{I}x_i\mathrm{I}} \right)^2$
Skewness değeri	$\mathrm{SD} = \frac{1}{\mathrm{N}} \sum_{i=1}^{N} \left(\frac{x_i - \overline{x}}{\sigma} \right)^3$
Kurtosis değeri	$\mathrm{KD} = \frac{1}{N} \sum_{i=1}^{N} \left(\frac{x_i - \overline{x}}{\sigma} \right)^4$
Güç	$\mathrm{P} = \frac{1}{N} \sum_{n=1}^{N} \mathrm{I}x_n\mathrm{I}^2$

Zaman alanında uygulanan bu yöntemler, sinyallerinin özelliklerini anlamak ve analizlerin etkinliğini arttırmak açısından büyük önem taşır. Bu analizler sayesinde sinyallerin dalgalanma seviyeleri, karmaşıklıkları ve istatistiksel verileri elde edilebilir. Ancak sinyaller hakkındaki bilgilere erişim için sadece zaman alanında yapılan analizler yeterli değildir. Bu sebeple farklı frekans alanı yöntemleri de zaman alanından elde edilen bilgileri tamamlayıcı olarak kullanılmaktadır.

Frekans Alanı Özellik Çıkarımı

Sinyallerin zaman alanında olduğu gibi, frekans alanında da özellik çıkarımı büyük önem taşır. Sinyallerin frekans bileşenlerini elde etmek, sinyalin farklı frekans bantlarından analiz edilmesini kolaylaştırır. Bir sinyalin frekans alanı bileşenleri, sinyalin farklı frekanslardaki yapılarını ifade eder ve sinyalin frekans alanında nasıl dağıldığını gösterir. Frekans alanı bileşenleri,

sinyalin analizi ve işleme süreçlerinde kritik bir rol oynar. Bu amaçla kullanılan çeşitli yöntemler ve bu yöntemlerin varyasyonları mevcuttur.

Hızlı Fourier Dönüşümü (Fast Fourier Transform - FFT), sinyalleri zaman alanından frekans alanına dönüştürmek için kullanılan bir yöntemdir. Bu yöntemde, sinyallerin farklı frekans bileşenlerine ayrılması sağlanır ve sinyalin frekans bileşenlerini gösteren güç spektral yoğunluğu hesaplanır. Bu hesaplamayı gerçekleştirmek için öncelikle otokorelasyonun tahmin edilmesi gerekmektedir (Al-Fahoum & Al-Fraihat, 2014). Zaman alanında sinyalin tüm özellikleri bir arada gözlemlenebilirken, frekans alanında bu özellikler bağımsız frekans bileşenlerine ayrılarak analiz edilebilir. Bu işlem sırasında kullanılan formül Denklem 4'te verilmiştir.

$$X_k = \sum_{n=0}^{N-1} x_n * e^{-i2\pi kn/N} \tag{4}$$

N zaman örneği sayısını, n incelenen örneği, X_n sinyalin n zamanındaki genliğini k ise frekansı ifade etmektedir.

$$X_n = \frac{1}{N} \sum_{n=0}^{N-1} X_k * e^{-i2\pi kn/N} \tag{5}$$

Zaman alanındaki verilerin frekans alanına dönüştürülmesiyle, bu yöntemin zaman alanı verilerine uygulanabilirliği sınırlı hale gelmiştir (Kit vd., 2023). Ayrıca FFT, büyük gürültü duyarlılığına sahiptir.

Ortak Uzaysal Desenler (Common Spatial Pattern - CSP), EEG verilerinin uzamsal ayrıntısını artırmak için yaygın olarak kullanılan bir yöntemdir İlk olarak anormal EEG aktivitesini tanımlamak için CSP algoritması tanıtılmıştır. Daha sonra, BBA alanında hareketle ilgili kalıpları ve farklı zihinsel aktiviteleri ayırt etmek için etkili bir yöntem olduğu gösterilmiştir. CSP, EEG verilerinin sinyal-gürültü oranını azaltmaktadır. Optimal uzaysal filtreleme için ham EEG sinyallerini bir koşulun varyansını maksimize ederken diğer koşulun varyansını en aza indirerek ayırmaktadır (Singh vd., 2022). CSP'nin temel amacı, bu çok boyutlu veri matrisini daha az boyuta sahip bir alt uzaya dönüştürmektir. Bu alt uzay, belirli beyin aktivitelerini temsil edecek şekilde şekillendirilir. CSP, bu dönüşüm için doğrusal bir ilişki kullanır ve her bir EEG kanalının ağırlıklarını içeren bir matris aracılığıyla belirli beyin aktivitelerinin optimal şekilde temsil edilebileceği yeni bir uzay oluşturur (Afrakhteh & Mosavi, 2020). CSP gürültüye son derece hassastır ve aşırı uyum olasılığı yüksektir.

Yüksek Dereceli Spektral (Higher-Order Spectral - HOS), normal dağılıma uymayan süreçleri analiz etme yeteneğine sahiptir ve gürültülere

karşı dayanıklıdır. Bu analiz yöntemi, sinyalin güç spektrumunda kaybolan faz bilgisini içerir ve düşük sinyal-gürültü oranına sahip zayıf sinyallerde daha iyi sonuçlar vermektedir. Sinyalin yüksek dereceli momentlerine odaklanan bu yöntem sinyaldeki gürültüyü filtreleyerek, önemli bilgilere erişimi sağlamaktadır. Gauss gürültüsü gibi normal dağılıma uyan gürültülerin üçüncü ve daha yüksek dereceli momentlerindeki (çarpıklık ve basıklık) değerler sıfır olduğundan, bu tür gürültüleri filtreler ve sinyalin önemli olabilecek non-lineer özelliklerini belirler.

Frekans alanı özellik çıkarımı, sinyalin frekans bileşenlerini analiz ederek sinyalin karakteristik özelliklerinin belirlemeye yardımcı olur. Bu sayede, sinyalin analiz edilme sürecinde daha detaylı bilgi elde edilmesini sağlar. Zaman-frekans alanı analizi ise sinyalin hem zaman hem de frekans boyutlarında nasıl değiştiğini inceleyerek, sinyalin dinamik özelliklerini daha kapsamlı bir şekilde ortaya koyar.

Zaman-Frekans Alanı Özellik Çıkarımı

Zaman-frekans alanı özellik çıkarımı, bir sinyalin hem zaman hem de frekans alanlarındaki özelliklerini analiz ederek bilgi çıkarmayı amaçlayan bir tekniktir. Bu teknik, sinyalin zaman içindeki değişimini ve frekans bileşenlerini birlikte analiz ederek, sinyalin içerdiği bilgilerin daha kapsamlı bir şekilde incelenmesini sağlar. Zaman serileri veya sürekli sinyaller üzerinde etkili olan bu yöntem, sinyalin belirli bir zaman diliminde hangi frekans bileşenlerine sahip olduğunu göstermektedir.

Otoregresif Bileşenler (AutoRegressive Components - AR), Otoregresif yöntemler, EEG verilerini modellemek için yaygın olarak kullanılan yöntemlerdir. Bu yöntemler, her kanaldaki sinyali önceki zaman noktalarındaki sinyalin doğrusal bir kombinasyonu olarak temsil ederek sinyalin zamana bağlı değişimini açıklamayı amaçlamaktadır. Aynı zamanda çok değişkenli AR modelleri kullanılarak kanallar arasındaki ilişkilerde ölçülmektedir. Bu modeller sıradan, kısmi veya yönlendirilmiş tutarlılık ve doğrudan transfer fonksiyonu gibi nicelikleri hesaplamak için kullanılabilecek yararlı bilgiler sağlamaktadır. AR modelleri, EEG sinyallerini daha az yer kaplayarak ve daha az miktarda bilgiyle etkili bir şekilde temsil eder, bu da hesaplama açısından verimli bir temsil oluşturur. Ayrıca, AR modeli parametreleri, bireysel farklılıklardan kaynaklanan verilerdeki ölçeklendirme değişikliklerinden etkilenmez (Lawhern vd., 2012).

Dalgacık Dönüşümü (Wavelet Transform - WT), zamanla değişen biyomedikal sinyaller gibi çok sayıda veri noktasını içeren sinyallerin analizi için kullanılır. Durağan olmayan EEG sinyalleri gibi sinyallerde, ham verilerden özellik çıkarımı için en uygun yöntemlerden biri, dalgacık dönüşümü gibi spektral tahmin teknikleridir. WT yönteminde, orijinal EEG sinyali, dalgacıklar olarak adlandırılan basit ve güvenilir yapı bloklarıyla temsil edilmektedir (Al-Fahoum & Al-Fraihat, 2014). Bu yöntemin temel fikri, sinyali bir dizi dalgacık katsayısına ayrıştırmaktır. Dalgacık analizi,

sinyali daha az sayıda parametreyle temsil ederek sıkıştırır ve bu sayede sinyali daha küçük parçalara ayırmamıza olanak tanır. Her bir parçayı temsil etmek için uygun bir dalgacık fonksiyonu seçilerek, sinyalin daha iyi anlaşılması ve işlenmesi sağlanır. Dalgacık dönüşümü, bir sinyali farklı frekans bantları ve çözünürlüklerde analiz etmek için kullanılan bir yöntemdir. İlk adımda, sinyal yaklaşık ve detay katsayılarına ayrıştırılır. Yaklaşık katsayıları, sinyalin daha düşük frekanslı bileşenlerini, detay katsayıları ise daha yüksek frekanslı bileşenlerini temsil eder. Daha sonra, yaklaşık katsayıları aynı dalgacık dönüşümü adımı kullanılarak daha da ayrıştırılabilir. Bu süreç, zaman alanındaki sinyalin ardışık yüksek geçiş ve alçak geçiş filtrelemeleriyle elde edilir ve sinyalin farklı frekans bileşenlerine ayrılmasını sağlar. Alçak geçiş ve yüksek geçiş filtrelerinin denklemleri Denklem 6 ve 7'de yer almaktadır.

$$\mathrm{YGF(S)} = \mathrm{D}_{1j} = \sum_t S(t)k(2j-t) \tag{6}$$

$$\mathrm{DGF(S)} = \mathrm{A}_{1j} = \sum_t S(t)h(2j-t) \tag{7}$$

D_1 detay katsayısını ifade ederken, A_1 ise yaklaşık katsayısını ifade etmektedir. İlk katsayılar oluşturulduktan sonra A_1 katsayısı tekrar filtreleme işlemine tabi tutularak hedeflenen işaret elde edilene kadar ayrıştırılma işlemi devam ettirmektedir. Oluşturulan i. seviyedeki yaklaşık ve detay dalgacıklarının enerjisi Denklem 8 ve 9'daki matematiksel formül ile hesaplanmaktadır.

$$ED_i = \sum_{j=1}^{N} \left|D_{ij}\right|^2 \qquad i = 1,2,\ldots..,l \tag{8}$$

$$\mathrm{EA}_i = \sum_{j=1}^{N} \left|A_{ij}\right|^2 \qquad i = 1,2,\ldots..,l \tag{9}$$

Formülde l değeri ayrıştırılacak olan seviyeyi ifade ederken, N değeri her seviyedeki toplam detay ve yaklaşık katsayılarını belirtir (Salem vd., 2014). 4. Seviye dalgacık dönüşümünün şematik görünümü Şekil 7'de verilmiştir.

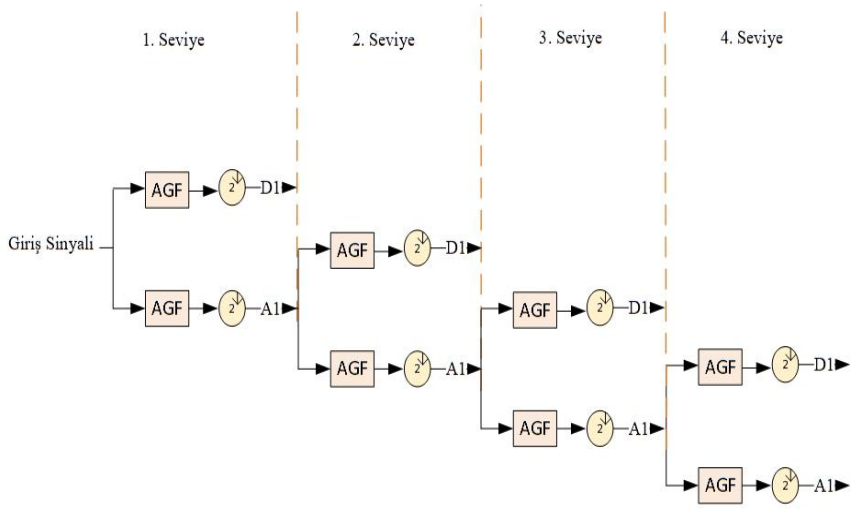

Şekil 6. Dördüncü Seviye Dalgacık Dönüşümü

EEG sinyalleri, beyin aktivitesini ölçmek için kullanılan önemli bilgi kaynaklarıdır. Bu sinyaller, beyin-bilgisayar arayüzü sistemlerinde beyin kontrol sinyalleri olarak işlev görür. BBA sistemlerinde, EEG sinyalleri önce ön işleme adımlarından geçirilir, ardından özellik çıkarımı yapılır. Bu süreç, sinyallerin daha anlamlı ve kullanışlı hale getirilmesini sağlar. EEG sinyallerinin analizi, sinyal işleme adımlarının ardından bu sinyallerden elde edilen özelliklerin sınıflandırılmasıyla tamamlanmaktadır. Bu bağlamda, farklı sınıflandırma yöntemleri EEG tabanlı sistemlerin etkinliğini artırmak amacıyla kullanılmaktadır.

EEG Sinyallerinin Analizi ve Klasik Sınıflandırma Yöntemleri

Makine öğrenmesi yöntemleri, verilerin matematiksel bir temsil kullanılarak modellenmesini sağlayan ve tıp alanında teşhis sistemlerinde önemli bir rol oynayan araçlardır. Bu sistemler, geçmiş vakalardan elde edilen veriler ile eğitilerek veriler arasındaki karmaşık ilişkileri öğrenir ve yeni vakaları analiz ederek tahminler yapabilir. Özellikle sağlık alanında makine öğrenmesi algoritmaları, tıbbi görüntüleme, hastalık teşhisi ve tedavi planlaması gibi kritik süreçlerde başarıyla kullanılmaktadır. Bu teknikler, büyük veri setlerindeki gizli örüntüleri ortaya çıkararak teşhis doğruluğunu artırmada etkili bir çözüm sunar.

EEG sinyalleri gibi karmaşık ve durağan olmayan biyomedikal verilerin analizinde makine öğrenmesi algoritmaları, farklı örüntülerin sınıflandırılmasında kritik bir rol oynar. EEG sinyalleri, ön işleme aşamalarından geçtikten sonra makine öğrenmesi tabanlı sınıflandırma algoritmaları kullanılarak analiz edilir. Bu yöntemler, sinyallerin frekans bileşenlerini, genliklerini ve diğer özelliklerini değerlendirerek, tıbbi

teşhislerde önemli bilgilerin elde edilmesine olanak tanır. Aşağıda, bu sınıflandırma yöntemleri detaylı olarak ele alınmaktadır.

Karar Ağaçları

Ağaç tabanlı öğrenme modeli olarak da bilinen karar ağaçları (Decision Trees - DT) sınıflandırma ve regresyon problemlerinin çözümünde kullanılan gözetimli öğrenme modellerindendir. Bu teknik, çok sayıda veri içeren bir veri kümesini yüksek bilgi kazancı sağlayacak şekilde tekrar tekrar daha küçük kümelere bölmek için kullanılmaktadır. Bu bölme işlemi sırasında her aşamada entropi değeri azalır ve model, sınıflandırma doğruluğunu artırmaya yönelik optimize edilir (Mahato & Paul, 2019).

Karar ağaçlarının temel yapısı şu şekilde tanımlanabilir: Düğümler, veri kümesindeki bir özelliği veya karar noktasını temsil eder. Yapraklar, farklı sınıf etiketlerini ifade ederken, dallar düğümler arasındaki bağlantıları ve karar kurallarını gösterir. Bölme işlemi sırasında entropi, kazanç oranı ve Gini indeksi gibi yöntemler, en iyi bölünmeyi belirlemek için kullanılır. Bu süreçte ağaç yapısının karmaşıklığını azaltmak ve genelleme yeteneğini artırmak amacıyla belirli durdurma kriterleri uygulanır. Daha az bilgiye sahip olan düğümler budanarak model sadeleştirilir.

Karar ağacı sistemlerinin en büyük avantajlarından biri, veriler arasındaki karmaşık ilişkileri görselleştirme ve anlama sürecini kolaylaştırmasıdır. Eksik verileri etkili bir şekilde işleyebilmesi, yorumlamasının kolay olması ve doğrudan anlaşılabilir karar kuralları sunması gibi özellikleri, bu yöntemin geniş bir uygulama alanında kullanılmasını sağlar. Bununla birlikte, küçük boyutlu veri setlerinde aşırı uyumlama riski yüksektir ve veri gürültüsüne karşı hassas olabilir (Song & Lu, 2015). Karar ağaçları, güçlü görselleştirme kabiliyetleri ve kullanım kolaylığı sayesinde EEG verilerinin sınıflandırılmasında etkili bir yöntemdir. Ancak daha karmaşık veri setlerinde, bu yöntemin doğruluğunu artırmak için rastgele orman gibi daha gelişmiş modellerle desteklenmesi gerekebilir.

Rastgele Orman Algoritması

Rastgele Orman (Random Forest - RF) algoritması, denetimli sınıflandırma ve regresyon problemlerindeki verimliliği ve yorumlanabilirliği nedeniyle sıklıkla tercih edilen bir yöntemdir. Bu algoritma, farklı karar ağacı modellerini bir araya getirerek kullanır ve özellikle değişken sayısının yüksek olduğu problemlerde yüksek performans sergiler. Her bir ağaç, rastgele seçilen özellikler arasından en iyisini seçerek oluşturulur, bu da her ağacın birbirinden bağımsız olarak eğitildiği ve tahmin yaptığı anlamına gelir. Sonuç olarak, her ağacın tahmini alınarak bir oylama yapılır ve bu oylama sonucu, rastgele ormanın final tahmini olarak kullanılır. Bu özellikler, RF algoritmasının doğruluğunu artırır.

Ağaçlar, yer değiştirmeli olarak orijinal veri setinden türetilen verilerle oluşturulur ve ağaçlarda budama işlemi yapılmaz. Ayrıca, hızlı bir algoritma

olması ve aşırı uyumlamaya karşı dayanıklı olması nedeniyle sınıflandırma işlemlerinde yaygın olarak kullanılır. Her ağacın bağımsız olarak eğitilmesi, algoritmanın paralelleştirilebilir olmasını sağlar ve bu da işlem hızını artırır ve büyük veri setlerinde daha verimli bir şekilde kullanılmasına olanak tanır (Biau & Scornet, 2016).

Naïve Bayes Algoritması

Naive Bayes (NB) algoritması, temeli Bayes teoremine dayanan ve olasılık tabanlı bir yaklaşımla çalışan bir sınıflandırma yöntemidir. Model, eğitim verilerindeki her bir çıktının tekrar sıklığını ve bağımsız değişkenlerin bağımlı değişkenlere olan etkisini değerlendirerek olasılık hesaplamaları yapar. Bu yaklaşım, hem kategorik hem de sayısal özniteliklere sahip verilerin sınıflandırılmasında kullanılabilir. Ayrıca, sınıf etiketi bulunmayan yeni verilerin etiket tahmini için etkili bir çözüm sunar (Aksoy, 2018).

Naive Bayes (NB) sınıflandırıcısı, kısa çalışma süresi, yüksek veri işleme kapasitesi ve veri akışını etkin bir şekilde yönetebilme yeteneğiyle sınıflandırma problemlerinde sıkça tercih edilen bir yöntemdir. Eksik verileri işleyebilme kabiliyeti ve hızlı çalışma özelliği, büyük veri setlerinde dahi etkili sonuçlar elde edilmesini sağlar. Model, her bir özniteliğin sınıf etiketi üzerindeki etkisini bağımsız olarak değerlendirir ve bu sayede veri setindeki öznitelik sayısının artmasına rağmen karmaşıklık seviyesi düşük tutulur. Ancak Naive Bayes algoritmasının dezavantajları da bulunmaktadır. Model, tüm özniteliklerin eşit derecede önemli olduğunu varsayarak öznitelikler arası ilişkileri göz ardı eder. Bu durum, ilgisiz veya bağımlı özelliklerin olduğu veri setlerinde tahmin performansının düşmesine neden olabilir. Tüm bu özelliklerine rağmen, Naive Bayes sınıflandırıcısı, sınıflandırma problemlerinde yaygın olarak kullanılan basit ve etkili bir yöntemdir.

Destek Vektör Makineleri

Destek vektör makineleri (Support Vector Machine - SVM) ilk olarak Vapnik tarafından önerilen bir yöntem olup, örüntü tanıma ve sınıflandırma problemlerinin çözümüne yönelik olarak tasarlanmıştır. İstatistiksel öğrenme teorisine dayanan SVM, hem doğrusal hem de doğrusal olmayan verilerin sınıflandırılmasında etkili bir şekilde kullanılabilir. Sınıflandırma işleminin temelinde, farklı sınıflara ait verilerin bir hiper-düzlem ile ayrılması prensibi yer alır (Vapnik, 2000).

SVM, eğitim veri setindeki en uç noktadaki verileri, yani destek vektörlerini kullanarak en uygun hiper-düzlemi belirler. Bu düzlem, sınıfları birbirinden mümkün olduğunca uzak tutacak şekilde optimize edilir ve her iki sınıfın veri noktaları arasındaki en kısa çizgiye dik bir doğrultuda yönlendirilir. Bu özellik, modelin genelleme yeteneğini artırır ve sınıflandırma performansını olumlu yönde etkiler. Doğrusal olarak ayrılabilen veri setlerinde, hiper-düzlem iki sınıfa eş uzaklıkta bir düzlem olarak tanımlanırken, doğrusal olarak ayrılamayan veri setlerinde çekirdek

fonksiyonları devreye girer. Bu çekirdek fonksiyonları arasında doğrusal, polinomiyal, sigmoid ve radyal tabanlı fonksiyonlar bulunur.

SVM, yüksek boyutlu veri setlerinde güçlü performans gösteren bir yöntemdir. Aşırı uydurmaya karşı dayanıklı olması, modelin genellemeye yönelik başarısını artırır. Ancak, büyük veri setlerinde hesaplama maliyetinin yüksek olması ve parametre seçimlerinin modele olan etkisi önemli dezavantajlar arasında yer alır. SVM hem doğrusal hem de doğrusal olmayan sınıflandırma problemleri için yüksek performanslı bir çözüm sunar. Ancak, hesaplama maliyeti ve çekirdek fonksiyonlarının seçimi gibi faktörler, kullanım sırasında dikkat edilmesi gereken önemli unsurlardır (Chua vd., 2011).

Lojistik Regresyon

Lojistik Regresyon (LR), değişkenlerin etkilerini incelemek, aralarındaki ilişkileri gözlemlemek ve sonuçları analiz etmek amacıyla tıbbi araştırmalarda sıkça tercih edilen bir yöntemdir. Bu yöntem, lineer regresyonun lojit ölçeğindeki bileşenlerini kullanarak, sonuç üzerindeki en yüksek olasılıkla etkili olan değişkenleri tanımlar ve modele dahil eder. LR, sınıflandırma problemlerinde, bağımlı değişkenin bir sınıfa ait olma olasılığını hesaplamak için kullanılır.

Modelleme sürecinde bağımsız değişkenlerin dikkatlice seçilmesi kritik öneme sahiptir. Bu seçim, geçmiş deneysel ve klinik araştırmaların sonuçları ve istatistiksel analiz yöntemleri kullanılarak yapılır. Ayrıca, aşırı uyumlama riskinden kaçınmak için yeterli örneklem boyutunun belirlenmesi gereklidir. Model oluşturma aşamasında, doğrudan, hiyerarşik ve istatistiksel yaklaşımlar yaygın olarak kullanılır. Model, bağımsız değişkenlerin etkilerini eş zamanlı olarak değerlendirir ve elde edilen sonuçlar hem model uyumu hem de bireysel değişkenler açısından yorumlanır.

Lojistik regresyon, küçük ve orta ölçekli veri setlerinde etkili sonuçlar sağlayan bir yöntemdir. Sağlık alanında, özellikle tıbbi teşhis süreçlerinde, değişkenlerin hastalık risklerini öngörmedeki etkilerini değerlendirmek ve sonuçları yorumlamak için kullanılır. Bu nedenle, sağlık verilerinin analizinde temel araçlardan biri olarak kabul edilir (Leeb & Pfurtscheller, 2004).

K-En Yakın Komşu Algoritması

K-En Yakın Komşu (K Nearest Neighbors - KNN) algoritması, yeni veriler ile mevcut veriler arasındaki benzerlikleri değerlendirerek sınıflandırma yapan, model oluşturma gerektirmeyen bir öğrenme yöntemidir. KNN, sınıflandırma işlemini, veriler arasındaki uzaklıkları hesaplayarak ve en yakın komşuların sınıf etiketlerine dayanarak gerçekleştirir. Bu yöntemde, uzaklık vektörleri (Minkowski, Öklit, Manhattan, Chebychev, Cosine ve Jaccard gibi) ve *k* komşuluk değeri belirleyici unsurlardır. *k* değeri, modelin doğruluğunu ve genelleme yeteneğini doğrudan etkiler. Sınıflandırma işlemi

sırasında, gözlem noktasına en yakın k komşu belirlenir ve en sık tekrarlanan sınıf etiketi, gözlem noktasının sınıfı olarak atanır (Han vd., 2011).

KNN algoritması, uygulanmasının kolay olması ve parametre sayısının azlığı nedeniyle sınıflandırma problemlerinde sıkça tercih edilmektedir. Gürültülü eğitim verilerine karşı dayanıklılığı da bu yöntemi avantajlı kılar. Bununla birlikte, algoritmanın performansı, seçilen uzaklık ölçütüne ve *k* değerine büyük ölçüde bağlıdır. Ayrıca büyük veri setlerinde yüksek hesaplama maliyeti, KNN'nin bir dezavantajı olarak öne çıkar. KNN, küçük ve orta boyutlu veri setlerinde basit ve etkili bir sınıflandırma çözümü sunar. Ancak, uzaklık ölçütü ve *k* komşuluk değerinin uygun şekilde belirlenmesi, modelin başarısı için büyük öneme sahiptir.

SONUÇ

Elektroensefalografi, nörolojik hastalıkların teşhisi, tedavisi ve rehabilitasyonu gibi pek çok alanda sunduğu imkânlarla tıbbi uygulamalarda devrim yaratmaya devam etmektedir. EEG'nin, özellikle Epilepsi, Parkinson ve Alzheimer gibi nörolojik hastalıkların erken teşhisinde kritik bir araç olması, bu teknolojinin sağlık alanındaki önemini daha da artırmaktadır. Bunun yanı sıra, klasik sinyal işleme yöntemlerinin ötesine geçerek, yapay zeka ve derin öğrenme algoritmalarıyla desteklenen EEG analiz yöntemleri, daha büyük ve karmaşık veri setlerinin kısa sürede ve hassas bir şekilde işlenmesini mümkün kılmaktadır. Bu gelişmeler, nörolojik bozuklukların yanı sıra nörodejeneratif rahatsızlıkların teşhisinde de yeni ufuklar açmıştır.

EEG'nin potansiyeli yalnızca nörolojik hastalıkların erken teşhisi ile sınırlı kalmamaktadır. Travma sonrası beyin hasarı yaşayan hastaların nörorehabilitasyon süreçlerinde önemli bir rol oynayan EEG, aynı zamanda psikiyatrik bozuklukların yönetiminde de etkin bir şekilde kullanılmaktadır. Beyin bilgisayar arayüzleri ile EEG'nin entegrasyonu, fiziksel engelli bireylerin yaşam kalitesini artırmaya yönelik inovatif çözümler sunmakta; bu sayede bireyler, zihinsel komutlarla protez cihazlarını veya çeşitli iletişim sistemlerini kontrol edebilme yetisine kavuşmaktadır. Günlük aktivitelerde bağımsızlık sağlayan bu teknolojiler, engelli bireyler için yeni fırsatlar yaratmaktadır.

Bunun yanı sıra, EEG'nin uygulama alanları arasında uyku araştırmaları, bilinç durumlarının analizi ve zihinsel performans artırma gibi önemli başlıklar yer almaktadır. Bu tür çok yönlü kullanım alanları, bireylerin hem kişisel hem de toplumsal düzeyde sağlık ve yaşam kalitesini artırmayı hedefleyen yenilikçi çözümler sunmaktadır. Özellikle, EEG'nin bulut tabanlı platformlarla entegrasyonu ve taşınabilir cihazların geliştirilmesi sayesinde bu teknolojiler dünya genelinde daha geniş bir kitleye ulaşma potansiyeline sahiptir.

EEG'nin derin öğrenme algoritmaları ve yapay zeka teknolojileriyle desteklenen geleceği, sadece nörolojik hastalıkların daha erken ve doğru bir şekilde teşhis edilmesini sağlamakla kalmayıp, kişiye özel tedavi yöntemlerinin geliştirilmesine ve beyin aktivitelerinin daha etkili bir şekilde kontrol edilmesine olanak tanımaktadır. Bu yenilikler, EEG teknolojisinin insan sağlığı ve yaşam kalitesi üzerindeki etkilerini derinleştirecek ve tıbbi uygulamalarda kalıcı değişimlere yol açacaktır. EEG'nin gelişimi, tıbbi teşhis ve tedavinin geleceğini şekillendiren en önemli araçlardan biri olma yolunda emin adımlarla ilerlemektedir.

REFERANSLAR

Abiri, R., Borhani, S., Sellers, E., Jiang, Y., & Zhao, X. (2018). A comprehensive review of EEG-based brain-computer interface paradigms. Journal of Neural Engineering, 16. https://doi.org/10.1088/1741-2552/aaf12e

Abootalebi, V., Moradi, M. H., & Khalilzadeh, M. A. (2009). A new approach for EEG feature extraction in P300-based lie detection. Computer Methods and Programs in Biomedicine, 94(1), 48-57. https://doi.org/10.1016/j.cmpb.2008.10.001

Adrian, E. D., & Matthews, B. H. C. (1934). The interpretation of potential waves in the cortex. The Journal of Physiology, 81(4), 440-471.

Afrakhteh, S., & Mosavi, M. R. (2020). Chapter 2—Applying an efficient evolutionary algorithm for EEG signal feature selection and classification in decision-based systems. İçinde A. Mohamed (Ed.), Energy Efficiency of Medical Devices and Healthcare Applications (ss. 25-52). Academic Press. https://doi.org/10.1016/B978-0-12-819045-6.00002-9

Ajmeria, R., Mondal, M., Banerjee, R., Halder, T., Deb, P. K., Mishra, D., Nayak, P., Misra, S., Pal, S. K., & Chakravarty, D. (2023). A Critical Survey of EEG-Based BCI Systems for Applications in Industrial Internet of Things. IEEE Communications Surveys & Tutorials, 25(1), 184-212. IEEE Communications Surveys & Tutorials. https://doi.org/10.1109/COMST.2022.3232576

Aksoy, G. (2018). Ağırlıklı Bayes sınıflandırıcıda ağırlıkların optimizasyonu / Optimization of the weights of weighted naïve Bayesian classifier. https://openaccess.firat.edu.tr/xmlui/handle/11508/18444

Alakus, T. B., Gonen, M., & Turkoglu, I. (2020). Database for an emotion recognition system based on EEG signals and various computer games – GAMEEMO. Biomedical Signal Processing and Control, 60, 101951. https://doi.org/10.1016/j.bspc.2020.101951

Albera, L., Kachenoura, A., Comon, P., Karfoul, A., Wendling, F., Senhadji, L., & Merlet, I. (2012). ICA-based EEG denoising: A comparative analysis of fifteen methods. Bulletin of the Polish Academy of Sciences: Technical Sciences, 60(3 Special issue on Data Mining in Bioengineering), 407-418. https://doi.org/10.2478/v10175-012-0052-3

Al-Fahoum, A. S., & Al-Fraihat, A. A. (2014). Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains. ISRN Neuroscience, 2014, 730218. https://doi.org/10.1155/2014/730218

Aspinall, P., Mavros, P., Coyne, R., & Roe, J. (2015). The urban brain: Analysing outdoor physical activity with mobile EEG. British Journal of Sports Medicine, 49(4), 272-276. https://doi.org/10.1136/bjsports-2012-091877

Avoli, M. (2012). Herbert H. Jasper and the Basic Mechanisms of the Epilepsies. Içinde J. L. Noebels, M. Avoli, M. A. Rogawski, R. W. Olsen, & A. V. Delgado-Escueta (Ed.), Jasper's Basic Mechanisms of the Epilepsies (4th bs). National Center for Biotechnology Information (US). http://www.ncbi.nlm.nih.gov/books/NBK98150/

Behzad, R., & Behzad, A. (2021). The Role of EEG in the Diagnosis and Management of Patients with Sleep Disorders. Journal of Behavioral and Brain Science, 11, 257-266. https://doi.org/10.4236/jbbs.2021.1110021

Biau, G., & Scornet, E. (2016). A random forest guided tour. TEST, 25(2), 197-227. https://doi.org/10.1007/s11749-016-0481-7

Bin, G., Gao, X., Wang, Y., Hong, B., & Gao, S. (2009). VEP-based brain-computer interfaces: Time, frequency, and code modulations [Research Frontier]. IEEE Computational Intelligence Magazine, 4(4), 22-26. IEEE Computational Intelligence Magazine. https://doi.org/10.1109/MCI.2009.934562

Bladin, P. F. (2006). W. Grey Walter, pioneer in the electroencephalogram, robotics, cybernetics, artificial intelligence. Journal of Clinical Neuroscience, 13(2), 170-177. https://doi.org/10.1016/j.jocn.2005.04.010

Boudraa, A.-O., Cexus, J.-C., & Saidi, Z. (2005). EMD-Based Signal Noise Reduction. Signal Processing, 1.

Bousseta, R., El Ouakouak, I., Gharbi, M., & Regragui, F. (2018). EEG Based Brain Computer Interface for Controlling a Robot Arm Movement Through Thought. IRBM, 39(2), 129-135. https://doi.org/10.1016/j.irbm.2018.02.001

Chua, K. C., Chandran, V., Acharya, U. R., & Lim, C. M. (2011). Application of Higher Order Spectra to Identify Epileptic EEG. Journal of Medical Systems, 35(6), 1563-1571. https://doi.org/10.1007/s10916-010-9433-z

Clercq, W., Vergult, A., Vanrumste, B., Paesschen, W., & Huffel, S. (2007). Canonical Correlation Analysis Applied to Remove Muscle Artifacts From the Electroencephalogram. IEEE transactions on bio-medical engineering, 53, 2583-2587. https://doi.org/10.1109/TBME.2006.879459

Coenen, A., Fine, E., & Zayachkivska, O. (2014). Adolf Beck: A forgotten pioneer in electroencephalography. Journal of the History of the Neurosciences, 23(3), 276-286. https://doi.org/10.1080/0964704X.2013.867600

Elsayed, N., & Bayoumi, M. (2017). Brain Computer Interface: EEG Signal Preprocessing Issues and Solution. International Journal of Computer Applications, 169. https://doi.org/10.5120/ijca2017914621

Fabiani, G. E., McFarland, D. J., Wolpaw, J. R., & Pfurtscheller, G. (2004). Conversion of EEG activity into cursor movement by a brain-computer interface (BCI). IEEE Transactions on Neural Systems and Rehabilitation Engineering, 12(3), 331-338. https://doi.org/10.1109/TNSRE.2004.834627

Farwell, L. A., & Donchin, E. (1988). Talking off the top of your head: Toward a mental prosthesis utilizing event-related brain potentials. Electroencephalography and Clinical Neurophysiology, 70(6), 510-523. https://doi.org/10.1016/0013-4694(88)90149-6

Fazel-Rezai, R., Allison, B. Z., Guger, C., Sellers, E. W., Kleih, S. C., & Kübler, A. (2012). P300 brain computer interface: Current challenges and emerging

trends. Frontiers in Neuroengineering, 5. https://doi.org/10.3389/fneng.2012.00014

Fernández-Caballero, A., Navarro, E., Fernández-Sotos, P., González, P., Ricarte, J. J., Latorre, J. M., & Rodriguez-Jimenez, R. (2017). Human-Avatar Symbiosis for the Treatment of Auditory Verbal Hallucinations in Schizophrenia through Virtual/Augmented Reality and Brain-Computer Interfaces. Frontiers in Neuroinformatics, 11, 64. https://doi.org/10.3389/fninf.2017.00064

Fuchs, T., Birbaumer, N., Lutzenberger, W., Gruzelier, J. H., & Kaiser, J. (2003). Neurofeedback Treatment for Attention-Deficit/Hyperactivity Disorder in Children: A Comparison with Methylphenidate. Applied Psychophysiology and Biofeedback, 28(1), 1-12. https://doi.org/10.1023/A:1022353731579

Gevensleben, H., Albrecht, B., Lütcke, H., Auer, T., Dewiputri, W. I., Schweizer, R., Moll, G., Heinrich, H., & Rothenberger, A. (2014). Neurofeedback of slow cortical potentials: Neural mechanisms and feasibility of a placebo-controlled design in healthy adults. Frontiers in Human Neuroscience, 8, 990. https://doi.org/10.3389/fnhum.2014.00990

Golub, M. D., Chase, S. M., Batista, A. P., & Yu, B. M. (2016). Brain–computer interfaces for dissecting cognitive processes underlying sensorimotor control. Current Opinion in Neurobiology, 37, 53-58. https://doi.org/10.1016/j.conb.2015.12.005

Gostilovich, S., Kotliar Shapirov, A., Znobishchev, A., Phan, A.-H., & Cichocki, A. (2023). Biomarkers of professional cybersportsmen: Event related potentials and cognitive tests study. PLOS ONE, 18(8), e0289293. https://doi.org/10.1371/journal.pone.0289293

Gotman, J. (1982). Automatic recognition of epileptic seizures in the EEG. Electroencephalography and Clinical Neurophysiology, 54(5), 530-540. https://doi.org/10.1016/0013-4694(82)90038-4

Grass, A. M. (1984). The electroencephalographic heritage until 1960. The American Journal of EEG Technology, 24(3), 133-173.

Grossberg, J. M. (1972). Brain wave feedback experiments and the concept of mental mechanisms. Journal of Behavior Therapy and Experimental Psychiatry, 3(4), 245-251. https://doi.org/10.1016/0005-7916(72)90043-2

Haas, L. F. (2003). Hans Berger (1873-1941), Richard Caton (1842-1926), and electroencephalography. Journal of Neurology, Neurosurgery, and Psychiatry, 74(1), 9. https://doi.org/10.1136/jnnp.74.1.9

Han, J., Kamber, M., & Pei, J. (2011). Data Mining: Concepts and Techniques. Elsevier.

Heinrich, S. P. (2010). Some thoughts on the interpretation of steady-state evoked potentials. Documenta Ophthalmologica, 120(3), 205-214. https://doi.org/10.1007/s10633-010-9212-7

Hjorth, B. (1970). EEG analysis based on time domain properties. Electroencephalography and Clinical Neurophysiology, 29(3), 306-310. https://doi.org/10.1016/0013-4694(70)90143-4

Holmes, G. L., & Khazipov, R. (2007). Basic Neurophysiology and the Cortical Basis of EEG. Içinde A. S. Blum & S. B. Rutkove (Ed.), The Clinical Neurophysiology Primer (ss. 19-33). Humana Press. https://doi.org/10.1007/978-1-59745-271-7_2

Horrell, T., El-Baz, A., Baruth, J., Tasman, A., Sokhadze, G., Stewart, C., & Sokhadze, E. (2010). Neurofeedback Effects on Evoked and Induced EEG Gamma Band Reactivity to Drug-related Cues in Cocaine Addiction. Journal of Neurotherapy, 14(3), 195-216. https://doi.org/10.1080/10874208.2010.501498

Hsu, J.-L., Zhen, Y.-L., Lin, T.-C., & Chiu, Y.-S. (2018). Affective content analysis of music emotion through EEG. Multimedia Systems, 24(2), 195-210. https://doi.org/10.1007/s00530-017-0542-0

Isaksson, A., Wennberg, A., & Zetterberg, L. H. (1981). Computer analysis of EEG signals with parametric models. Proceedings of the IEEE, 69(4), 451-461. Proceedings of the IEEE. https://doi.org/10.1109/PROC.1981.11988

Iturrate, I., Antelis, J., Kübler, A., & Minguez, J. (2009). A Noninvasive Brain-Actuated Wheelchair Based on a P300 Neurophysiological Protocol and Automated Navigation. Robotics, IEEE Transactions on, 25, 614-627. https://doi.org/10.1109/TRO.2009.2020347

Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 374(2065), 20150202. https://doi.org/10.1098/rsta.2015.0202

Kawala-Sterniuk, A., Podpora, M., Pelc, M., Blaszczyszyn, M., Gorzelanczyk, E. J., Martinek, R., & Ozana, S. (2020). Comparison of Smoothing Filters in Analysis of EEG Data for the Medical Diagnostics Purposes. Sensors (Basel, Switzerland), 20(3), 807. https://doi.org/10.3390/s20030807

Kit, N. K., Amin, H. U., Ng, K. H., Price, J., & Subhani, A. R. (2023). EEG Feature Extraction based on Fast Fourier Transform and Wavelet Analysis for Classification of Mental Stress Levels using Machine Learning. Advances in Science, Technology and Engineering Systems Journal, 8(6), 46-56. https://doi.org/10.25046/aj080606

Kumar, J. S., & Bhuvaneswari, P. (2012). Analysis of Electroencephalography (EEG) Signals and Its Categorization–A Study. Procedia Engineering, 38, 2525-2536. https://doi.org/10.1016/j.proeng.2012.06.298

Lawhern, V., Hairston, W. D., McDowell, K., Westerfield, M., & Robbins, K. (2012). Detection and classification of subject-generated artifacts in EEG signals using autoregressive models. Journal of Neuroscience Methods, 208(2), 181-189. https://doi.org/10.1016/j.jneumeth.2012.05.017

Leeb, R., & Pfurtscheller, G. (2004). Walking through a virtual city by thought. Conference Proceedings: ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference, 2004, 4503-4506. https://doi.org/10.1109/IEMBS.2004.1404251

Little, S., Pogosyan, A., Neal, S., Zavala, B., Zrinzo, L., Hariz, M., Foltynie, T., Limousin, P., Ashkan, K., FitzGerald, J., Green, A. L., Aziz, T. Z., & Brown, P. (2013). Adaptive deep brain stimulation in advanced Parkinson disease. Annals of Neurology, 74(3), 449-457. https://doi.org/10.1002/ana.23951

Loh, H. W., Ooi, C. P., Aydemir, E., Tuncer, T., Dogan, S., & Acharya, U. R. (2022). Decision support system for major depression detection using spectrogram and convolution neural network with EEG signals. Expert Systems, 39(3), e12773. https://doi.org/10.1111/exsy.12773

Ludwig, K. A., Miriani, R. M., Langhals, N. B., Joseph, M. D., Anderson, D. J., & Kipke, D. R. (2009). Using a Common Average Reference to Improve Cortical Neuron Recordings From Microelectrode Arrays. Journal of Neurophysiology, 101(3), 1679-1689. https://doi.org/10.1152/jn.90989.2008

Lynch, J. J., & Paskewitz, D. A. (1971). On the mechanisms of the feedback control of human brain wave activity. Journal of Nervous and Mental Disease, 153(3), 205-217. https://doi.org/10.1097/00005053-197109000-00005

Mahato, S., & Paul, S. (2019). Classification of Depression Patients and Normal Subjects Based on Electroencephalogram (EEG) Signal Using Alpha Power and Theta Asymmetry. Journal of Medical Systems, 44(1), 28. https://doi.org/10.1007/s10916-019-1486-z

Marzbani, H., Marateb, H. R., & Mansourian, M. (2016). Neurofeedback: A Comprehensive Review on System Design, Methodology and Clinical Applications. Basic and Clinical Neuroscience, 7(2), 143-158. https://doi.org/10.15412/J.BCN.03070208

Mridha, M. F., Das, S. C., Kabir, M. M., Lima, A. A., Islam, M. R., & Watanobe, Y. (2021). Brain-Computer Interface: Advancement and Challenges. Sensors, 21(17), Article 17. https://doi.org/10.3390/s21175746

Nascimento, V. H., & Silva, M. T. M. (2014). Chapter 12—Adaptive Filters. İçinde P. S. R. Diniz, J. A. K. Suykens, R. Chellappa, & S. Theodoridis (Ed.), Academic Press Library in Signal Processing (C. 1, ss. 619-761). Elsevier. https://doi.org/10.1016/B978-0-12-396502-8.00012-7

Nirenberg, L., Hanley, J., & Stear, E. (1971). A New Approach to Prosthetic Control: EEG Motor Signal Tracking With an Adaptively Designed Phase-Locked Loop. Biomedical Engineering, IEEE Transactions on, BME-18, 389-398. https://doi.org/10.1109/TBME.1971.4502880

Nobukawa, S., Yamanishi, T., Nishimura, H., Wada, Y., Kikuchi, M., & Takahashi, T. (2019). Atypical temporal-scale-specific fractal changes in Alzheimer's disease EEG and their relevance to cognitive decline. Cognitive Neurodynamics, 13(1), 1-11. https://doi.org/10.1007/s11571-018-9509-x

Ormerod, W. (2006). Richard Caton (1842-1926): Pioneer electrophysiologist and cardiologist. Journal of Medical Biography, 14(1), 30-35. https://doi.org/10.1258/j.jmb.2006.04-22

Petersén, I., & Eeg-Olofsson, O. (1971). The Development of the Electroencephalogram in Normal Children from the Age of 1 Through 15 Years – Non-paroxysmal activity. Neuropädiatrie, 2(3), 247-304. https://doi.org/10.1055/s-0028-1091786

Pfurtscheller, G., Leeb, R., Keinrath, C., Friedman, D., Neuper, C., Guger, C., & Slater, M. (2006). Walking from thought. Brain Research, 1071(1), 145-152. https://doi.org/10.1016/j.brainres.2005.11.083

Piccolino, M. (1998). Animal electricity and the birth of electrophysiology: The legacy of Luigi Galvani. Brain Research Bulletin, 46(5), 381-407. https://doi.org/10.1016/S0361-9230(98)00026-4

Poulos, M., Felekis, T., & Evangelou, A. (2012). Is it possible to extract a fingerprint for early breast cancer via EEG analysis? Medical Hypotheses, 78(6), 711-716. https://doi.org/10.1016/j.mehy.2012.02.016

Salem, O., Naseem, A., & Mehaoua, A. (2014). Epileptic seizure detection from EEG signal using Discrete Wavelet Transform and Ant Colony classifier. 2014

IEEE International Conference on Communications (ICC), 3529-3534. https://doi.org/10.1109/ICC.2014.6883868

Seeck, M., Koessler, L., Bast, T., Leijten, F., Michel, C., Baumgartner, C., He, B., & Beniczky, S. (2017). The standardized EEG electrode array of the IFCN. Clinical Neurophysiology, 128(10), 2070-2077. https://doi.org/10.1016/j.clinph.2017.06.254

Shi, X., Wang, T., Wang, L., Liu, H., & Yan, N. (2019). Hybrid Convolutional Recurrent Neural Networks Outperform CNN and RNN in Task-state EEG Detection for Parkinson's Disease. 2019 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC), 939-944. https://doi.org/10.1109/APSIPAASC47483.2019.9023190

Silverman, D. (1963). The Rationale and History of the 10-20 System of the International Federation. American Journal of EEG Technology. https://www.tandfonline.com/doi/abs/10.1080/00029238.1963.11080602

Singh, N. P., Gautam, A. K., & Sharan, T. (2022). 13—An insight into the hardware and software aspects of a BCI system with focus on ultra-low power bulk driven OTA and Gm-C based filter design, and a detailed review of the recent AI/ML techniques. İçinde V. Bajaj & G. R. Sinha (Ed.), Artificial Intelligence-Based Brain-Computer Interface (ss. 283-315). Academic Press. https://doi.org/10.1016/B978-0-323-91197-9.00015-1

Sneddon, R., Shankle, W. R., Hara, J., Rodriquez, A., Hoffman, D., & Saha, U. (2005). EEG detection of early Alzheimer's disease using psychophysical tasks. Clinical EEG and Neuroscience, 36(3), 141-150. https://doi.org/10.1177/155005940503600304

SONG, Y., & LU, Y. (2015). Decision tree methods: Applications for classification and prediction. Shanghai Archives of Psychiatry, 27(2), 130-135. https://doi.org/10.11919/j.issn.1002-0829.215044

Sterman, M. B., & Friar, L. (1972). Suppression of seizures in an epileptic following sensorimotor EEG feedback training. Electroencephalography and Clinical Neurophysiology, 33(1), 89-95. https://doi.org/10.1016/0013-4694(72)90028-4

Stone, J. L., & Hughes, J. R. (2013). Early History of Electroencephalography and Establishment of the American Clinical Neurophysiology Society. Journal of Clinical Neurophysiology, 30(1), 28-44. https://doi.org/10.1097/WNP.0b013e31827edb2d

Torres, E. P., Torres, E. A., Hernández-Álvarez, M., & Yoo, S. G. (2020). EEG-Based BCI Emotion Recognition: A Survey. Sensors, 20(18), Article 18. https://doi.org/10.3390/s20185083

Tozzo, C. A., Elfner, L. F., & May, J. G. (1988). EEG biofeedback and relaxation training in the control of epileptic seizures. International Journal of Psychophysiology, 6(3), 185-194. https://doi.org/10.1016/0167-8760(88)90004-9

Tuncer, T., Dogan, S., & Subasi, A. (2021). EEG-based driving fatigue detection using multilevel feature extraction and iterative hybrid feature selection. Biomedical Signal Processing and Control, 68, 102591. https://doi.org/10.1016/j.bspc.2021.102591

van Dokkum, L. E. H., Ward, T., & Laffont, I. (2015). Brain computer interfaces for neurorehabilitation – its current status as a rehabilitation strategy post-stroke.

Annals of Physical and Rehabilitation Medicine, 58(1), 3-8. https://doi.org/10.1016/j.rehab.2014.09.016

Vapnik, V. N. (2000). The Nature of Statistical Learning Theory. Springer. https://doi.org/10.1007/978-1-4757-3264-1

Vidyaratne, L. S., & Iftekharuddin, K. M. (2017). Real-Time Epileptic Seizure Detection Using EEG. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 25(11), 2146-2156. IEEE Transactions on Neural Systems and Rehabilitation Engineering. https://doi.org/10.1109/TNSRE.2017.2697920

Vogel, F. (1970). The genetic basis of the normal human electroencephalogram (EEG). Humangenetik, 10(2), 91-114. https://doi.org/10.1007/BF00295509

Wong, D. K. (t.y.). Multichannel classification of brain -wave representations of language by perceptron-based models and independent component analysis [Ph.D.]. Geliş tarihi 25 Mayıs 2024, gönderen https://www.proquest.com/docview/305123250/abstract/4AD12C11B5EF4EBDPQ/1

Yarğı, V., & Postalcıoğlu, S. (2021). EEG İşareti Kullanılarak Bağımlılığa Yatkınlığın Makine Öğrenmesi Teknikleri ile Analizi. El-Cezeri, 8(1), Article 1. https://doi.org/10.31202/ecjse.787726

Yu, Y., Liu, Y., Yin, E., Jiang, J., Zhou, Z., & Hu, D. (2019). An Asynchronous Hybrid Spelling Approach Based on EEG–EOG Signals for Chinese Character Input. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 27(6), 1292-1302. IEEE Transactions on Neural Systems and Rehabilitation Engineering. https://doi.org/10.1109/TNSRE.2019.2914916

Zhao, G., Ge, Y., Shen, B., Wei, X., & Wang, H. (2018). Emotion Analysis for Personality Inference from EEG Signals. IEEE Transactions on Affective Computing, 9(3), 362-371. IEEE Transactions on Affective Computing. https://doi.org/10.1109/TAFFC.2017.2786207

Kimlik Avı saldırılarının tespitinde sınıflandırma algoritmalarının performans karşılaştırılması

Fatih Kürşad GÜNDÜZ[1]

1- Öğr Grv.Fatih Kürşad GÜNDÜZ Süleyman demirel Üniversitesi Bilgi İşlem Daire Başkanlığı. emrekatmer@gmail.com ORCID No: 0000-0002-8952-6660

ÖZET

Bilgi güvenliği, günümüz dünyasında bilgisayarların hızlı gelişimiyle birlikte büyük bir öneme kavuşmuştur. Dijitalleşme ve internetin gelişmesiyle, bireylerin ve kurumların hassas bilgilerini çevrim içi ortamlarda daha sık paylaşmasına neden olmuştur. Bu durum, kötü niyetli kişilerin bu bilgileri ele geçirmek için yeni yöntemler geliştirmesine olanak sağlamıştır. Özellikle kimlik avı saldırıları (phishing), bilgi güvenliğini tehdit eden en yaygın ve zararlı saldırı türlerinden biri olarak öne çıkmaktadır.

Anahtar Kelimeler – Kimlik avı (Phishing), Siber güvenlik, Dolandırıcılık, Hesap güvenliği ve Makine Öğrenmesi

GİRİŞ

Kimlik avı saldırıları, genel olarak kullanıcıları kandırmaya yönelik tasarlanmış sahte e-postalar, web siteleri veya mesajlarla yapılmaktadır. Bu metodlarla saldırganlar, son kullanıcıların kişisel bilgilerini örneğin şifrelerini, kredi kartı bilgilerini veya banka hesap bilgilerini ele geçirilebilmektedir. Bu saldırılar çok düzeyde ciddi maddi kayıplara ve itibar zararlarına yol açmaktadır. Son yıllarda, kimlik avı saldırılarının sıklığında ve karmaşıklığında kayda değer bir artış gözlenmiştir. IBM raporlarına göre, kimlik avı saldırılarının 2016 yılında bir önceki yıla kıyasla %450 oranında arttığı belirtilmiştir.

Kimlik avı saldırıları sadece bireylerin değil, aynı zamanda şirketlerin ve hatta ulusal güvenliğin de tehlikeye girmesiyle sonuçlanabilir. Örneğin, bir çalışanın kimlik bilgilerinin çalınması, şirket ağlarına izinsiz erişimine neden olarak daha büyük çaplı veri ihlalleri ortaya çıkabilir. Bunun sonucunda şirketler hem mali kayıplara uğrar hem de müşterilerinin güvenini kaybedebilir. Dolayısıyla, bilgi güvenliği stratejilerinin önemli bir bileşeni olarak kimlik avı saldırılarının tespiti ve önlenmesi önemli bir konudur. Bu konuda farkındalık oluşturmak ve etkili savunma mekanizmaları geliştirmek, bireylerin ve kurumların bu tür tehditlere karşı kendilerini korumasında büyük bir rol oynamaktadır.

Kimlik avı (Phishing), son kullanıcıları sahte web uygulamalarıyla kandırarak son kullanıcıların özel bilgilerini çalmaya çalışmaktır. Bu web uygulamaları kötü niyetli birtakım kişiler tarafından herhangi bir web sayfasının kopyası olarak hazırlanmaktadır. Bu web sayfaları orijinaline çok benzemekte ve teknik hileler ve sosyal mühendislikte kimlik bilgilerini başarılı bir şekilde çalabilmektedir. Örneğin, bu tür sahte web sayfaları, orijinal sitenin alan adına çok benzeyen alan adlarıyla kaydedilir. Ayrıca,

görsel tasarımı, logoları ve hatta sayfanın işlevselliğini birebir kopyalayarak kullanıcıları yanıltmayı hedefler.

Bu sayfalarda, özellikle SSL sertifikası gibi güvenlik önlemlerine dikkat edilmediği durumlarda, güvenli görünecek şekilde yeşil kilit simgesi veya diğer güven unsurları taklit edilebilir[3]. Sahte e-posta adresleri, SMS'ler veya sosyal medya mesajları kullanılarak kullanıcılar bu sahte sayfalara yönlendirilirler ve kimlik avı saldırısı başarıyla gerçekleştirilir [4]. Bunun yanı sıra, kötü niyetli kişiler, kurbanları acele etmeye zorlayan veya bir tür tehdit içeren mesajlarla paniğe sürükler, bu da kullanıcıların daha az dikkatli davranmasına neden olur.

Kimlik avı saldırıları, genellikle güvenilir bir kaynaktan geliyormuş izlenimi veren e-postalar aracılığıyla yapılır. Bu tür saldırılarda saldırganlar, sahte bir e-posta adresi veya güvenilir bir kurumun adını kullanıp son kullanıcıların hassas bilgilerini ele geçirmeyi açalar. Ancak kimlik avı yalnızca e-postalarla sınırlı kalmaz; dosya paylaşım platformları, çevrim içi forumlar, bloglar ve hatta sosyal medya gibi dijital ortamlar da bu tür saldırılar için uygun zemin sağlar. Örneğin, bir saldırgan, popüler bir dosya paylaşım sitesinde kötü amaçlı bir bağlantı yerleştirebilir ya da bir blog gönderisinde sahte bir ödül kazanma bağlantısıyla kullanıcıları aldatabilir. Bu tür saldırılar, kullanıcıların dijital platformlardaki güvenlik açıklarını hedef alarak dolandırıcılık faaliyetlerini kolaylaştırır. Bu durum, kimlik avı saldırılarına karşı mücadele yöntemlerinin geliştirilmesi gerekliliğini ortaya koymuştur.

Bilgisayar teknolojilerinde mevcut ağ sistemleri, farklı amaçlara sahip saldırı mekanizmalarına açık durumdadır. Örneğin, ağ trafiğini analiz ederek bilgi sızdırmaya çalışan saldırganlar, genellikle sistem açıklarından yararlanır. Ancak, gerekli önlemler alındığında bu saldırılar tespit edilir ve etkisizleştirilir. Yapay zeka, bu tür saldırıların tespit edilmesinde ve önlenmesinde önemli bir yardımcıdır. Özellikle anormal veri davranışlarını belirleme ve ortaya çıkabilecek tehditleri öngörme yeteneği, yapay zeka tabanlı sistemlerin bilgi güvenliğinde ön plana çıkmasını sağlamaktadır. Örneğin, ağ üzerinde anormal bir bağlantı etkinliği algılandığında, yapay zeka algoritmaları bu durumu analiz edebilir ve ilgili birimleri uyarabilir. Yapay zeka destekli akıllı sistemler, bilgi güvenliği sağlamak için etkili yöntemler sunmaktadır. Bu sistemler, sadece mevcut tehditlere karşı koruma sağlamakla kalmaz, aynı zamanda yeni tehdit türlerini tespit edip bir savunma mekanizması oluşturur.

Günümüzde bu tür akıllı uygulamalar, bilgi güvenliği alanında popüler bir konu haline gelmiştir. Gelecekte de bu popülaritesini artırması beklenmektedir. Bilgisayar teknolojilerinde var olan ağ sistemlerine farklı

amaçlara sahip saldırı metotları bulunur. Bu saldırılar gerekli önlemler alındığında tespit edilebilir. Yapay zekâ bu önlemlerin alınmasını sağlayabilmekte ve bilgi güvenliğindeki önemini günden güne artırmaktadır. Akıllı sistemler bilgi güvenliğini artırmak için bir takım özel yöntemler kullanmaktadır.

Makine öğrenmesi, veri sınıflandırma gibi işlemlerde oldukça işlevli bir araçtır. Sınıflandırma, bir veri kümesindeki verilerin birtakım kurallara göre gruplanmasını sağlar. Bu, bir verinin hangi sınıfa ait olduğunu belirlemek için kullanılan bir işlemdir. Örnek, kimlik avı yapan bir web sitesini meşru bir web sitesinden ayırt etmek, sınıflandırma algoritmalarının bir uygulamasıdır. Bu algoritmalar, geçmiş veri setlerinden öğrenerek yeni verileri değerlendirme yeteneğine sahiptir. Özellikle bilgi güvenliği gibi alanlarda, sınıflandırma algoritmalarının kullanımı için oldukça uygundur. Yapay sinir ağları, destek vektör makineleri (SVM), karar ağaçları ve rastgele ormanlar gibi algoritmalar, kimlik avı tespiti gibi görevlerde literatürde oldukça sık biçimde kullanılmaktadır.

Kimlik avı saldırılarını tespit etmek için yapılan bir çalışmada, Sklearn kütüphanesinde bulunan çeşitli sınıflandırma algoritmaları kullanılarak, kimlik avı yapan web sitelerinin tespiti sağlanmıştır. Çalışmada, algoritmaların performansını değerlendirmek ve karşılaştırmak amacıyla, WEKA, Rapidminer ve Orange gibi veri madenciliği araçları da kullanılmıştır. Bu araçlar, verilerin görselleştirilmesi ve analiz edilmesi açısından güçlü özellikler sunmaktadır. Çalışmada kullanılan dört sınıflandırma algoritması, kimlik avı tespiti açısından farklı sonuçlar ortaya koymuş ve algoritmaların hassasiyet, doğruluk, geri çağırma ve F1 skoru gibi metrikler üzerinden karşılaştırmaları yapılmıştır. Bu tür karşılaştırmalar, hangi algoritmanın belirli bir veri kümesi üzerinde daha iyi performans gösterdiğini belirlemek açısından önemlidir. Çalışmanın sonuçları, sadece kimlik avı tespiti için değil, aynı zamanda gelecekte bu tür tehditlerle mücadelede kullanılabilecek algoritmaların seçimi için de yol gösterici olmuştur [9].

2. Kimlik Avı Saldırısı

Kimlik avı saldırıları çeşitli teknikler halinde sınıflandırılabilir. Mızrak kimlik avı, seçilen kullanıcılara gönderilen ve kişinin veya bir organizasyonun bilgilerini çalmaya yönelik zararlı bir yöntemdir . Kopya kimlik avı yöntemi ise önceden gönderilen illegal postanın zararlı bir kopyasını kullanarak zarar vermeye çalışır . Malware tabanlı kimlik avı ise e-posta ile indirilebilen bir dosyadan oluşmaktadır. Bu dosyalar, keylogger ve screenlogger gibi saldırıyı yapan kişiye bilgileri aktaran yazılımlardır.

Bunu kullanarak en çok kullanılan siteyi değiştirerek zararlı siteye yönlenmesini sağlayabilirler. Arama motorlarında kullanılan kimlik avı saldırılarından kullanıcı zararlı sitelerin listelendiği bir arama motoruna girerek kişisel bilgilerini çaldırabilmektedir. Kimlik avı saldırısı son yıllarda çok artış gösteren bir saldırı biçimdir.

3.Sınıflandırma Algoritmaları

3.1.Naives-Bayes(NB)

Naive Bayes, olasılıksal bir makine öğrenmesi algoritmasıdır ve Bayes teoremine dayanır. Bu algoritma, bir veri örneğinin belirli bir sınıfa ait olma olasılığını hesaplamak için kullanılır. "Naive" terimi, algoritmanın özellikler arasında bağımsızlık varsayımında bulunmasından gelir. Bu varsayım, gerçek dünyadaki uygulamalarda genellikle tam olarak geçerli olmasa da, Naive Bayes'in hızlı, etkili ve çoğu durumda oldukça doğru sonuçlar vermesini sağlar. Naive Bayes, özellikle metin sınıflandırma, spam tespiti, duygu analizi ve kimlik avı tespiti gibi uygulamalarda sıklıkla kullanılır.
Kimlik avı saldırılarının tespitinde Naive Bayes algoritması, web sitelerinin veya e-postaların özelliklerini analiz ederek bunların meşru mu yoksa kötü niyetli mi olduğunu belirlemek için kullanılabilir. Örneğin:

3.1.2 Web Sitesi Tespiti

URL uzunluğu, alan adı yaşı, HTTPS kullanım durumu gibi özellikler kullanılarak bir web sitesinin kimlik avı saldırısı içerip içermediği belirlenebilir. Naive Bayes, bu özelliklerin olasılık dağılımlarını öğrenerek web sitelerini sınıflandırabilir.

3.1.3 E-posta Analizi

E-posta metinlerinde kullanılan kelime frekansları (örneğin "ödül", "hesap kilitlendi", "tıklayın"), bağlantıların sayısı veya e-posta başlığındaki anormallikler gibi özellikler analiz edilebilir. Naive Bayes, bu özelliklere dayanarak spam ve kimlik avı e-postalarını meşru e-postalardan ayırabilir .

3.2. Karar-Ağaçları

Karar ağacı öğrenme algoritması, sınıflandırma ve tahmin için sıkça kullanılan bir algoritmadır. Karar ağaçları kolay yorumu ve anlaşılabilirliği açısından sınıflandırma için oldukça uygundur. Karar ağaçları tekniğini kullanarak verinin sınıflandırması, öğrenme ve sınıflandırma olmak üzere 2 adımdan oluşur. Öğrenme basamağında önceden eğitim verisi modelleme yapmak için algoritma tarafından analiz edilir. Sınıflandırılacak veriler için

kurallar oluşturulur. Sınıflandırma verisinde, sınıflandırma için oluşturulan kurallarla sınıflandırma yapılır .
Karar ağaçları, bir ağacın dalları gibi, kök düğümden başlayarak veriyi dallara ayırır ve nihayetinde bir yaprak düğümde (sonuç) bir sınıf ya da değer tahmin eder. Her bir düğüm, veriyi bir özelliğe göre bölmek için bir koşul belirler. Karar ağaçları, basit ve anlaşılabilir yapısıyla, kimlik avı tespiti gibi bilgi güvenliği uygulamalarında etkili bir araçtır. Özellikle, özelliklerin görselleştirilmesi ve karar sürecinin açıklanabilir olması, bu yöntemi tercih edilir kılmaktadır. Ancak, aşırı uydurma gibi sınırlamalar göz önünde bulundurularak, karar ağaçları genellikle daha gelişmiş modellerle (rastgele ormanlar veya gradyan artırma gibi) desteklenir. Gelecekte, karar ağaçlarının daha karmaşık siber tehditleri tespit etmek için yeni özelliklerle zenginleştirilmesi beklenmektedir .

3.3. K-Neighbours(K-NN)

K-Nearest Neighbors (K-NN), denetimli öğrenme kategorisinde yer alan, hem sınıflandırma hem de regresyon problemleri için kullanılan basit ama etkili bir makine öğrenmesi algoritmasıdır. Bu yöntem, bir veri noktasını, en yakın K komşusunun özelliklerine göre sınıflandırmayı veya tahmin etmeyi hedefler. K-NN algoritması, temelde verinin geometrik yapısını kullanarak tahmin yapar ve öğrenme süreci sırasında modelin eğitilmesi yerine, tüm veri setinin bellekte saklanmasını gerektirir.

K-NN algoritması, basitliği ve sezgisel yapısı nedeniyle kimlik avı tespiti gibi bilgi güvenliği uygulamalarında kullanılabilir. Özellikle küçük veri kümelerinde etkili sonuçlar sunan K-NN, gerçek zamanlı analiz gerektiren durumlarda dikkatle kullanılmalıdır. Gelecekte, K-NN algoritmasının bellek ve hız sorunlarını aşmak için optimize edilmiş versiyonlarının geliştirilmesi, bu yöntemin daha geniş ölçekte kullanımını mümkün kılabilir. Ayrıca, hibrit yaklaşımlar (örneğin, K-NN ve yapay sinir ağları kombinasyonu) bu algoritmanın gücünü artırabilir .

3.4. Yapay Sinir Ağları(MLP)

Yapay sinir ağları, insanların beyin fonksiyonundan esinlenen yapay sinir ağları (YSA), deneme yoluyla öğrenme yapabilmektedir. YSA, veriler arasındaki bilinmeyen ve fark edilmesi güç ilişkileri ortaya çıkarabilmektedir. YSA, problemle çözümün doğrusal olmadığı problemler için ideal bir algoritmadır. Ancak problemle çözüm arasında doğrusal bir ilişki yoksa doğrusal olmayan modeller uygun değildir
YSA, girdi ile çıktı arasında herhangi bir ilişkiye ihtiyaç duymaz. Herhangi bir varsayıma gerek duymadan modellemeyi sağlarlar. Sisteme ilk önce girdi ve çıktı bilgileri verilmekte, bunların arasındaki ilişki öğrenilmekte ve ağın

eğitimi gerçekleştirilmektedir. Öğreticili öğrenme olan bu model genelde tercih edilmektedir .

4.Değerlendirme Ölçütleri

Çalışmada kullanılan sınıflandırma algoritmaları isabet (accuracy), keskinlik (precision) ve Hassasiyet(Recall) ölçütlerine göre değerlendirilecektir. F-1 Score: kavramı veri bilimlerinde performans ölçütü olarak kullanılmaktadır.

İsabet:doğru tahmin edilen verilen tüm verilere oranıdır.
Keskinlik: Tahmin yapılan durumların doğru olanların oranı
Hassasiyet: Doğru tahminleri bulma oranı
F-1 Score: Keskinlik ve hassasiyet değerlerinin harmonik ortalamasıdır[15].

5.Materyal Metot

Sklearn Kütüphanesi python destekli, geniş ölçekli makine öğrenmesi algoritmaları orta ölçekli danışmanlı ve danışmansız olarak tüm problemlerde kullanılabilmektedir. Kütüphane makine öğrenmesini uzmanı olmayanlar için genel amaçlı bir kullanım sunmaktadır. Sonuçlar İsabet, hassasiyet Keskinlik ve F-1 Score bakımından değerlendirilmiştir.Kullanılan yazılımlar ve kütüphanelerden elde edilen isabet perfomansı tablo 1' de listelenmiştir.

Tablo 1: İsabet Oranı 50 adet çalıştırma ortalaması Karşılaştırma tablosu

İsabet oranı	Sklearn	Weka	RapidMiner	Orange
YSA	0.82	0.86	0.85	0.71
KNN	0.89	0.86	0.89	0.75
KA	0.88	0.88	0.78	0.78
NB	0.81	0.85	0.78	0.74

Çalışma örnek sayısı 2456 kimlik avı saldırısı üzerinde deney yapılmıştır. Sınıflandırma algoritmaları sırasıyla Naive-bayes, Karar ağaçları, Yapay sinir ağları ve K-NN algoritmaları kullanılmıştır. Cross validation (çapraz doğrulama) genel değer olarak 10 alınmıştır. Algoritmaları kıyaslanması amacıyla Keskinlik, Hassasiyet, F-ölçütü ve İsabetlilik değerleri kullanılmıştır. Tablo 3'te algoritmalardan elde edilen isabetlilik oranları sunulmuştur. Buna göre Weka programındaki K-NN ve Yapay Sinir Ağları algoritmaları isabetlilik açısından başarılı olmuştur.

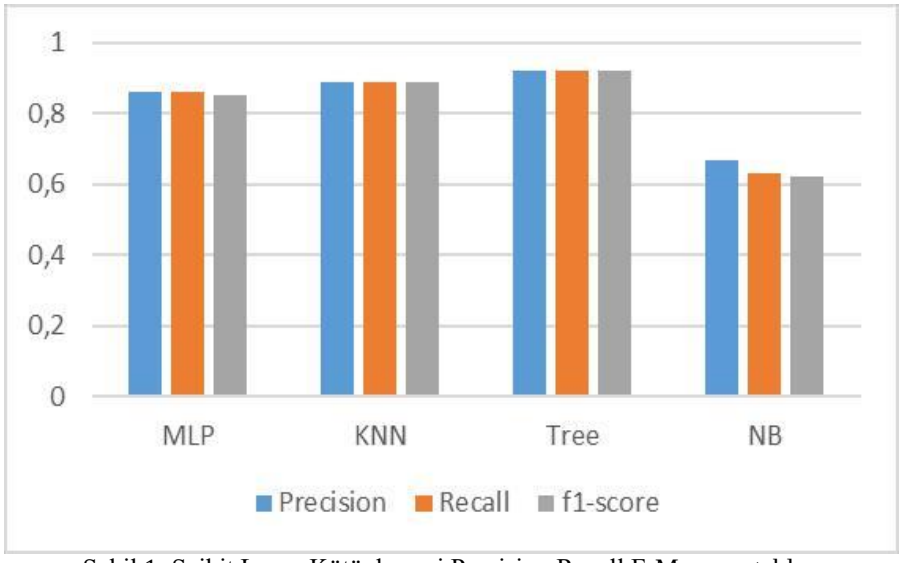

Şekil 1: Scikit Learn Kütüphanesi Precision Recall F-Measure tablosu

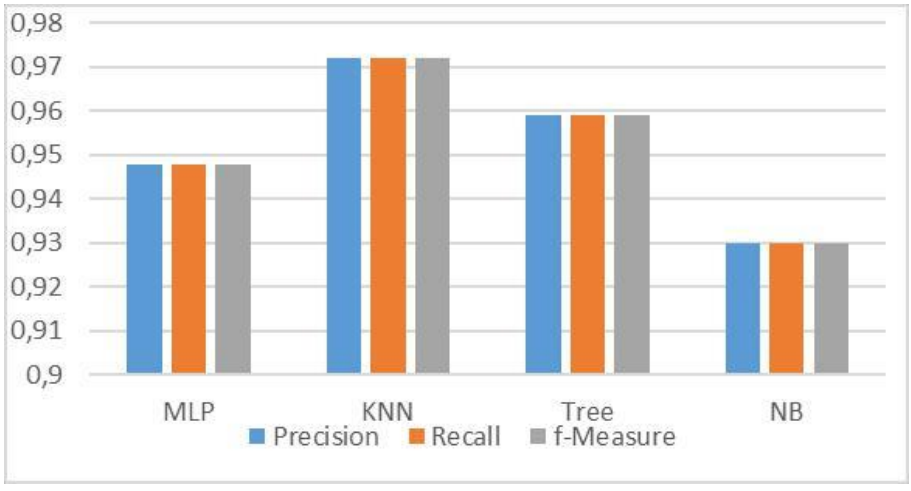

Şekil 2: WEKA Precision Recall F-Measure tablosu

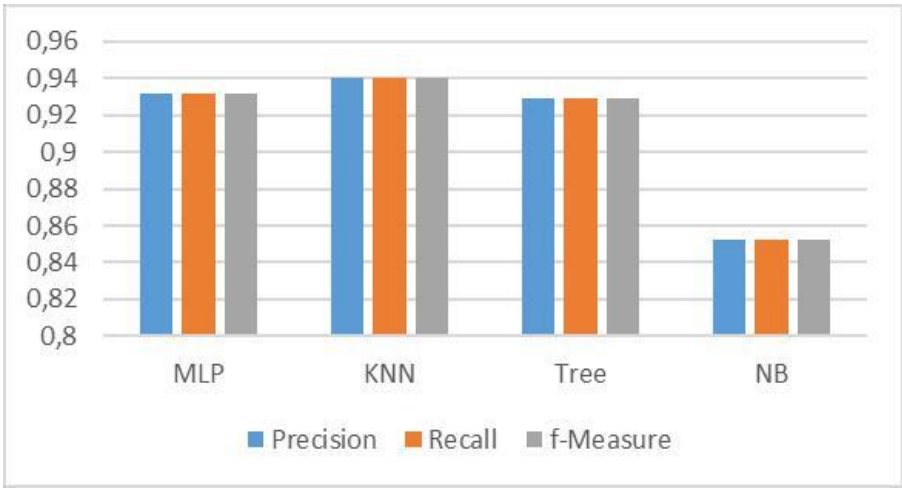

Şekil 3. Rapidminer Precision Recall F-Measure tablosu

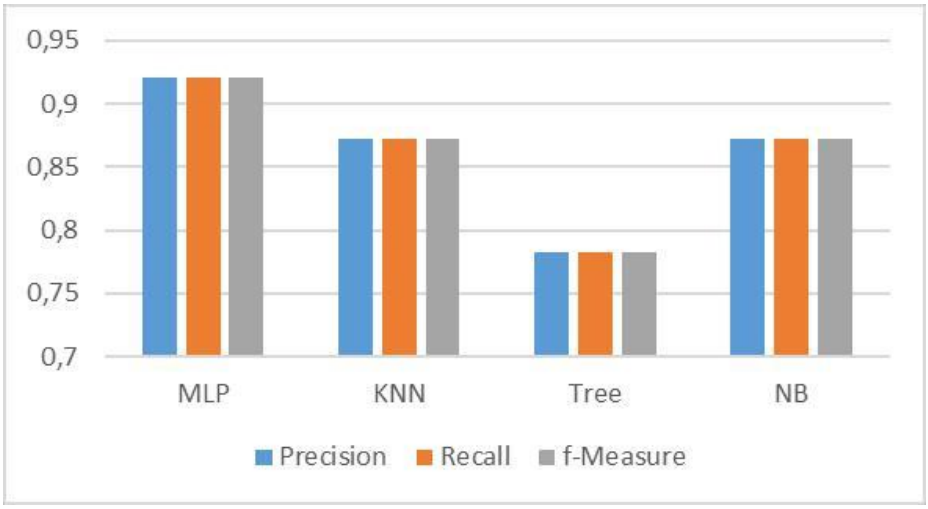

Şekil 4: Orange Precision Recall F-Measure tablosu

Python Sklearn kütüphanesi ile yapılan deneylerin keskinlik, hassasiyet ve f-ölçüm açışından karşılaştırılmıştır. Sklearn kütüphanesinde yapılan bu deneyde Karar Ağaçları(Tree) algoritması diğer algoritmalara göre başarılı olmuştur. Tablo 5' te Java ile yazılan weka programı ile yapılan deneylerin sonuçları karşılaştırılmıştır. Yapılan bu deneyde K-Neighbours(K-NN) ile yapılan deneyler performans bakımından diğerlerine göre ön plana çıkmıştır. Tablo 6'da yine Rapidminer ile yapılan deneylerin sonuçları yansıtılmıştır. Bu deneyde K-Neighbours(K-NN), Yapay Sinir Ağları(MLP) ve Karar-Ağaçları(Decision Tree) diğerlerine göre daha iyi performans sağlamıştır.

Tablo 7'de Orange ile yapılan deneylerde Yapay Sinir Ağları(MLP) performans bakımında ön plana çıkmıştır.

Sonuçlar

Çalışmada yapılan deneylerde Sklearn Kütüphanesi, Weka, Rapidminer ve Orange uygulaması kullanılarak hangi algoritmaların ve hangi yazılım dillerinin daha isabetli olduğu tartışılmıştır. Çalışmada yapılan belirlenen 4 algoritma 4 programda 2458 kimlik avı örneğinde deneyler yapılmıştır. Bu deneyler sonucunda Naives bayes(NB) algoritması diğerlerine göre düşük performans gösterdiği saptanmıştır. Çünkü kullanılabilmesi için sisteme daha fazla öğretilmiş veri sokulmalıdır. Böylelikle sınıflandırma yapması dahada kolaylaşmaktadır. Deneylerde K-Neighbours(K-NN), Yapay Sinir Ağları(MLP) diğerlerine göre daha iyi performans gösterdiği gözlemlenmiştir. Bunun yanında Python ve Javanın veri madenciliği konusunda iyi performans gösterdikleri gözlenmiştir. Sonuç olarak yapılan bu çalışmada algoritma karşılaştırılmasının yanında programlama dillerininde karşılaştırılması incelenen diğer çalışmalarda tespit edilmemiştir. Bu açıdan literatüre bir katkı sağlayacağı düşünülmüştür.

KAYNAKÇA

Aburrous, M. A., Hossain, M. A., Dahal, K., & Thabtah, F. (2010). Intelligent phishing website detection using random forest algorithm. International Journal of Network Security & Its Applications, 2(4), 1–13.

Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. IEEE Transactions on Information Theory, 13(1), 21–27.

Davis, J., & Goadrich, M. (2006). The relationship between precision-recall and ROC curves. Proceedings of the 23rd International Conference on Machine Learning (ICML), 233–240.

Haykin, S. (1999). Neural Networks: A Comprehensive Foundation (2nd ed.). Prentice Hall.

Hong, J. (2012). The state of phishing attacks. Communications of the ACM, 55(1), 74–81.

IBM. (n.d.). Cost of a data breach report: Threat intelligence. [Online]. Available: https://www.ibm.com/security/data-breach/threat-intelligence [Accessed: Dec. 19, 2024].

Jakobsson, M., & Myers, S. (2007). Phishing and Countermeasures: Understanding the Increasing Problem of Electronic Identity Theft. Hoboken, NJ: Wiley-Interscience.

Konradt, C., Schilling, A., & Werners, B. (2016). Phishing: An economic analysis of cybercrime perpetrators. Computers & Security, 58, 39–46.

Patil, T., Patil, M., & Mane, R. (2017). Phishing website detection using classification techniques: A comparative study. International Journal of Advanced Research in Computer Science, 8(2), 146–153.

Quinlan, J. R. (1986). Induction of decision trees. Machine Learning, 1(1), 81–106.

Somwanshi, I., Ghorpade, P., & Ingle, R. (2020). Artificial intelligence in network security: Techniques, applications, and future directions. Journal of Network and Computer Applications, 170, 102779.

Vishwanath, A., Herath, T., Chen, R., Wang, J., & Rao, H. R. (2011). Why do people get phished? Testing individual differences in phishing vulnerability within an integrated, information processing model. Decision Support Systems, 51(3), 576–586.

Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. International Journal of Forecasting, 14, 35–62.

Aburrous, M. A., Hossain, M. A., Dahal, K., & Thabtah, F. (2010). Intelligent phishing website detection using random forest algorithm. International Journal of Network Security & Its Applications, 2(4), 1–13.

Aleroud, A., & Zhou, L. (2017). Phishing environments, techniques, and countermeasures: A survey. Computers & Security, 68, 160–196.

Basnet, R., Mukkamala, S., & Sung, A. H. (2012). Detection of phishing attacks: A machine learning approach. Studies in Fuzziness and Soft Computing, 296, 373–383.

Bergholz, A., De Beer, J., Glahn, S., Moens, M. F., Paaß, G., & Strobel, S. (2010). New filtering approaches for phishing email. Journal of Computer Security, 18(1), 7–35.

Fette, I., Sadeh, N., & Tomasic, A. (2007). Learning to detect phishing emails. Proceedings of the 16th International Conference on World Wide Web, 649–656.

Garera, S., Provos, N., Chew, M., & Rubin, A. D. (2007). A framework for detection and measurement of phishing attacks. Proceedings of the 2007 ACM Workshop on Recurring Malcode, 1–8.

Miyamoto, D., Hazeyama, H., & Kadobayashi, Y. (2008). An evaluation of machine learning-based methods for detection of phishing sites. Proceedings of the 15th International Conference on Neural Information Processing: Part II, 539–546.

Mohammad, R. M., Thabtah, F., & McCluskey, L. (2014). Predicting phishing websites based on self-structuring neural network. Neural Computing and Applications, 25(2), 443–458.

Whittaker, C., Ryner, B., & Nazif, M. (2010). Large-scale automatic classification of phishing pages. Proceedings of the Network and Distributed System Security Symposium.

Zhang, Y., Hong, J. I., & Cranor, L. F. (2007). Cantina: A content-based approach to detecting phishing web sites. Proceedings of the 16th International Conference on World Wide Web, 639–648.

Tıbbi Veri Analizinde Derin Öğrenme

Hasan AYDOĞAN [1]

Gül Fatma TÜRKER[2]

1- Süleyman Demirel Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Bilgisayar Mühendisliği Yl2330138015@ogr.sdu.edu.tr ORCID No: 0009-0005-8891-7095
2- Dr.Öğr.Üyesi; Süleyman Demirel Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Bilgisayar Mühendisliği gulturker@sdu.edu.tr ORCID No: 0000-0001-5714-5102

ÖZET

Son yıllarda elektronik sağlık sistemlerinin yaygınlaşması, sağlık teknolojisi alanında önemli gelişmeler sağlamış ve tıbbi verilerin kaydedilmesi ve analiz edilmesini kolaylaştırmıştır. Bu bağlamda, yapay zekâ ve derin öğrenme, hastalıkların teşhis ve tedavisinde devrim yaratmaktadır. Derin öğrenme, radyolojik görüntülerden genetik verilere kadar farklı veri türlerini analiz ederek, insan beyninin karar mekanizmasını taklit eden yapısıyla sağlık uzmanlarına büyük kolaylıklar sağlamaktadır.

Makine öğrenmesi (ML), denetimli ve denetimsiz öğrenme yöntemleriyle büyük veri setlerini analiz ederek doğru tahminler ve kararlar üretebilir. Sağlık alanında ML, özellikle enfeksiyon hastalıkları, ilaç geliştirme ve tıbbi görüntü analizi gibi uygulamalarda yaygın olarak kullanılmaktadır.

Derin öğrenme teknolojileri, bilgisayar destekli tanı (CAD) sistemlerinde yaygın olarak kullanılmakta ve hastalıkların sınıflandırılması ile tedavi planlamasında önemli bir rol oynamaktadır. Derin öğrenme, sağlık sektöründe teşhis doğruluğunu artırma, tedavi süreçlerini hızlandırma ve maliyetleri düşürme potansiyeline sahiptir. Ancak veri mahremiyeti, yüksek hesaplama gereksinimleri ve model şeffaflığı bu teknolojinin uygulanmasında çözülmesi gereken temel zorluklardır.

Bu çalışma, yapay zekanın bir alt uzantısı olan derin öğrenme tekniklerini ayrıntılı bir şekilde incelemektedir. Sağlık alanında kullanılan derin öğrenme yöntemleri arasında, görsel veri analizi için evrişimli sinir ağları (CNN), sıralı verileri işlemek için tekrarlayan sinir ağları (RNN), karar süreçlerinde etkinlik sağlayan derin inanç ağları (DBN) ve veri optimizasyonu için derin sinir ağları (DNN) yer almaktadır.

Anahtar Kelimeler – Bilgisayar Destekli Tanı, Derin Öğrenme, Kişiselleştirilmiş Tıp, Makine Öğrenmesi, Sağlık Teknolojisi

1.GİRİŞ

Son yıllarda elektronik sağlık sistemlerinin yaygınlaşmasıyla birlikte sağlık teknolojisi alanında yeni teşhis ve tedavi yöntemleri geliştirilmiştir. Elektronik sağlık sistemlerinin kullanılması, radyolojik görüntüler ve laboratuvar test sonuçları gibi tıbbi verilerin kaydedilmesini kolaylaştırmıştır. Yapılan araştırmalar, makine öğrenmesinin hastalıkların erken teşhisinde yaygın bir yöntem olduğunu göstermektedir (Norgeot vd., 2019: 14-15). Bilgisayarlar, insan yaşamını kolaylaştırırken, insan benzeri düşünme yeteneği geliştirme çabaları makine öğrenmesinin ilerlemesine katkı sağlamıştır. Bu süre, insan zekasını taklit eden yapay zekâ olarak

adlandırılmaktadır. Yapay zekanın sağlık hizmetleriyle birleştirilmesi tıbbi teşhis alanında önemli gelişmelere yol açmıştır (Ravi vd., 2017: 4-21).

Derin öğrenme, birçok tıbbi görüntüyü benzer özelliklerine göre gruplandırarak katmanları aracılığıyla hastalıkları tespit eder. Sağlık alanında kullanılan Derin öğrenme teknolojileri, araştırmacılar ve tıp uzmanları için tıbbi verilerin analizini kolaylaştırarak hastalıkların tedavisinde önemli bir rol oynar. Bu süreç, insan beyninin karar mekanizmasını taklit eder. Günümüzde Derin öğrenme modelleri, bilgisayar destekli tanı (CAD) sistemlerinde hastalıkların sınıflandırılmasında ve teşhis ile tedavi süreçlerinin planlanmasında kullanılmaktadır (Fakoor vd., 2013:1-7).

Genetik verilerdeki desenleri ve eğilimleri analiz etmek için Derin öğrenme teknikleri kullanılarak, insanları etkileyebilecek hastalıklar belirlenebilir. DNA üzerindeki mutasyonların hastalıklara nasıl yol açtığı, genetik analizler sayesinde ortaya konabilir. Derin öğrenme, genetik yapıya dayalı kişiye özel tedavi yöntemlerinin geliştirilmesine yardımcı olmaktadır (Domingos, 2012: 78-87).

Sağlık alanında Derin öğrenme, yeni ilaçların keşfedilmesini destekler. Bu teknoloji, ilaç kullanan hastaların verileri inceleyerek ilaçların yan etkilerini belirleyebilir. Bunun yanı sıra ilaçların kullanım dozları ve diğer önemli detaylar hakkında veriler elde edebilir (Gawehn vd., 2016: 3-14).

Bugüne kadar sağlık bilişimi alanındaki birçok deneysel çalışma, Derin öğrenme modellerinin başarılı bir şekilde uygulanmasını sağlamış ve genellikle alternatif yöntemlerle benzer performans gösterirken, çoğu durumda bu yöntemleri geride bırakmayı başarmıştır. Ancak derin öğrenmenin sağlık bilişimindeki uygulamaları bazı zorlukları da beraberinde getirmektedir. Bu teknolojinin etkili olabilmesi için büyük miktarda veriye ihtiyaç duyulurken, sağlık sektöründe bu verilerin temini oldukça zordur. Ayrıca bu süreç büyük hesaplama kaynakları gerektirir; bu kaynaklar eksik olduğunda eğitim süreci zaman alıcı ve zahmetli hale gelebilir. Derin öğrenme modelleri, yakınsama sorunları veya aşırı öğrenme gibi zorluklarla karşılaşabileceği için, bu sorunları çözmek adına ek öğrenme stratejilerinin geliştirilmesi önemlidir (Malik vd., 2020: 469-468).

1.1.Sağlık Alanında Derin Öğrenme Uygulamaları

Sinir sistemi hastalıklarının teşhisinde biyomedikal sinirbilim alanında hesaplamalı yöntemler kullanılmaktadır. Bu yöntemler, hastaların verilerini daha doğru ve hızlı analiz ederek doktorların tedavi süreçlerini şekillendirmelerine yardımcı olur. Alzheimer ve beyin tümörleri gibi nörolojik hastalıkların tanısında derin sinir ağları (DNN), anormallikleri tespit etmek için etkili bir şekilde kullanılmaktadır (Chin vd., 2017: 368-372). Yapay zekanın ilerlemesiyle birlikte, bulanık mantık algoritmaları nörolojik hastalıkların teşhisinde kullanılmaya başlanmıştır. Ancak bu algoritmalar tamamen otomatik değildir, bu yüzden rastgele orman yöntemleri önerilmiştir. Yine de bu yöntemler de bazı mühendislik tekniklerine ihtiyaç duyduğundan, CNN modelleri bu tür hastalıkların teşhisinde daha yaygın olarak kullanılmaktadır. CNN modelleri, beyin lezyonlarını tanıyarak felç gibi hastalıkları tespit edebilme yeteneğine sahiptir (Rahman vd., 2021: 1-23).

Beyin dokusundaki hücrelerin anormal şekilde çoğalarak kitle oluşturması, beyin tümörü olarak tanımlanır. Bu tür hastalıkların tedavisinde, doğru teşhis için beyin lezyonlarının dikkatlice tanımlanması önemlidir ve bu da hassas bir inceleme gerektirir. Geçmişte beyin lezyonlarını teşhis etmek için EEG gibi geleneksel makine öğrenimi yöntemleri kullanılıyordu. Ancak transfer öğrenme yaklaşımları sayesinde lezyonların tespiti ve tanımlanması için daha etkili derin öğrenme modelleri kullanılmaya başlanmıştır (Taricciotti vd., 2022: 1-9).

Kronik obstrüktif akciğer hastalığı (KOAH), bronşların daralmasıyla akciğerlerin elastikiyetini kaybetmesine yol açan bir hastalıktır. Bu hastalık, nefes darlığı ve balgam üretimi gibi spesifik olmayan semptomlarla teşhis edilir. KOAH'ın tanısı için yapay sinir ağları, özellikle de Feed-Forward Sinir Ağları (FFNN) kullanılmaktadır. FFNN modeli, küçük veri setleriyle bile hastaların sağlık durumunu yüksek doğrulukla tahmin edebilmektedir. Bu model, doktorlara hasta bakımını iyileştirme ve karar verme süreçlerinde önemli destek sağlar (Nunavath vd., 2018: 217-228).

2.SAĞLIK ALANINDA MAKİNE ÖĞRENİMİ: VERİ İŞLEME ve YORUMLAMA

Makine öğrenimi (ML), bilgisayarların verilerden öğrenerek karmaşık görevleri otomatikleştirmesine olanak sağlayan bir yapay zekâ türüdür. Bu sistemler, doğrudan programlanma yerine, deneyimlerden öğrenip performanslarını iyileştirecek şekilde tasarlanır. ML algoritmaları, büyük veri kümelerini analiz ederek doğru tahminler ve kararlar üretmek

için eğitilir. Bu süreçte kullanılan veri miktarı arttıkça algoritmaların doğruluğu ve etkinliği de artmaktadır (Jordan ve Mitchell, 2015:255-260).

ML, denetimli, denetimsiz, yarı denetimli ve pekiştirmeli olmak üzere dört temel kategoriye ayrılır. Bu yöntemler arasında en yaygın kullanılanı denetimli öğrenmedir. Denetimli öğrenmede, etiketlenmiş veri setleri kullanılarak model eğitilir ve genellikle sınıflandırma, tahminleme ve regresyon gibi işlemlerde uygulanır. Denetimsiz öğrenmede ise model, etiketsiz veriler üzerinden eğitilir. Bu tür algoritmalar, veriler arasındaki ilişkileri analiz ederek sonuç üretir. Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenme tekniklerini birleştirir. Etiketli ve etiketsiz verilerin birlikte kullanılması sayesinde modelin öğrenme performansı artar. Pekiştirmeli öğrenme ise modelin en doğru kararları alabilmesi için ödül-ceza sistemiyle çalışır. Bu yöntemde algoritma, en iyi ödüle ulaşan seçenekleri belirlemeyi öğrenir ve bu doğrultuda karar verir (Cheplygina vd., 2019: 280-296).

Sağlık alanındaki ilerlemeler, sağlık verilerinin üretilme hızında büyük bir artışa neden olmuştur. Bu verilerin analiz edilmesi ve anlamlandırılmasında modern makinelerin hesaplama gücü önemli bir ihtiyaç haline gelmiştir. Bu bağlamda, makine öğrenimi büyük veri kümelerinin işlenmesi ve yorumlanması açısından giderek daha fazla önem kazanmaktadır. ML sistemleri, enfeksiyon hastalıklarıyla ilgili araştırma ve ilaç geliştirme süreçlerinden manyetik rezonans görüntülerinin analizine kadar tıbbın birçok alanında etkin bir şekilde kullanılmaktadır (Habehh ve Gohel, 2021:291-300).

2.1. Tıbbi Görüntülemede Makine Öğrenimi

Tıp alanında medikal cihaz üretimi artarken, yapay zekanın sağlık uygulamalarına entegrasyonu için mühendislik çalışmaları hız kazanmıştır. Artan hesaplama gücü ve medikal veri hacmi, yapay zekanın bir alt dalı olan makine öğreniminin tıbbi görüntüleme gibi alanlarda kullanımını mümkün kılmıştır (Zhou vd., 2020: 820-838).

Radyolojide uygulanması zor olan sınıflandırma işlemleri, ML teknikleri sayesinde yüksek hassasiyet ve doğrulukla yapılabilmektedir. Özellikle manyetik rezonans görüntüleriyle yapılan bir ML yönteminin en büyük yeniliği, işlemlerin tamamen otomatik olarak gerçekleştirilmesini sağlayan modellerin geliştirilmesidir. Bu modeller, MR görüntülerindeki dokuları veri kaybı olmadan analiz eder (Choy vd., 2018: 318-328).

ML yöntemleriyle tıbbi görüntülemenin en büyük zorluğu, yeterli veri miktarının bulunmamasıdır. Bu durum büyük veri setleri ile eğitilmesi gereken modellerin eğitilmesini zorlaştırır. Bu sorunu aşmak için transfer öğrenme tekniği bir çözüm olarak sunulmuştur. Transfer öğrenme, az veriyle doğru sonuçlar elde etse de daha nitelikli sonuçlar için daha büyük veri kümeleri gereklidir (Thrall vd., 2018: 504-508).

3. DERİN ÖĞRENME: VERİ HESAPLAMA GÜCÜ ve ÖĞRENME YETENEĞİ

İnsan beyni, duyu organları aracılığıyla aldığı verileri, geçmişteki deneyimleriyle karşılaştırarak bilgiye dönüştürür. Bu bilgi, bireyin karar almasına olanak tanıyabileceği gibi gelecekteki kararlarını da etkileyebilir. Beynin karar alma mekanizmasını matematiksel olarak modelleme çabası, yapay zekâ kavramının temelini oluşturmuş ve sinir hücrelerinin yapısını taklit ederek makinelerin öğrenmesini mümkün kılan yapay sinir ağlarının geliştirilmesine öncülük etmiştir. Zamanla bu ağlar, daha fazla veri kullanarak daha karmaşık sorunları çözme kapasitesini geliştirmiş ve derin öğrenme adı verilen ileri bir aşamaya evrilmiştir (Ghosh vd.,2019: 1-35).

Derin öğrenme, çok katmanlı yapay sinir ağlarını temel alan bir yapay zekâ yöntemidir ve doğal dil işleme, nesne tanıma gibi alanlarda kullanılır. Günümüzde verilerin hızındaki, çeşitliliğindeki ve kapasitesindeki büyük artış, Big Data kavramını ortaya çıkarmış ve bu da derin öğrenmenin daha etkili sistemler tasarlamasına olanak sağlamıştır (Rana ve Bhushan, 2022:157-161). Derin öğrenme algoritmaları, geleneksel makine öğrenmesi algoritmalarına kıyasla büyük veri setleriyle çok daha büyük başarı oranları elde etmektedir. Derin öğrenmeyi geleneksel makine öğrenmesinden ayıran önemli özellikler, büyük veri setleri ile çalışabilmesi, karmaşık yapıların işlenebilmesi için yüksek hesaplama gücüne sahip donanımlara ihtiyaç duyması ve kendi kendine öğrenebilmesidir. Bu özellikler derin öğrenmenin başarısına önemli katkılar sağlar (Esteva vd.,2019:24-29).

3.1. Yapay Sinir Ağları

Yapay sinir ağları, derin öğrenmenin temelini oluşturan ve insan beynindeki nöronları taklit ederek öğrenme gerçekleştiren bilgisayar sistemleridir. McCulloch ve Pitts, nöronları diğer nöronlardan gelen girdilerle modelleyerek, bu girdilerin ağırlıklarına göre nöronları etkinleştirebilen bir model geliştirmişlerdir. 1960'lı yıllarda, bu modelin insan beynine benzerliği kanıtlanmıştır (Krogh, 2008:195-197). Bugün yapay sinir ağları sınıflandırma, tahmin ve örüntü tanıma gibi problemleri

çözmede yaygın olarak kullanılmaktadır. İnsan beyninin konuşma tanıma, nesne tanıma ve dil işleme gibi görevlerini yapay sinir ağları başarıyla yerine getirebilmektedir (Paul vd., 2024:145-170).

Yapay sinir ağı modeli, üç katmandan oluşur; giriş, gizli ve çıkış katmanları. Giriş katmanına veri girişi yapılır ve her bir giriş elemanı, gizli katmana bağlanır. Gizli katman, veriyi işleyerek bir sonraki katmana aktarır. Eğer gizli katman sayısı fazla ve katmanlardaki nöron sayısı fazla ise, derin sinir ağları yapısı ortaya çıkar. Çıkış katmanı ise gizli katmandan gelen veriyi işleyerek son çıktıyı üretir (Abiodun vd.,2018: 1-41).

3.2. Nesne Tespiti İçin Kullanılan Derin Öğrenme Mimarileri

Derin öğrenme algoritmaları, klasik sinir ağlarından farklı olarak daha karışık verileri işleyebilmek için gizli katmanlar kullanır. Tıp alanında ise yaygın olarak Konvolüsyonel Sinir Ağları (Convolutional Neural Network- CNN), Derin İnanç Ağları (Deep Belief Network- DBN), Tekrarlayan Sinir Ağları (Recurrent Neural Network -RNN) ve Derin Sinir Ağları (Deep Neural network-DNN) yer almaktadır (Vasques vd., 2020: 842-850).

3.2.1. Konvolüsyonel Sinir Ağı (CNN)

Derin öğrenme yöntemlerinden biri olan CNN, görsel veri analizi, görüntü tanıma ve işleme alanlarında yaygın olarak kullanılan bir yapay sinir ağı türüdür. CNN, insan beyninin görüntüleri işleme biçimine benzer bir şekilde çalışarak görüntüyü düşük seviyeli özelliklere ayırır ve bu özellikleri birleştirerek anlamlandırır. Büyük veri setlerini eğitmekte etkili olan CNN'ler, giriş görüntülerine dayalı doğru çıktılar tahmin etmek için geri yayılım algoritmalarını kullanır. Ayrıca ağın performansını artırmak için veri artırma tekniklerinden yararlanılır (Sharma vd.,2024: 637-659).

CNN'in geliştirilmesinde insan görme sisteminden esinlenilmiştir. İnsan beyni, nesneleri tanımlarken çeşitli özelliklerden faydalanarak çıkarım yapar. Benzer şekilde CNN, bilgisayarların görüntüleri anlamlandırmasını sağlar. Bilgisayarlar, her bir piksele karşılık gelen renk değerlerini matrisler halinde saklar ve CNN modelleri bu matrisler üzerinde işlemler gerçekleştirir (Yamashita vd., 2018:611-629).

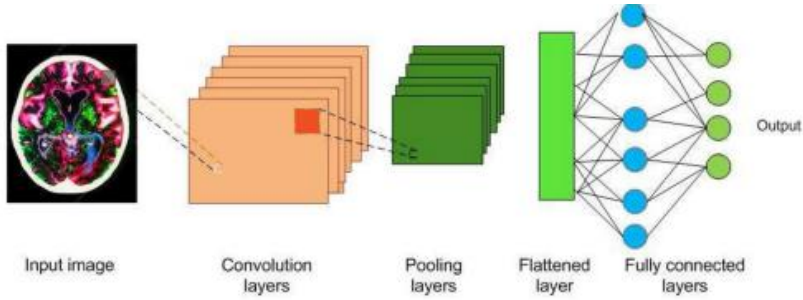

Şekil 1: Konvolüsyonel sinir ağı (CNN) mimarisine bir örnek (Sarvamangala ve Kulkami, 2022:1-22).

CNN, tıbbi görüntüleme alanında da önemli bir rol oynar. Örneğin, tümörlerin erken teşhisi ve sınıflandırılmasında etkili bir şekilde kullanılmaktadır. Manyetik rezonans görüntüleme (MRG), vücuttaki tümörlerin tespiti için yaygın kullanılan yöntemlerden biridir. MRG, yüksek çözünürlüklü görüntüler sağlayarak dokulardaki anormallikleri detaylı bir şekilde ortaya koyar. CNN, MRG verilerinden faydalanarak tümörlerin tespiti ve sınıflandırılmasında hızlı ve doğru sonuçlar sunar (Gu vd.,2018:354-377).

Kemik kırıklarının tespitinde CNN mimarisine dayalı derin öğrenme sistemleri mevcuttur. Bu sistemler, X-ray görüntülerinden veri toplama, ön işleme performans analizi, model seçimi ve eğitimi gibi temel adımları içerir. EfficientNetv2b2-FracAtlas gibi modüller, yüksek performansları ve hesaplama verimliliğiyle bu alanda öne çıkmaktadır. CNN tabanlı sistemler, tıbbi tanı süreçlerini iyileştirerek insan hatası riskini azaltmak ve hızlı, doğru tıbbi bakım sunmak için büyük bir potansiyel taşır (Achawale vd.,2024:323-333).

Gelecekte, CNN teknolojisi ileri düzey algoritmalar ve büyük veri setlerinin entegrasyonu ile daha güçlü hale gelerek, karmaşık problemleri çözme kapasitesini arttıracaktır (Hasan vd., 2024:173-181).

3.2.1.1. Açıklanabilir Yapay Zekâ Teknikleri

Açıklanabilir yapay zekâ yöntemleri (AYZ), CNN modellerinin kararlarını hangi görüntü bölgesine dayanarak verdiğini belirlemek için kullanılan tekniklerdir. Özellikle tıp alanında, CNN modellerinin karar süreçlerini anlamak, doktorlar ve araştırmacılar için büyük önem taşımaktadır. Local Interpretable Model- Agnostic Explanations (LIME) ve Shapley Additive Explanations (SHAP) gibi yöntemler, modellerin kararlarını görselleştirerek daha anlaşılır hale getirir (Lundberg, 2017:1-10).

CNN ve AYZ yöntemleriyle elde edilen sonuçlar doğruluk, hassasiyet, özgüllük, F1skoru ve IOU gibi performans göstergeleriyle değerlendirilir. Bu göstergeler, modellerin klinik alanlarda güvenilirliğini ve etkinliğini belirlemeye yardımcı olur. Ayrıca geliştirilen modellerin güçlü ve zayıf yönlerini ortaya koyarak iyileştirilmesine olanak tanır (Sokolova ve Lapalme, 2009:427-437).

3.2.2. Derin İnanç Ağı (DBN)

Derin inanç ağları, birbiri üzerine yığılmış çok sayıda katmandan oluşan bir yapıdadır. Her katman, bir önceki katmana göre daha karmaşık özellikleri öğrenir ve bağımsız olarak eğitilebilir. Yüksek öğrenme kapasitesi ve karar verme süreçlerindeki etkinliği nedeniyle, DBN farklı uygulama alanlarında önemli bir yapay zekâ modeli olarak kullanılır (Al-Atroshi vd., 2024:1-11).

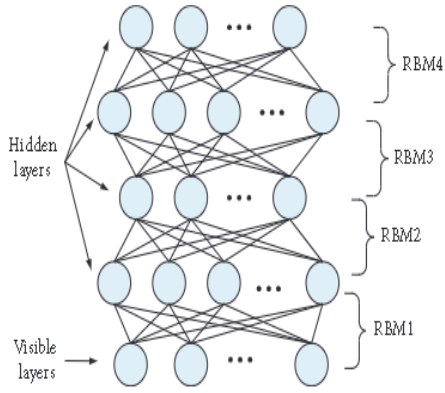

Şekil 2: Derin inanç ağı (DBN) mimarisi (Chao vd., 2018:1236-1246)

Göğüs kanserinin erken teşhisi hastaların hayatta kalma oranlarını artırmada kritik bir öneme sahiptir. DBN modelleri, mamogram ve tomografi görüntülerinden kanserli dokuları tespit etmede etkili bir yöntem sunar. Bu modeller, gizli katmanlar ve aktivasyon fonksiyonları gibi parametreleriyle temsili öğrenme yeteneği sağlar ve meme kanseri türlerini sınıflandırmada başarılı sonuçlar elde eder (Archana, 2024:3074-3101).

3.2.3. Tekrarlayan Sinir Ağı (RNN)

Tekrarlayan Sinir Ağları (RNN), sıralı verileri işlemek için kullanılan bir derin öğrenme modelidir. RNN, önceki bilgilerle yeni giriş verilerini bir arada değerlendirerek mevcut çıktıyı üretir. Model giriş

verilerini işler, bu verilerden elde edilen çıktıyı doğru değerlerle karşılaştırır ve aradaki farklara göre ağın ağırlıklarını güncelleyerek daha doğru sonuçlar elde eder (Samee vd.,2022:1-18).

RNN mimarisi, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Her katman kendine özgü bir işlevi yerine getirerek modelin veriler arasındaki bağlantıyı öğrenmesini ve daha nitelikli sonuçlar üretmesini sağlar. RNN, önceki giriş değerlerini depolayarak yeni giriş değerleriyle ilişkilendirir ve bu sayede veriler arasında ilişki kurar (Yu vd., 2019:1235-1270).

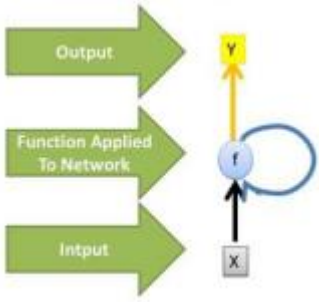

Şekil 3: Tekrarlayan sinir ağı (RNN) mimarisine bir örnek (Katte, 2018:124-129).

Diyabet gibi tüm vücut sistemini etkileyen hastalıların tanısında RNN modülü yaygın olarak kullanılmaktadır. Diyabetli ve diyabetli olmayan bireylerden toplanan veriler ön işleme tabi tutulur ve RNN tabanlı analitik modeller oluşturularak hastalığın tanısı konulur. Bu modellerin performansı, Parçacık Sürüsü Optimizasyonu (PSO) algoritması kullanılarak optimize edilerek daha etkili sonuçlar elde edilir (Srinivasu vd., 2022: 1-30).

3.2.4. Derin Sinir Ağı (DNN)

Sinir ağları, insan beyninin işlevlerini makineler aracılığıyla taklit etmek için geliştirilmiş bilgi işlem modülleridir. Derin sinir ağları (DNN), birden fazla gizli katman içerir ve bu katmanlar arsındaki nöronlar, bağlantılar aracılığıyla birbirleriyle iletişim kurar. DNN modülü, sinir hücreleri arasındaki ağırlıkların işlenen veriye uygun olacak şekilde optimize edilmesini sağlayarak öğrenme sürecini gerçekleştirir (Futoma vd., 2015:229-238).

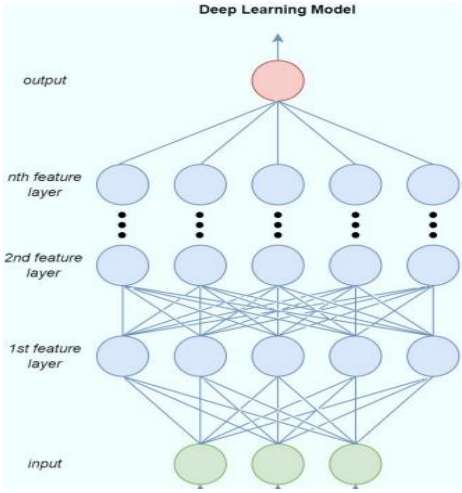

Şekil 4: Derin sinir ağı mimarisi (Miotto vd, 2018:1236-1246).

DNN, gen dizilimlerinden kanser teşhisine ve stres bozukluklarının belirlenmesine kadar çeşitli tıbbi alanlarda yaygın olarak kullanılmaktadır. Kolorektal kanser vakalarında ise lenf nodu metastazlarının tespiti için oldukça etkili bir araçtır. DNN, kanserli dokuları piksel düzeyinde yüksek hassasiyetle tespit eder ve lenf düğümlerinin analiz süresini önemli ölçüde kısaltır. Özellikle yüksek vaka hacmi ve fazla sayıda lenf nodu bulunan durumlarda DNN modüllerinin kullanımı klinik iş akışını optimize eder ve histopatolojik değerlendirme kalitesini artırır (Bychkov vd., 2018:1-11).

3.3. Tıbbi Görüntü Analizi ve Bilgisayar Destekli Tanı İçin Derin Öğrenme

Modern tıptaki gelişmeler, tıbbi görüntüleme analizinin etkinliğini büyük ölçüde arttırmıştır. Fakat tanı sürecinde görüntülerin değerlendirilmesi sırasında bazı hatalar meydana gelmektedir. Bu bağlamda bilgisayar destekli tanı (CAD) sistemleri, tıbbi görüntülerdeki hastalıklı dokuları tespit etmek ve iyi huylu ya da kötü huylu tümörleri analiz etmek için kullanılır (Chan vd.,2020:218-227).

Derin öğrenme yöntemleri, CAD sistemlerinde tıbbi görüntülerin analiz edilmesi ve hastalık sonuçlarının belirlenmesi için kullanılır. Yeni bir veri girildiğinde, modelin hastalık teşhisi yapması hedeflenir. Geniş veri setleriyle eğitilen bu sistemler, tedavi planlaması ve tedaviye verilen yanıtın değerlendirilmesi gibi hasta bakım süreçlerinde önemli bir rol oynayabilir (Czajkowska ve Borak, 2022:1-36).

Derin öğrenmenin CAD sistemlerinde kullanılmasının temel sebebi, nesne tespitindeki üstün performansıdır. Günümüzde CAD sistemlerinde kullanılan CNN modelleri, genellikle dokulardaki anormallikleri tespit etmek üzere eğitilmektedir. Ayrıca, CNN'lerin tümör segmentasyonu, sınıflandırılması ve ayrıştırılması gibi işlemlerle CAD sistemine entegrasyonu giderek yaygınlaşmaktadır (Ali vd., 2019:285-291).

Yapay zekadaki ilerlemelerin, CAD sistemlerinin sağlık alanındaki kullanımını daha da yaygınlaştıracağı tahmin edilmektedir. Ancak, CNN tabanlı CAD araçlarının gelişimindeki en büyük engellerden biri, yeterli ve doğru veri setlerinin eksikliğidir. Bu sorunun çözümü için elektronik sağlık kayıtlarından yararlanılarak, veri madenciliği ve doğal dil işleme yöntemleri kullanılabilir (Wenderott vd., 2024:1-10).

4. SONUÇLAR

Derin öğrenme, sağlık sektöründe büyük değişiklikler meydana getirerek sağlık bilişiminde veri odaklı çözümlerin getirilmesine olanak tanımıştır. Son zamanlarda, derin öğrenme, klinik süreçlerin daha verimli hale getirilmesi, uzaktan hasta takibinin iyileştirilmesi ve tıbbi görüntülerin analiz edilmesi gibi çeşitli alanlarda yaygın olarak kullanılmaya başlanmıştır. Bu çalışmada, sağlık alanında kullanılan derin öğrenme yöntemleri incelenmiş ve tıbbi görüntülerin yüksek doğrulukla ve kısa sürede analiz edilmesine ilişkin detaylı değerlendirmeler sunulmuştur.

Yapay zekadaki gelişmelerle birlikte, bu alanda kullanılan teknolojilerin daha da geliştirilmesi hedeflenebilir. Etkili sistemler geliştirebilmek için mevcut derin öğrenme modellerinin daha da ileri seviyelere taşınması gereklidir. Bunun için çeşitli sağlık verileriyle uyumlu çalışabilecek şekilde tasarlanmış derin öğrenme modellerinin oluşturulması, sağlık sistemlerinde karşılaşılan kritik problemleri çözmede etkili bir rol oynamaktadır.

REFERANSLAR

Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. Heliyon, 4(11).

Achawale, M. A., More, Y., Bankar, M. A., Ghuge, M. P., & Zole, M. G. (2024). Bone fracture detection using convolutional neural network (CNN). Journal of basic science and engineering, 21(1), 323-333.

AI-Atroshi, C., Rene Beulah, J., Singamaneni, K. K., Pretty Diana Cyril, C., Neelakandan, S., & Velmurugan, S. (2024). Retracted Article: Automated speech-based evaluation of mild cognitive impairment and Alzheimer's

disease detection using deep belief network model. International Journal of Healthcare Management, 1-11.

Ali, N. A., Syafeeza, A. R., Geok, L. J., Wong, Y. C., Hamid, N. A., & Jaafar, A. S. (2019). Design of automated computer-aided classification of brain tumor using deep learning. In Intelligent and Interactive Computing: Proceedings of IIC 2018 (pp. 285-291). Springer Singapore.

Archana, S. (2024). Detection of breast cancer by deep belief network with improved activation function. International Journal of Adaptive Control and Signal Processing, 38(9), 3074-3101.

B. Norgeot, B. S. Glicksberg, and A. J. Butte, ''A call for deeplearning healthcare,'' Nature Med., vol. 25, no. 1, pp. 14–15, Jan. 2019.

Bychkov, D., Linder, N., Turkki, R., Nordling, S., Kovanen, P. E., Verrill, C., ... & Lundin, J. (2018). Deep learning-based tissue analysis predicts outcome in colorectal cancer. Scientific reports, 8(1), 3395.

Chan, H. P., Hadjiiski, L. M., & Samala, R. K. (2020). Computer-aided diagnosis in the era of deep learning. Medical physics, 47(5), e218-e227.

Chao, H., Zhi, H., Dong, L., & Liu, Y. (2018). Recognition of Emotions Using Multichannel EEG Data and DBN-GC-Based Ensemble Deep Learning Framework. Computational intelligence and neuroscience, 2018(1), 9750904.

Cheplygina, V., De Bruijne, M., & Pluim, J. P. (2019). Not-so-supervised: a survey of semi-supervised, multi-instance, and transfer learning in medical image analysis. Medical image analysis, 54, 280-296.

Chin, C. L., Lin, B. J., Wu, G. R., Weng, T. C., Yang, C. S., Su, R. C., & Pan, Y. J. (2017, November). An automated early ischemic stroke detection system using CNN deep learning algorithm. In 2017 IEEE 8th International conference on awareness science and technology (iCAST) pp. 368-372. IEEE.

Choy, G., Khalilzadeh, O., Michalski, M., Do, S., Samir, A. E., Pianykh, O. S., ... & Dreyer, K. J. (2018). Current applications and future impact of machine learning in radiology. Radiology, 288(2), 318-328.

Czajkowska, J., & Borak, M. (2022). Computer-aided diagnosis methods for high-frequency ultrasound data analysis: a review. Sensors, 22(21), 8326.

D. Ravì, C. Wong, F. Deligianni, M. Berthelot, J. Andreu-Perez,B. Lo, and G.-Z. Yang, ''Deep learning for health informatics,''IEEE J. Biomed. Health Informat., vol. 21, no. 1, pp. 4–21, Jan. 2017.

Domingos, P. (2012). A few useful things to know about machine learning. Commun. ACM, vol. 55, no. 10, pp. 78–87.

Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., ... & Dean, J. (2019). A guide to deep learning in healthcare. Nature medicine, 25(1), 24-29.

Fakoor, R., Ladhak, F., Nazi, A., & Huber, M. (2013). Using deep learning to enhance cancer diagnosis and classification. In Proc. Int. Conf. Mach. Learn., 2013, pp. 1–7.

Futoma, J., Morris, J., & Lucas, J. (2015). A comparison of models for predicting early hospital readmissions. Journal of biomedical informatics, 56, 229-238.

Gawehn, E., Hiss, J. A., & Schneider, G. (2016). Deep learning in drug discovery. Molecular informatics, 35(1), 3-14.

Ghosh, S., Das, N., Das, I., & Maulik, U. (2019). Understanding deep learning techniques for image segmentation. ACM computing surveys (CSUR), 52(4), 1-35.

Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T. (2018). Recent advances in convolutional neural networks. Pattern recognition, 77, 354-377.

Habehh, H., & Gohel, S. (2021). Machine learning in healthcare. Current genomics, 22(4), 291.

Hasan, M. A., Bhargav, T., Sandeep, V., Reddy, V. S., & Ajay, R. (2024). Image classification using convolutional neural networks. International Journal of Mechanical Engineering Research and Technology, 16(2), 173-181.

Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. Science, 349(6245), 255-260.

Katte, T. (2018). Recurrent neural network and its various architecture types. Int J Res Scie Innovation, 5(3), 124-129.

Krogh, A. (2008). What are artificial neural networks?. Nature biotechnology, 26(2), 195-197.

Lundberg, S. (2017). A unified approach to interpreting model predictions. arXiv preprint arXiv:1705.07874

Malik, M., Singh, Y., Garg, P., & Gupta, S. (2020). Deep learning in healthcare system. International Journal of Grid and Distributed Computing, 13(2), 469-468.

Miotto, R., Wang, F., Wang, S., Jiang, X., Dudley, J. T. (2018). Deep learning for healthcare: review, opportunities, and challenges. Brief Bioinform, 19(6), 1236-1246.

Nunavath, V., Goodwin, M., Fidje, J. T., & Moe, C. E. (2018). Deep neural networks for prediction of exacerbations of patients with chronic obstructive pulmonary disease. In Engineering Applications of Neural Networks: 19th International Conference, EANN 2018, Bristol, UK, September 3-5, 2018, Proceedings 19 (pp. 217-228). Springer International Publishing.

Paul, S. G., Saha, A., Hasan, M. Z., Noori, S. R. H., & Moustafa, A. (2024). A systematic review of graph neural network in healthcare-based applications: Recent advances, trends, and future directions. IEEE Access.

Rana, M., & Bhushan, M. (2022, March). Advancements in healthcare services using deep learning techniques. In 2022 International mobile and embedded technology conference (MECON) (pp. 157-161). IEEE.

Rahman, M. H., Rana, H. K., Peng, S., Hu, X., Chen, C., Quinn, J. M., & Moni, M. A. (2021). Bioinformatics and machine learning methodologies to identify the effects of central nervous system disorders on glioblastoma progression. Briefings in Bioinformatics, 22(5), 1-23.

Samee, N. A., Mahmoud, N. F., Aldhahri, E. A., Rafiq, A., Muthanna, M. S. A., & Ahmad, I. (2022). RNN and biLSTM fusion for accurate automatic epileptic seizure diagnosis using EEG signals. Life, 12(12), 1946.

Sarvamangala DR, Kulkarni RV. Convolutional neural networks in medical image understanding: a survey. Evol Intel 2022; 15(3): 1-22.

Sharma, P., Nayak, D. R., Balabantaray, B. K., Tanveer, M., & Nayak, R. (2024). A survey on cancer detection via convolutional neural networks: Current challenges and future directions. Neural Networks, 169, 637-659.

Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. Information processing & management, 45(4), 427-437.

Srinivasu, P. N., Shafi, J., Krishna, T. B., Sujatha, C. N., Praveen, S. P., & Ijaz, M. F. (2022). Using recurrent neural networks for predicting type-2 diabetes from genomic sequences. Springer Nature, 121-128.

Tariciotti, L., Caccavella, V. M., Fiore, G., Schisano, L., Carrabba, G., Borsa, S., ... & Bertani, G. (2022). A deep learning model for preoperative differentiation of glioblastoma, brain metastasis and primary central nervous system lymphoma: a pilot study. Frontiers in Oncology, 12, 816638.

Thrall, J. H., Li, X., Li, Q., Cruz, C., Do, S., Dreyer, K., & Brink, J. (2018). Artificial intelligence and machine learning in radiology: opportunities, challenges, pitfalls, and criteria for success. Journal of the American College of Radiology, 15(3), 504-508.

Vasques, F., Camporota, L., & Barrett, N. A. (2020, December). Nonantibiotic pharmacological treatment of severe chronic obstructive pulmonary disease exacerbations. In Seminars in Respiratory and Critical Care Medicine (Vol. 41, No. 06, pp. 842-850). Thieme Medical Publishers.

Wenderott, K., Krups, J., Luetkens, J. A., & Weigl, M. (2024). Radiologists' perspectives on the workflow integration of an artificial intelligence-based computer-aided detection system: A qualitative study. Applied ergonomics, 117, 104243.

Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. Insights into imaging, 9, 611-629.

Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. Neural computation, 31(7), 1235-1270.

Zhou, S. K., Greenspan, H., Davatzikos, C., Duncan, J. S., Van Ginneken, B., Madabhushi, A., ... & Summers, R. M. (2021). A review of deep learning in medical imaging: Imaging traits, technology trends, case studies with progress highlights, and future promises. Proceedings of the IEEE, 109(5), 820-838.