

Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme

A Study on Deep Learning and Artificial Neural Network Models

 Ercan AKIN^{1,*}, Mustafa Ergin ŞAHİN¹ 

¹Recep Tayyip Erdoğan Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Rize, Türkiye
ercan_akin22@erdogan.edu.tr

Öz

Makine öğrenmesinin alt kümelerinden olan derin öğrenme, son zamanlarda gelişen teknolojiye ayak uydurmak için geliştirilen yapay zekâ uygulamalarının temelini oluşturmaktadır. Yapay zekâ ile çözüm aranan birçok problemde derin öğrenme yöntemleri kullanılmış ve birçok derin öğrenme yaklaşımı ortaya çıkartılmıştır. Görüntülerin işlenmesinde, ses tanımlamalarında, nesne tespitlerinde, mühendislik uygulamaları, ticari faaliyetler ve istatistiksel birçok çalışmaya kaynak oluşturan verilerin işlenmesinde, medikal uygulama ve doğal dil işleme gibi birçok alanda kullanılmış ve kullanılmaya devam edilmektedir. Günümüz şartlarında teknolojiye paralel olarak veriler giderek artmaktadır. Bu artan veri havuzu birçok kişi ve firmalar için inanılmaz derecede önem arz etmektedir. Google, Apple, Baidu, Tesla, Mercedes, Facebook ve Microsoft gibi birçok büyük firma bu verileri işlemek için bu konu üzerinde çalışmalar yürütmekte ve uygulamalarına derin öğrenmeyi entegre etmektedir. Teknoloji yarışı ve pazarlama stratejileri sayesinde günümüzde önemli bir noktaya gelen yapay sinir ağı modelleri ve derin öğrenme konusu, konumuza temel oluşturmaktadır. Bu çalışmada derin öğrenmenin tarihçesi, çalışma prensibi, uygulama alanları ve bu uygulama alanlarında kullanılan yapay sinir ağı modelleri hakkında bilgi verilmiştir. Son bölümde ise güncel bazı uygulamalardan bahsedilmiştir.

Anahtar Kelimeler: Yapay Zekâ, Makine Öğrenmesi, Derin Öğrenme, Yapay Sinir Ağları

Abstract

Deep learning, which is one of the subsets of machine learning, forms the basis of artificial intelligence (AI) applications developed to keep up with the developing technology. Deep learning methods have been used in many problems for which solutions are sought with artificial intelligence and many deep learning approaches have been revealed. It has been used and continues to be used in many fields such as image processing, sound identification, object detection, data processing (Engineering applications, Commercial activities, Statistical studies, etc.), medical practice, and natural language processing. In today's conditions, data is increasing in parallel with technology. This growing pool of data is incredibly important to many individuals and companies. Many large companies such as Google, Facebook, Apple, Tesla, Mercedes, Baidu, and Microsoft are working on this issue to process this data and integrate deep learning into their applications. The technology race and marketing strategies that bring artificial neural

networks and models, deep learning to such an important point today, form the basis of our subject. In this study, information is given about the history of deep learning, its working principle, application areas and artificial neural network models used in these application areas. In the last section, some current applications are mentioned.

Keywords: Artificial Intelligence, Machine Learning, Deep Learning, Artificial Neural Networks

1.Giriş

Yapay zekâ, makine öğrenmesi ve derin öğrenme mantık olarak aynı olsa da işlev bakımından birbirlerinden ayrılır. Yapay zekâ, sadece sisteme girilen yani öğretilen veriler doğrultusunda işlem yapabilirken makine öğrenmesi verilen veriler ve bu verilerden oluşturduğu ekstra bilgiler doğrultusunda çıkarım yapmaktadır. Denetimli makine öğreniminin bir alt dalı olan derin öğrenme ise beyin yapısından ve işlevinden ilham alan yapay sinir ağı algoritmalarını kullanarak işlemleri gerçekleştirmektedir [1]. Yapay zekâ ve makine öğrenmesine göre daha çok veriyi daha karmaşık bir şekilde kendi oluşturduğu algoritma zincirleri ile yinelemeli olarak öğrenebilen ve sürekli olarak öz nitelik değerlerini oluşturup oluşturduğu bu öz niteliklere göre çıkarımlar yapabilen bir sistemdir. En genel tanımıyla derin öğrenme; canlıların karmaşık problemler ve durumlar karşısında kullandığı gözlem, analiz, öğrenme ve karar verme gibi özgül davranışları, çok yüksek miktardaki verileri denetimli veya denetimsiz öğrenme algoritmalarında kullanarak öz nitelik çıkaran ve çıkardığı bu öz niteliklere dönüştürme ve sınıflandırma gibi işlemler uygulayarak taklit edebilen bir makine öğrenmesi yöntemidir [2], [3].

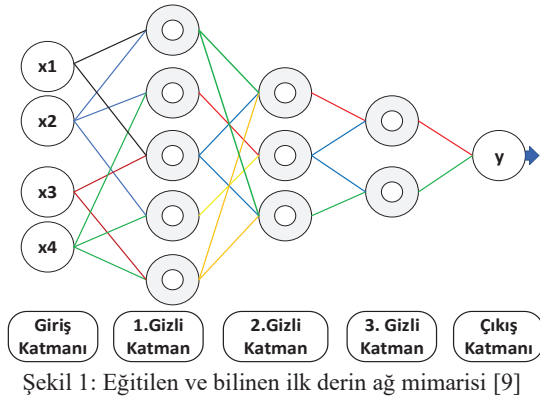
Günümüzde otonom sistemlerin daha ileri bir seviyeye ulaşabilmesi için yapay zekâ teknolojileri ile donatılmış sistemlere gereksinim duyulmaktadır [4]. Geçmişte yapay zekâ da karar verme veya tahmin oluşturma süreçlerinde sadece makine öğrenmesi algoritmaları kullanılmıştır. Fakat günümüz teknolojisinde insan faktörüne olan bağlılık git gide azalmakta ve yerini derin öğrenme tabanlı sistemlere bırakmaktadır. Buna bağlı olarak giderek artan ve karmaşık bir hal alan verilerin hızlı bir şekilde analiz edilmesi, öğrenilmesi ve uygulanmasında derin öğrenme yöntemleri kullanılmaya başlanmıştır [3], [5].

Bu çalışmada son yıllarda önemi oldukça artan derin öğrenme kavramı detaylı bir şekilde araştırılmıştır. İkinci bölümde derin öğrenmenin tanımı, çalışma prensibi ve tarihçesi anlatılmıştır. Üçüncü bölümde derin öğrenmede kullanılan yapay sinir ağı modelleri, derin öğrenme hakkında araştırma

yapan firmalar ve derin öğrenme için kullanılacak modeller anlatılmıştır. Dördüncü bölümde ise dünyada ki uygulama alanlarına kısa bir şekilde değinilmiş ve fotovoltaik sistemlerde kullanılan MPPT modelinin yapay zekâ ile modellenmesi vurgulanmıştır.

2. Derin Öğrenmenin Tarihiçesi

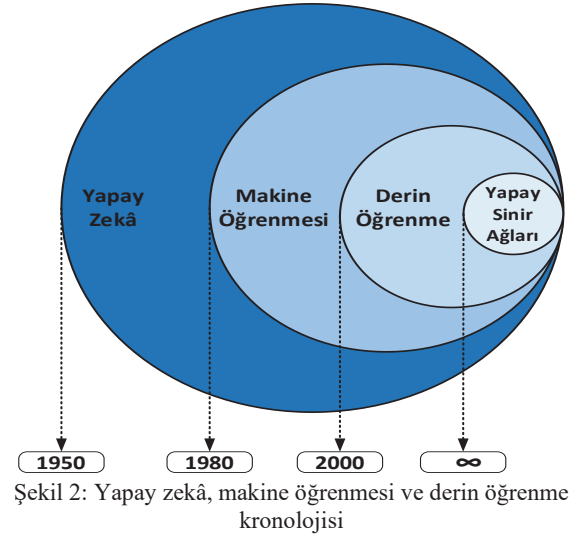
Derin öğrenmenin ilk adımı 1943 yılında Walter Pitts ve Warren McCulloch tarafından oluşturulan McCulloch-Pitts nöronları olarak adlandırılan matematiksel bir sinir ağı modelidir [6]. 1950 yılında Alan Turing ve 1952 yılında Arthur Samuel makine öğreniminin temellerini attılar. 1959 yılında David Hubel ve Torsten Wiesel basit ve karmaşık hücre yapılarını ortaya çıkartarak derin öğrenmeye özgü bir dönüm noktası olmasa bile yapay sinir ağlarının gelişimine katkıda bulunmuştur [7]. 1960 yılında Heury J. Kelley uçakların olası rotalarıyla ilgili bir kontrol kuramı oluşturmuştur. Bu kontrol kuramı geri beslemeli öğrenme algoritmalarının başlangıç noktası olarak kabul görmüştür [8]. 1965 yılında Alexey Ivakhnenko, çok değişkenli veri setlerini kullanarak bilgisayar tabanlı matematiksel bir model oluşturmuş ve bu modelini sinir ağlarına uyarlayarak çalışan ilk derin öğrenme ağlarını geliştirmiştir [9]. Alexey Ivakhnenko, V.G.Lapa ve arkadaşları tarafından eğitilen ve bilinen ilk derin ağ mimarisi Şekil 1 'de gösterilmiştir.



Şekil 1: Eğitilen ve bilinen ilk derin ağ mimarisi [9]

1979-80 senelerinde Kunihiro Fukushima tarafından geliştirilen ve Neocognitron adını verdiği yapay sinir ağı modeli ile günümüzde daha çok görüntü analizlerinde kullanılan konvüsyonel yapay sinir ağlarının temeli atılmıştır [10]. 1982 yılında ise John Hopfield tarafından, tekrarlayan sinir ağlarının temeli olarak kabul edilen, Hopfield ağı modeli oluşturulmuştur [11]. 1985 yılında İngilizce kelimeleri hemen hemen bir çocuğun öğreneceği şekilde öğrenen ve telaffuz edebilen program Terry Sejnowski tarafından geliştirildi. 1986 yılından aynı şekilde şekil tanıma programı geliştirildi [12]. 1989 yılında Yann LeCun makinelerin elle yazılmış rakamları okuyabilmesini sağlayan bir sistem geliştirdi. Bu sistem en çok çeklerin ve posta kodlarının okunmasında kullanıldı. 1993 yılında Jürgen Schmidhuber, derin öğrenme için önemli bir gelişme olan ve Çok Derin Öğrenme görevi adını verdiği çözümlenmiş yaklaşık 1000 katmandan oluşan devirli sinir ağı modelini kullanıma sunmuştur. Jürgen Schmidhuber ayrıca 1997 yılında uzun-kısa süreli hafıza (LSTM) modelini ilk kez ortaya atmıştır [13]. 1998

yılında Yann LeCun tarafından gradyan tabanlı öğrenme algoritması geliştirilmiş ve geri yayılım algoritması ile birleştirilmiştir [14]. Fei-Fei Li; araştırmacılar, eğitmenler ve öğrenciler için 2009 yılında ImageNet veri tabanını oluşturmuştur. Bu sistemde yaklaşık 15 milyon veri bulunmakta olup kullanıcılar öğrenme modellerini bu verileri kullanarak tasarlayabilmektedir [15]. 2014 yılında ise yüz algılama (DeepFace) sistemi geliştirilmiştir [16]. Günümüzde ise tıp [17]–[19], robotik [20], nesne tespiti [21], görüntü işleme, ses tanıma-işleme [22], veri tahmini, endüstri ve finansal [23] gibi birçok alanda derin öğrenme ve yapay sinir ağı modelleri kullanılmaktadır. Şekil 2 'de yapay zekânın tarihsel kronolojisi gösterilmiştir.

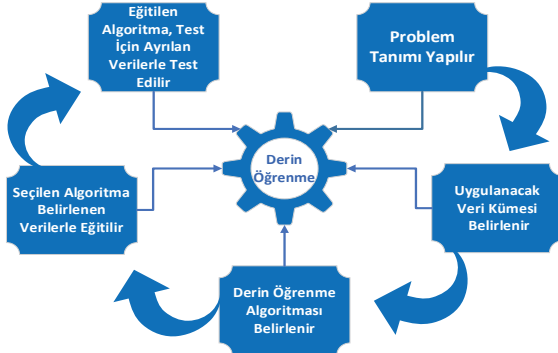


Şekil 2: Yapay zekâ, makine öğrenmesi ve derin öğrenme kronolojisi

3. Derin Öğrenme Sistemi Nasıl Çalışır?

Derin öğrenme temel olarak veriye ait sınıflandırılmış özniteliklerin eğitilmesine dayalıdır. Bu nedenle düşük seviyeli öznitelikler birleştirilir ve daha yüksek seviye öznitelikler içeren bir öznitelik hiyerarşisi oluşturulur. Bu hiyerarşik yapıların oluşturulması sistemlerin karmaşık girdi-çıkı ilişkilerini doğrudan veriden almasını sayılarak insan yapımı özniteliklere olan bağımlılığı azaltmaktadır [24]. Örneğin bir görüntü için öznitelik denildiği zaman; piksel başına düşen yoğunluk değerlerinin bir vektörü veya kenar kümeleri, özel şekiller gibi öznitelikler düşünülebilir. Bu özniteliklerin içinden bazıları veriyi daha iyi tanımlamaktadır. Büyük veri havuzlarından elle öznitelik sınıflandırması yapmak yerine öznitelik çıkarım algoritmalarının kullanımı da bu aşama için büyük bir avantajdır [25].

Şekil 3'te derin öğrenmenin çalışma basamakları belirtilmiştir. İlk olarak problemin tanımı ve derin öğrenmeye uygunluğu tespit edilir. İlgili veri kümeleri belirlenir ve analiz için hazırlanır. Kullanılacak algoritma modeli seçilir. Tanımlı veriler, kullanılan algoritmaya göre analitik model oluşturularak, seçilen algoritma ile eğitilir ve gerektiğinde revize edilir. Son olarak test skorları elde etmek için model çalıştırılır ve çıkan sonuca göre ileriye yönelik tahminler yapılır.



Şekil 3: Derin öğrenme çalışma basamakları

İyi bir derin öğrenme modellemesi yapılabilmesi için büyük bir veri havuzuna, bu verileri eğitecek bir algoritmaya, verilerin öznitelik sınıflandırılmasına, transfer fonksiyonu seçimine, ağ yapısının ve gizli katman sayısının belirlenmesi gibi birçok etken göz önünde bulundurulmalıdır. Derin öğrenme modellerinin yapısı genel olarak girdi katmanı, gizli katman ve çıktı katmanından oluşur. Bu katmanların her birine sayısal bir değer verilir [26]. Gizli katmandaki düğümler (nöronlar); girişi ve çıkışı düğümlerinden, eğitim algoritmasından, ağ yapısından ve aktivasyon fonksiyonunun türünden etkilenir [27]. Gizli katmandaki düğümlerin sayısını belirlemek amacıyla farklı türde ağları eğiterek ve test verisindeki hatayı araştırarak bir sonuç elde etmek gerekir [28].

4. Derin Öğrenmede Kullanılan Yapay Sinir Ağı Modelleri


Derin öğrenmede kullanılan yapay sinir ağları modelleri insan beyninin fonksiyonel işlevlerinden esinlenerek oluşturulmuştur. Öğrenebilen bir yapısı olan bu modeller algılama, kontrol ve analiz yapma, verileri saklama ve bu verilerden çıkarım yapabilme gibi birçok yeteneğe sahiptir. Kendi öznitelik verilerini oluşturarak öğrenme sürecini matematiksel olarak modellerler. Uygulama alanına göre birçok yapay sinir ağı modeli bulunmaktadır. Temel olarak dört gruba ayrılan; tek katmanlı, çok katmanlı, ileri beslemeli ve geri beslemeli yapay sinir ağları modelleri kullanılmaktadır [29].

4.1. Konvolüsyonel (Evrışimli) Sinir Ağları

Konvolüsyonel sinir ağları, temel olarak görüntüleri sınıflandırmak, fotoğraftaki benzerliklere göre objeleri veya nesnelere belirlenen özelliklere göre kümelemek için kullanılan çok katmanlı ve ileri beslemeli bir yapay sinir ağı modelidir. Bu sistem ilk olarak 1968 senesinde Hubel ve Wiesel tarafından hayvanların görme sistemleri temel olarak oluşturulmuştur [30]. Yapay sinir ağları modelleri içerisinde en çok kullanılan modellemedir.

Konvolüsyonel sinir ağları; konvolüsyon (convolution), düzleştirme (rectified linear unit), havuzlama (pooling) ve tam bağlantı (fully connection) katmanlarından oluşur. Bu işlem basamakları elde edilecek görüntü netliğine göre farklı sayıda

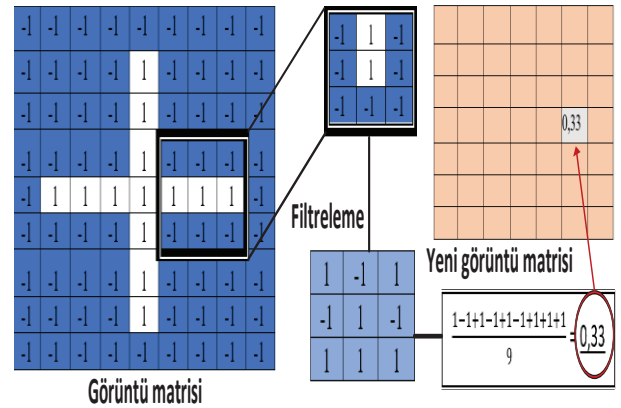
ve boyutta tasarlanabilmektedir. Şekil 4'te bu işlem basamaklarının sıralaması gösterilmiştir.



Şekil 4: Konvolüsyonel sinir ağı katmanları [31]

Konvolüsyonel sinir ağları çok sayıda filtreleme ve öznitelik çıkarım işlemi yaptığından dolayı görsellerdeki farklı özelliklerin tespit edilmesine ve gruplandırılmasına olanak sağlamaktadır. Görüntülerdeki nesnelere hangi niteliklere sahip olduğu (insan, araç-gereç, hayvan, bitki vb.) basit bir şekilde tespit edilebilmektedir.

Konvolüsyonel sinir ağlarında ilk basamak konvolüsyonel katmandır. Bu basamak da Şekil 5'de görüldüğü üzere bir görüntüye ait görüntü matrisinin (9x9x3), her bir satır-sütün aralığına 3x3x3 filtreleme işlemi uygulanarak 7x7x3 boyutlarında yeni bir görüntü matrisi elde edilir. Filtreleme matrisi ve ana matrisin taranan alan satır-satır ve sütun-sütün ile çarpılır. Çarpma işlemi sonucu oluşan matrisin tüm sütun ve satır değerleri toplanarak ortalaması alınır. Elde edilen değerler Şekil 5'deki belirtilen tabloya işlenir. Bu değerler veri boyutuna ve sayısına ve kullanılan filtreleme işlemine göre değişebilir.

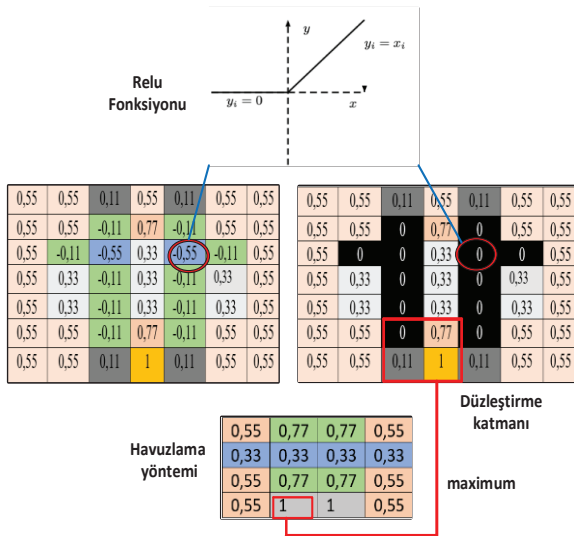


Şekil 5: Konvolüsyonel katman işlem basamakları

İkinci basamak olarak uygulanan düzleştirme işleminde genel olarak Eşitlik 1'de ki Relu (Rectified Linear Unit) fonksiyonu kullanılmaktadır. Şekil 6'da gösterildiği üzere bu işlemdeki amaç sıfırdan küçük değerleri karanlık ortam olarak algılayarak sıfır değerine eşitlemektir.


$$Relu = f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (1)$$

Üçüncü basamak olan havuzlama katmanının amacı konvolüsyon işlemi sonucu oluşan yeni görüntü matrisinin boyutunu azaltmaktır. Bu sayede boyutu düşürerek işlem ağırlığının hızını artırır. İki çeşit havuzlama yöntemi olup, bunlar ortalama ve en büyük değer yöntemleridir. En yaygın şekilde kullanılan en büyük değer havuzlama yönteminde NxN boyutunda matrisler seçilerek içerisindeki en büyük değer seçilir. Genel olarak 2x2 boyutlarında matris kullanılır. Şekil 6 da maksimum havuzlama yöntemi gösterilmiştir. Bu yöntemdeki amaç Relu işlemi sonucu oluşan matristeki karanlık noktaları yok etmektir. Elde edilecek görüntü matrisi istenilen seviyede netlik kazanmamışsa tekrar istenilen bir havuzlama yöntemi kullanılabilir.



Şekil 6: Relu fonksiyonu kullanarak düzeltme katmanı ve Maksimum havuzlama yöntemi

Konvolüsyon, düzeltme ve havuzlama sayısı kullanılan görüntüye veya kullanıcının amacına göre değişiklik gösterilebilmektedir. Bu işlemlerin amacı tam bağlantı öncesi tek boyutlu bir giriş verisi elde etmektir. Son basamak olan tam bağlantı katmanında nesneyi belirleyecek olan özelliklerin hangi kategoriye ait olduğu tespit edilir. Şekil 7’de gösterildiği gibi tam bağlantı katmanında elde edilen sütundaki değerlerden en yüksek değerlerin ortalaması alınarak doğruluk oranı, en düşük değerlerin ortalaması alınarak da hata oranı elde edilir.




Şekil 7: Tam bağlantı katmanı

Konvolüsyonel sinir ağları modelleri günümüzde görüntü işleme alanında öncelikli olarak kullanılmaktadır. Ayrıca ses ve video işlemede, tıbbi taramalar ile hastalıklarının teşhisinde, otonom cihazların kontrolünde ve görüntülerdeki nesnelere tanımlamada da tercih edilmektedir.

4.2. Tekrarlayan Sinir Ağları

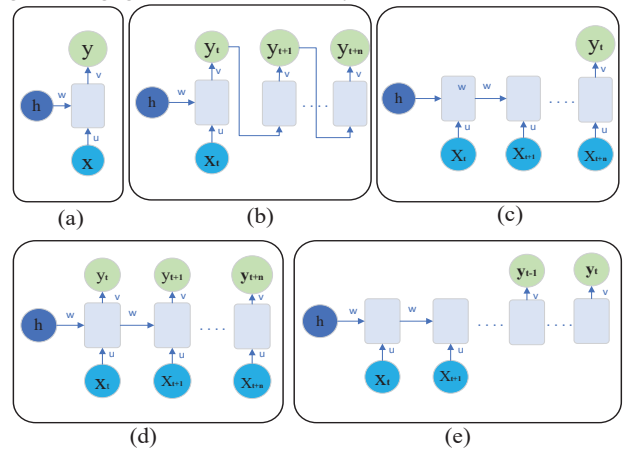
Jeffrey Elman tarafından tasarlanan tekrarlayan sinir ağları, önceki çıkışlarını bir sonraki giriş olarak kullanarak bir döngü oluşturan ve bu döngü esnasında bilgilerin sıralı olarak kullanılmasına özen gösteren öğrenme ve tahmin temelli bir yapay sinir ağı modelidir. Bu ağ yapısı ile bilgilerin kalıcı olarak döngülerde kalmasına ve gerektiği zaman kullanılmasına izin verilmektedir [32]. RNN (Recurrent Neural Network)’ler ileri beslemeli sinir ağlarının aksine kendi giriş belleklerini girdilerin keyfi sıralarını işlemek için kullanılabilirler. Bu modelin asıl amacı ardışık şekilde gelen verilerin birbirleriyle ilişkilendirilerek kullanılmasıdır. Genel olarak sinir ağlarında girişler birbirlerinden bağımsızdır. Fakat RNN’ler de her verinin çıktısı önceki verinin hesaplamalarına bağlıdır.

Şekil 8’de RNN algoritmasının çalışma şekli gösterilmiştir. Burada herhangi bir t zamanında, h aktivasyonu, x girdiyi ve y çıktıyı temsil etmektedir. h' önceki çıkış aynı zamanda bir sonraki giriştir.



Şekil 8: RNN algoritmasının çalışması

RNN’ler, bir döngü şeklinde tasarlandıkları için sıralı bir şekilde gelişen olayları birbirleriyle ilişkilendirebilmektedir. Akış içerisindeki bu ilişkilerin sınıflandırılabilmesinden dolayı da sıklıkla tercih edilmektedir. RNN algoritmasının Şekil 9’da gösterildiği gibi beş farklı çalışma yöntemi bulunmaktadır.




Şekil 9: RNN çalışma yöntemleri, (a) Tek giriş-tek çıkış, (b) Tek giriş-çok çıkış, (c) Çok giriş-çok çıkış, (d) Çoklu sıralı giriş-çoklu sıralı çıkış, (e) Çoklu senkronize giriş-çoklu senkronize çıkış

RNN modeli; Çevirilerde [33], altyazı oluşturmada [34], videolarda gürültü yok etmede [35], uzun metinlerin özeti çıkarılmada [36], el yazısının kime ait olduğunu tespit etmede [37], ses tanımda [38] ve daha birçok alanda kullanılabilirlerdir.

4.3. Uzun ve Kısa Süreli Hafıza Ağları

Sepp Hochreiter ve Jürgen Schmidhuber tarafından 1997 yılında RNN modellerindeki birtakım eksiklikleri gidermek amacıyla oluşturulmuştur [13]. RNN modellemesinde zamansal dizeler arasında oluşan boşluklar bir sonraki dizenin tahmin edilmesini zorlaştırmaktaydı [39]. Mesela “Türkiye’nin ana dili **Türkçedir**” cümlesinde **Türkçe** kelimesini tahmin etmek RNN modeli için kolaydır. Fakat “Ben Türkiye de doğdum” ...” Akıcı bir şekilde **Türkçe** konuşabilirim” gibi birbirinden bağımsız iki cümleden yol çıkarak aranan metnin bir dil olacağı tahmin edilebilir, fakat **Türkçe** kelimesi olduğunu tahmin etmek imkânsız yakındır. Bu durumlarda uzun kısa süreli bellek (Long Short-Term Memory-LSTM) algoritması olarak adlandırılan RNN modellemesinin bir türü olan derin öğrenme modeli kullanılabilir. LSTM, değerleri rastgele aralıklarla hatırlayan ve ileri beslemeli sinir ağlarının aksine geri besleme bağlantıları olan yapay bir tekrarlayan sinir ağı mimarisidir. LSTM modellemesi görüntü işleme ek olarak konuşma veya video gibi tümleşik veri dizilerini de oldukça başarılı bir şekilde işleyebilmektedir. Şekil 10’da LSTM hücresinin diyagram detayları gösterilmiştir.



Şekil 10: Herhangi bir t anında genel LSTM hücresinin diyagramı


LSTM diyagramında yer alan “Giriş Kapısı (I)” giriş verilerinin iletimini, “Unutma Kapısı (f)” önceki bloktan gelen verinin ne kadarının bellekte kalıp ne kadarının unutulacağını, “Aday bellek (Ç)” yeni bilgi oluşumunun uyarılmasını ve son olarak “Çıkış Kapısı (O)” çıkış verisinin hesaplanmasını ve iletilmesini sağlar. Bu kapılardan [0,1] aralığında çıktı elde etmek için sigmoid, [-1,1] aralığında çıktı elde etmek için de tanjant fonksiyonlarını kullanırlar. LSTM modeli resimleri tarayarak otomatik başlık oluşturma, sessiz videolar için otomatik ses oluşturma, cümle taraması yaparak otomatik kelime üretme [40], düzensiz dillerde öğrenme [41], robotik kalp cerrahisinde [42] ve birçok alanda kullanılmıştır.

4.4. Sınırlı Boltzman Makineleri

Sınırlandırılmış bir Boltzmann Makinesi (Restricted Boltzmann Machines-RBM), giriş veri seti üzerindeki olasılık dağılımlarını öğrenebilen, derin öğrenme ağlarının temelini oluşturan iki katmanlı rastlantısal bir yapay sinir ağıdır. Bu katmanlar görünür katman ve gizli katman olarak adlandırılır. Görünür katman giriş verilerinin verildiği katmandır. Gizli

katman ise her düğüm için derin öğrenme hesaplamalarının gerçekleştiği katmandır. Nöron benzeri bir birimi temsil eden her bir düğüm katmanlar üzerinde bulunur ve aynı katmandaki düğümler arasında bağlantı bulunmaz. Farklı katmanlarda bulunan düğümler arası bağlantı mevcuttur [43]. Giriş ve çıkış düğümleri sayısal olarak sınırlandırılmamıştır.

Görünür katmandaki bulunan düğümlere RBM ile eğitilecek olan veri kümesinden bir öznitelik alınır. Görünür katmanda bulunan bütün katmanlara aktarılan bu öznitelik gizli katmanda bulunan bir düğüme iletilerek gerekli hesaplamalara tabi tutulur. Bu işlemler bütün katmanlarda bulunan düğümlere uygulanır. Gizli katman çıktılarına belirlenen bir aktivasyon algoritması uygulanır. Bu yapı daha detaylı bir sinir ağının parçasıysa iki katman yerine daha çok gizli katmana sahip bir RBM modellemesi yapılır. Bir numaralı gizli katmanın çıkış verileri, iki numaralı gizli katmanın giriş verileri olarak ve son sınıflama katmanına ulaşmaya kadar istenilen sayıda gizli katmandan geçirilir. Şekil 11’de RBM algoritmasının işlem adımları gösterilmiştir.




Şekil 11: RBM algoritmasının işlem adımları

RBM modeli; Boyut azaltma [44], kümeleme [45], özellik öğrenimi [46], işbirlikçi filtreleme [42] ve konu modelleme [47] gibi çeşitli uygulamalarda kullanılabilir.

4.5. Derin Oto Kodlayıcılar

Derin Oto Kodlayıcılar (Autoencoders -AE) denetimsiz öğrenme yöntemlerinde sıklıkla kullanılan, girdi katmanındaki verileri çıktı katmanına kopyalayan ve literatürde Diablo ağı olarak bilinen bir sinir ağı modelidir [24], [48]. Buradaki amaç giriş olarak verdiğimiz veriyi sıkıştırarak en az kayıp ile en iyi öğrenmeyi gerçekleştirmek ve giriş verimizi çıktı katmanında tekrar oluşturmaktır. AE modeli temel olarak girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. Giriş katmanındaki nöron sayısı çıkış katmanındaki nöron sayısına eşit olmalıdır. Gizli katmanda bulunan nöron sayıları değişkenlik gösterebilir.

Şekil 12’de derin oto kodlayıcı algoritma şeması görülmektedir. Giriş ve çıkış katmanlarında bulunan düğümler (nöronlar) gizli katmandaki düğümlerden fazla ise veri kümesi sıkıştırılır. Bu şekilde daha az verinin ağı içerisinde yer alması sağlanır. Bu durum ağın performansını olumlu etkilemektedir. Girdi ve çıktı arasındaki benzerlik algoritmada kullanılan fonksiyonun başarılı olduğunu ispatlar [49].



Şekil 12: Derin oto kodlayıcı algoritma şeması

Bir derin oto kodlayıcının amacı, genel olarak boyutun indirgenmesi amacıyla veri kümesi için bir kodu eğitmek ve N boyutlu bir öznelik vektörünü daha küçük boyutlu bir vektöre minimum kayıpla dönüştürmektir. Boyutsal ışın azaltılmasının yanı sıra otomatik kodlayıcılar, veri sıkıştırma, gürültü giderme [50] ve bir denetimli öğrenme modeli için öznelik çıkartma algoritması olarak kullanılabilir.

5. Derin Öğrenme ve Yapay Sinir Ağı Modellerinin Kullanım Alanları

Derin öğrenme ve yapay sinir ağları modelleri gelişen teknolojiye paralel olarak hayatımızda epeyce yer edinmeye başlamıştır [29]. Doğal dil işleme, sinyal işleme, görüntü işleme, bilgisayarlı görü, sağlık ve robotik gibi birçok alanda kendine yer bulan derin öğrenme, genel olarak günümüz mühendislik uygulamalarında insan gibi düşünen, insan gibi davranışlar sergileyen uygulamalarda da tercih edilmektedir. Büyük veri tabanlarına ve bu verileri hesaplama gücüne sahip büyük teknoloji firmaları (Google, Apple, Facebook, Microsoft, Nvidia, Tesla, Bosch, Mercedes, Baidu vb.) tarafından da kullanılıp ürünlerine uygulanan derin öğrenme yaşantımızın her alanında bize eşlik etmeye devam etmektedir. Bu bağlamda Tablo 1’de günümüzde bu alana öncülük edebilecek güncel akademik çalışmalar belirtilmiştir.

Tablo 1: Güncel çalışmalar

Yıl	Konu	Yazar
2021	İş Sağlığı ve Güvenliği	[51]
2019	Cerrahi Robotlar	[52]
2023	Robotik Sistemler	[52]
2021	Güç Elektroniği Sistemleri	[53]
2020	Görüntü İşleme	[54]
2023	Batarya Yönetim Sistemleri	[55]
2020	PV Panel ve Süper Kapasitör Sistemleri	[56]
2023	Beyin Tümörlerinin Sınıflandırılması	[57]
2022	Siber Güvenlik Duvarı Sistemi	[58]
2021	Maksimum Güç Noktası Takip Sistemleri	[59]
2023	Elektrikli Araçlar	[60]

5.1. Oyun ve Eğlence

2014 yılında Google ekibine katılan Deepmind şirketinin geliştirdiği AlphaGo yazılımı Go oyununda (Çinlilere ait eski bir strateji oyunu) büyük bir başarı elde etti. 2017 yılından önce AlphaGo yazılımında bilgiler, hamleler ve analiz verileri, yazılımcı tarafından sisteme entegre ediliyordu. Fakat 2017 yılında AlphaGo’nun bir üst sürümü olan, Şekil 13’te gösterilen temsili resimde belirtilen şekilde, AlphaGo-Zero’nun piyasaya sürülmesi birçok alışılmışlığı ve bilgi için insana olan ihtiyacı ortadan kaldırdı. Temel eğitim süreçlerinden sonra asla müdahale edilmeyen bu sistem eski sürümüyle yaptığı yaklaşık 100 maçın hepsini kazandı. AlphaGo-Zero kendi kendine veri topluyor ve bu verileri işleyerek hamle yapıyor [61].



Şekil 13: AlphaGo-Zero temsili gösterimi [61]

5.2. Fotoğrafçılık ve Görüntü İşleme

Derin öğrenmenin bir diğer kullanım alanı da resim görüntü renklendirmedir. Gri tonlamalı görüntü girdi olarak alınır ve renklendirilmiş görüntü çıktı olarak elde edilir. Resmin karmaşıklığı ve renk çeşidine göre katman sayısı ve algoritmalar değişkenlik gösterebilir. Şekil 14’te ChromaGAN modeli kullanılarak yapılan bir renklendirme gösterilmiştir. Bu tarz renklendirmelerde resim kalitesi renklendirme kalitesini de arttırmaktadır. Çünkü görüntü işleme basamakları piksel boyutunda ki verileri işleyerek sonuç elde etmektedir [62].



Şekil 14: ChromaGAN modeli kullanılarak yapılan örnek çalışma [62]

ImageNet büyük ölçekli görsel tanıma yarışması(ILSVRC) 2012 yılından beri her yıl düzenlenmektedir. Bu yarışmadaki amaç en az hata oranını elde eden derin öğrenme mimarisini tasarlamaktır. Bu yarışmaya birçok büyük şirket, üniversite araştırmacıları ve tasarımcılar katılmaktadır. Tablo 2’de 2012-2021 yılları arasında gerçekleşen yarışmayı kazanan derin öğrenme mimarileri, tasarımcıları ve doğruluk oranları belirtilmiştir.

Tablo 2: Derin öğrenme modelleri ImageNet yarışma sonuçları [63]

Yıl	Derin Öğrenme Modeli	Tasarımcı	Doğruluk Oranı (%)
1998	Le Net	Yann LeCun	
2012	Alex Net	Alex Krizhevsky Geoffrey Hinton Ilya Sutskever	83,6
2013	ZF Net	Matthew Zeiler Rob Fergus	88,2
2014	Google Net	Google	94,3
2014	Vgg Net	Simonyan Zisserman	92,7
2015	Res Net	Kaiming He	96,4
2016	DRS Net	Deargen Company	96,5
2017	Se Net	Oxford	97,7
2018	PNAS Net	Johns Hopkins Google AI Standford	96,2
2019	FixPNAS Net-5	Hugo Touvron Andrea Vedaldi Matthijs Douze	96,8
2020	Harm-SE-RNX-101 64x4d	Vladimir Krylov Rozenn Dahyot Matej Ulicy	96,4
2021	NF Net-F5	Andrew Brock Samuel Smith Karen Simonyan Soham De	97,6

Bu mimarilerden AlexNet modeli 2012 yılında gerçekleştirilen ILSVRC ImageNet görsel tanıma yarışmasında %83,6 doğruluk oranı elde etmiştir [64]. Doğrusal olmayan fonksiyonlar için Tanh fonksiyonu yerine Relu kullanılarak hız altı kat artırılmış ve eğitim süresi kısaltılmıştır. 2014 yılında gerçekleştirilen ILSVRC ImageNet yarışmasını 22 katman derinliğine ve 144 katmana sahip GoogleNet 94,3% doğruluk oranı ile kazanmıştır. GoogleNet 5 milyon parametre kullanarak AlexNet'e kıyasla 12 kat daha az işlem yüküne sahip olmuştur [65]. Aynı yarışmada VggNet 92,7% doğruluk oranı yakalamıştır. VggNet modeli için 11,13,16 ve 19 katmanlı versiyonlar tasarlanmıştır [66]. Önceki derin öğrenme mimarilerinden farklı olarak yalnızca 2x2 ve 3x3 filtreler kullanılmıştır. 2015 yılında gerçekleştirilen ILSVRC ImageNet yarışmasını 96,4% doğruluk oranı yakalayarak Microsoft ResNet kazanmıştır (Bir insan bir görüntüyü 90-95% doğruluk oranlarıyla sınıflandırabilmektedir). ResNet daha önceki modellerde kullanılanlardan daha fazla sayıda katman kullanmıştır [67].

5.3. Araştırma ve Sohbet Robotları

Bu alanda günümüzde ön plana çıkan uygulamalar yapay zekâ tabanlı arama ve sohbet robotlarıdır. Özellikle ChatGPT, İntercom, Hubspot, Bard ve Genie gibi onlarca programlar oluşturulmuştur. Bu programlardan her biri kendi yapay sinir ağı modelini oluşturmakta ve eğitmektedir. Bu programlar sayesinde kullanıcılar araştırmalar, çeviriler, slaytlar, sunumlar, proje ödevleri ve daha nice aklımıza gelebilecek kütüphanelerde ve kitaplardan saatlerce hatta haftalarca

ulaşacağımız ya da hazırlayacağımız bilgilere saniyeler içinde ulaşabilmektedir. İnanılmaz bir veri havuzuna sahip bu sistemler her salisede bilgi dağarcığını genişletmekte ve kendi yapay zekâ tabanlarını geliştirmektedir. Özellikle Open AI tarafından geliştirilen ChatGPT sohbet robotunun popüleritesi günümüzde giderek artmaktadır. Bu sistemlerin yararlarından çok zararları olacağı da tartışılmakta ve gerekli güvenlik önlemleri alınması için uluslararası kararlar alınmaktadır.

5.4. Güvenlik ve Tespit Sistemleri

2023 yılında meydana gelen depremler ve sonrasında yapılan hasar tespit çalışmaları derin öğrenme konusunun bu alanlardaki gelişimini ve şu anki katkısını ön plana çıkarmıştır. Havadan çekilen görüntüler, konvolüsyonel yapay sinir ağında kullanılarak hasar tespit çalışmaları açısından kolaylık sağlayabilmektedir[68]. Aynı zamanda yer yapısı, sismik dalgalar, bulunulan ana kaya yapısı, iklimsel değişiklikler, yer altı ve üstü beşeri çalışmalar gibi veriler kullanılarak deprem öncesi uyarı sistemleri geliştirilebilmektedir [69], [70]. Her ne kadar depremin gerçekleşme süresi göz önüne alındığında erken uyarı sistemlerinin insanların kaçışı için zaman kazandıracak boyutta olmayacağı düşünülse de anlık olarak gelen uyarı ile doğalgaz ve elektrik gibi sistemler kapatılarak olası kayıpların azaltılması sağlanabilecektir.



Şekil 15: Türkiye'nin bazı bölgelerinin uzaydan tespit edilen deprem hasar haritası [71]

5.5. Sağlık


2020 yılında sağlık alanında yapılan bir çalışmada EKG (Elektrokardiyografi) sinyallerinin konvolüsyonel sinir ağları modellenmesine dayanan bir derin öğrenme çalışması yapılmıştır. Bu çalışma ile kalp ritminde anormallik oluşmasına sebep olan aritmi verileri kullanılmıştır. Bu veriler iki boyutlu resimlere dönüştürülerek konvolüsyonel sinir ağları ile modellenmiştir. Çalışmada LeNet mimarisi kullanılmıştır. Bu çalışma ile daha kısa zamanda aritmi tespiti yapılmıştır [72].

5.6. Ekonomi ve Finans

Çağımızın en büyük sorunlarından biri olan küresel ekonomi gerek pandemi gerek depremler ve gerekse artan enflasyon nedeniyle ağır bir yara almıştır. Gün geçtikçe artan hayat pahalılığına karşın insanlar borsa ve kripto para gibi günümüzde anlık olarak çok miktarda getirisi ve götürüsü olan sistemlere yönelmiştir. Piyasa endekslerinin tahmini ve trend tespiti için algoritmalar hazırlanarak risk analizleri yapılmıştır [73]. Aynı zamanda kripto paralar için fiyat tahmini yapan sistemler geliştirilmektedir [74]. Her ne kadar birçok başarılı çalışma bulunsada da bu şekildeki çalışmalar dikkate alınarak yatırımlar yapılmamalıdır.

5.7. Robotik Sistemler

Derin öğrenmenin en kullanışlı alanlarından biride robotik ve otonom uygulama alanlarıdır. Özellikle insansı robot tasarlamak ve derin öğrenme yöntemlerini kullanarak insana ait birçok özelliği tasarlanan bu robotlara uyarlamak birçok firma gibi Boston Dynamics adlı şirketinde ilk hedeflerinden biri haline gelmiştir. Şu ana kadar ürettiği Spot (köpek robot), Handle (tekerlekli robot), Pick (endüstriyel robot), Bigdog (büyük köpek robot) ve Atlas (insansı robot) firmanın hedeflerine ulaştığını göstermektedir. Bu çalışmaların daha ileri seviyelere getirilmesi toplum için ne tür kolaylıklar ya da tehlikeler getireceği tartışma konusu olarak gündemdeki yerini korumaktadır. En dinamik ve en gelişmiş kontrol sistemlerine sahip olan insansı robot Atlas, tasarlanan algoritmalar sayesinde hareketlerini planlayıp, tüm vücudunu ve çevreyi analiz ederek verilen görevi yerine getirebilmektedir. Şekil 16'da Boston Dynamics firmasının ürettiği robotlar gösterilmiştir.



Şekil 16: Boston Dynamics firmasının ürettiği robotlar [75]

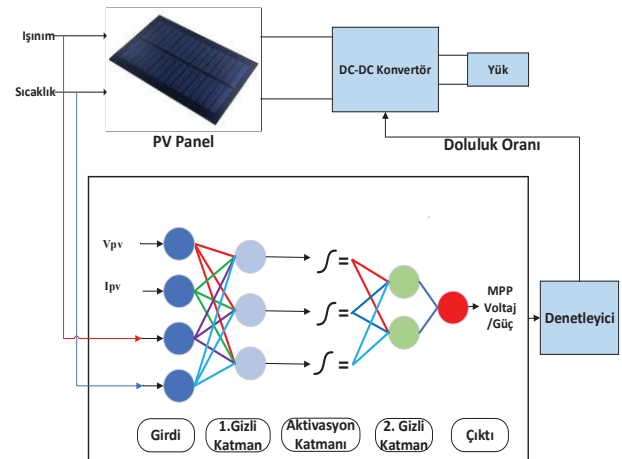
Otonom alanında ise 2015 yılından sonra büyük araba üreticileri (Tesla, Volvo, Mercedes, Nissan, Honda, Audi) 2020'li yılları kendilerine hedef koyarak birçok çalışma yürütmüştür. Bu firmalardan en ileri düzeyde sonuçlar elde eden Tesla firması tam otonom sürüş (Full Self Driving-FSD) adını verdiği tamamen elektrikli (kamaralar, sensörler) ve yapay zekâ odaklı araçlarını günümüzde piyasaya sürmekte ve halen test çalışmaları yaparak yeni güncellemeler geliştirmektedir. 2023 yılı itibarıyla 2. ve 3. seviye (sürücü kontrolünde) sürüşleri yapılan araçların 5.seviye (tam otonom) aşamasının tamamlanması 2026 yılını bulacağı belirtilmektedir. Bu çalışmalar Tesla tarafından tamamen otonom olarak düşünülse de araç sahiplerinin her an müdahale edecek şekilde hazır olmaları gerekliliği konusunda uyarılarda da bulunmaktadır.

5.8. Yapay Zekâ Tabanlı MPPT Sistemleri

Yenilenebilir enerji kaynaklarından olan fotovoltaik sistemler son zamanlarda enerji üretimi alanında söz sahibi olmaya başlamıştır. Gerek iklimsel şartlar gerekse arazi yapısının elverişliliği bu yöntemin ülkemizde kullanımını

yaygınlaştırmıştır. Bu sistemlerin en büyük dezavantajları sıcaklık, güneşlenme, gölgelenme ve maliyet yönünden kaynaklanmaktadır. Bu olumsuzluklar ise fotovoltaik sistemler için en önemli detay olan verimi etkilemektedir. Fotovoltaik sistemlerdeki verim kontrolü geleneksel yöntemlerle yapıldığı gibi son zamanlarda günümüz uygulamalarında çoğunlukla tercih edilen yapay zekâ tabanlı yöntemlerde tercih edilmeye başlanmıştır. Yapay zekâ tabanlı MPPT sistemlerinin geleneksel yöntemlere göre en büyük avantajı değişken hava şartlarına uyum sağlayabilmesi ve yüksek verim oranı elde edebilmesidir [76].

Yapay sinir ağı (YSA) modelleri genel olarak sıcaklık, ışınım, gölgelenme ve güneşlenme sürelerini dikkate alarak bir model oluşturmayı amaçlamaktadır. Şekil 17'de de gösterildiği üzere saydığımız bu nitelikler giriş verileri olarak kullanılır ve çıkış olarak doluluk oranı elde edilir. Bu oran elde edilirken girişte kullanılan veri setleri belirlenen YSA algoritmasında, istenilen sayıda ve istenilen boyutta, belirlenen katmanlarda (girdi, gizli, bellek, fonksiyon vb. katmanlar) eğitilir ve çıkan sonuçlar test algoritmaları ile test edilir. Elde edilen sonuçlar sürekli ve anlık olarak değişen çevresel koşullarda bile sistemlerin yüksek verimlerde çalışmasını sağlamakta ve birim zamanda elde edilen enerji miktarını maksimum seviyede tutmaktadır. Aynı zamanda sistemin stabil çalışmasını sağlayarak elektronik parçaların ömrünü uzatmakta ve maliyet açısından da avantaj sağlamaktadır. Maksimum güç noktası takip sistemi ve algoritmaları güneş panellerinde kullanıldığı gibi anlık değişen rüzgar hızı koşullarında bile maksimum seviyede verim elde edebilmek için rüzgar türbinlerinde de kullanılmaktadır [77].



Şekil 17: Yapay sinir ağları ile MPPT algoritması

Bu sistemlerin genel olarak güç elektroniği tabanlı sistemlerde (dönüştürücüler, motor kontrol devreleri, makine otomasyonları, güç kaynakları ve kontrol sistemleri, iklimlendirme, enerji üretim ve iletim sistemleri, vb.[78]) tercih edilmesinin sebebi oluşabilecek arızaların tespiti, anlık dalgalanmalar, reaktif güç ve iletim kayıpları gibi hem sistemi olumsuz etkileyecek hem de ekonomik yönden kayıpların yaşanmasına sebep olacak olumsuzlukların önüne geçilmesidir.

6. SONUÇ

Bu çalışmada makine öğrenmesinin bir alt dalı olarak kullanılmaya başlanan derin öğrenme ve yapay sinir ağları modelleri ele alınmıştır. Tarihsel olarak yapay zekâ, makine öğrenmesi ve derin öğrenme aşamaları irdelenmiştir. Günümüzde kendi çalışma alanını oluşturan ve bu alanda ilgiyi hak edecek seviyede bir gelişim gösteren derin öğrenme, özellikle yapay zekâ alanının devamı olarak günümüz teknolojisiyle çok iyi bütünleşmiştir. Derin öğrenme sistemlerinde kullanılan yapay sinir ağları modellerinden CNN, RNN, RBM, LSTM ve derin oto kollayıcılarının tanımlamaları, çalışma metodları ve kullanım alanları belirtilmiştir. Bir literatür taraması yapıp en güncel uygulamalar ve çalışmalar hakkında genel bilgiler ve gelişmeler aktarılmıştır.

Sonuç olarak tüm bu gelişmeler ve çalışmalar göz önünde bulundurulduğunda hızla gelişen derin öğrenme ve yapay sinir ağları konusunun artık yaşantımızın vazgeçilmez bir parçası olmaya doğru ilerlediğini görmekteyiz. Evimizde, iş yerimizde, sokakta hemen hemen her yerde yaşantımıza dokunmaya başlayan ve geliştirilebilir olması dolayısıyla yeniliklere daima açık olan derin öğrenme tabanlı uygulamalar, insanı taklit etmeyi bırakıp tamamen insan gibi düşünmeye ve hareket etmeye başlayacağı zaman getireceği tüm olumlu-olumsuz yönler şimdiden ele alınmalıdır. Tüm bu sistemlerin tek amacının canlı yaşamını kolaylaştırma olduğu unutulmamalıdır. Aynı zamanda bu çalışmada da belirtildiği gibi uygulama alanlarının genişliği ve yapılan çalışmalardan yola çıkarak derin öğrenme ve yapay zekâ konuları her yaş grubuna ulaşmalı ve bu yönde yatırımlar yapılmalıdır.

Kaynaklar

- [1] M. Copeland, “What’s the difference between artificial intelligence, machine learning and deep learning.”, 2016. <https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/> (Erişim zamanı; 10.15.2022).
- [2] L. Deng ve D. Yu, “Deep learning: Methods and applications”, *Found. Trends Signal Process.*, c. 7, sayı 3–4, ss. 197–387, 2013.
- [3] A. A. Süzen ve K. Kayaalp, *Derin Öğrenme ve Türkiye’deki Uygulamaları*, sayı September. 2018.
- [4] J. Fürnkranz, “Separate-and-Conquer Rule Learning”, ss. 3–54, 1999.
- [5] Y. Lecun, Y. Bengio, ve G. Hinton, “Deep learning”, *Nature*, c. 521, sayı 7553, ss. 436–444, 2015.
- [6] W. S. McCulloch ve W. Pitts, “A logical calculus of the ideas immanent in nervous activity”, *Adv. Intell. Syst. Comput.*, c. 867, ss. 786–798, 1943.
- [7] D. Hubel ve T. Wiesel, “Receptive fields of single neurones in the cat’s striate cortex”, *J. Physiol.*, c. 148(3), 57, sayı 12, ss. 574–591, 1959.
- [8] H. J. Kelley, “Gradient Theory of Optimal Flight Paths”, *ARS J.*, c. 30, sayı 10, ss. 947–954, 1960.
- [9] A. Ivakhnenko, “Cybernetic predicting devices”, sayı September, 1966.
- [10] K. Fukushima, “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position”, *Biol. Cybern.*, c. 36, sayı 4, ss. 193–202, 1980.
- [11] S. Aras, “Yapay sinir ağlarıyla zaman serisi tahminlemede yeni bir model seçim stratejisi”, 2013.
- [12] C. R. Rosenberg ve T. J. Sejnowski, “The spacing effect on NETtalk, a massively parallel network”, *Proc. Eighth Annu. Conf. Cogn. Sci. Soc.*, ss. 72–89, 1986.
- [13] S. Hochreiter ve J. Schmidhuber, “Long Short-Term Memory”, *Pak. J. Zool.*, c. 50, sayı 6, ss. 2199–2207, 1997.
- [14] Y. Lecun, L. Bottou, Y. Bengio, ve P. Haffner, “Gradient-Based Learning Applied to Document Recognition”, *Biochem. Biophys. Res. Commun.*, c. 330, sayı 4, ss. 1299–1305, 1998.
- [15] L. Fei-Fei, J. Deng, ve K. Li, “ImageNet: Constructing a large-scale image database”, *J. Vis.*, c. 9, sayı 8, ss. 1037–1037, 2010.
- [16] Y. Taigman, M. Yang, M. Ranzato, ve L. Wolf, “DeepFace: Closing the gap to human-level performance in face verification”, *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, ss. 1701–1708, 2014.
- [17] Z. Yu, K. Wang, Z. Wan, S. Xie, ve Z. Lv, “Popular deep learning algorithms for disease prediction: a review”, *Cluster Comput.*, c. 26, sayı 2, ss. 1231–1251, 2023.
- [18] F. Demir, “Ultrason RF Sinyallerinden Göğüs Kanserinin Derin Öğrenme Tabanlı Yaklaşımlarla Tespit Edilmesi”, *Fırat Üniversitesi Mühendislik Bilim. Derg.*, c. 34, sayı 2, ss. 761–768, 2022.
- [19] A. M. N. Erdoğan, T. Öztürk, ve M. Talo, “Yeni bir Evrişimsel Sinir Ağı Modeli Kullanarak Bilgisayarlı Tomografi Görüntülerinden Akciğer Kanseri Tespiti”, c. 34, sayı 2, ss. 795–802, 2022.
- [20] K. A. Joseph, C. Joshua Sony, L. Rajkumar, S. Krishna, A. Francis, ve A. Babu, “Deep Learning based Beach Cleaning Robot”, *2023 2nd Int. Conf. Appl. Artif. Intell. Comput.*, sayı Icaaic, ss. 427–433, 2023.
- [21] M. Haris ve A. Glowacz, “Road object detection: a comparative study of deep learning-based algorithms”, *Multimed. Tools Appl.*, c. 81, sayı 10, ss. 14247–14282, 2022.

- [22] F. Yin, J. Du, X. Xu, ve L. Zhao, "Depression Detection in Speech Using Transformer and Parallel Convolutional Neural Networks", *Electron.*, c. 12, sayı 2, ss. 1–16, 2023.
- [23] N. Jing, Z. Wu, ve H. Wang, "A hybrid model integrating deep learning with investor sentiment analysis for stock price prediction", *Expert Syst. Appl.*, c. 178, sayı April, s. 115019, 2021.
- [24] Y. Bengio, *Learning deep architectures for AI*, c. 2, sayı 1. 2009.
- [25] H. A. Song ve S. Y. Lee, "Hierarchical representation using NMF", *Lect. Notes Comput. Sci.*, c. 8226 LNCS, sayı PART 1, ss. 466–473, 2013.
- [26] S. Wang, "Artificial Neural Network. In: Interdisciplinary computing in java programming", *Springer Int. Ser. Eng. Comput. Sci.*, c. 743, ss. 39–55, 2003.
- [27] A. M. Alsugair ve A. A. Al-Qudrah, "Artificial neural network approach for pavement maintenance", *J. Comput. Civ. Eng.*, c. 12, sayı 4, ss. 249–255, 1998.
- [28] S. W.S., "Neural Networks FAQ's", 1997.
- [29] K. Ozturk ve M. Şahin, "Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış", *Tak. Vekayi*, c. 6, sayı 2, ss. 25–36, 2018.
- [30] D. Hubel and T. Wiesel, "Receptive fields and functional architecture of monkey striate cortex", *J. Physiol.*, c. 195, sayı 1, ss. 215–243, 1968.
- [31] W. Hu, Y. Huang, L. Wei, F. Zhang, ve H. Li, "Deep convolutional neural networks for hyperspectral image classification", *J. Sensors*, c. 2015, 2015.
- [32] E. Gavcar ve H. M. Metin, "Hisse Senedi Değerlerinin Makine Öğrenimi (Derin Öğrenme) İle Tahmini", c. 10, sayı 2, ss. 1–11, 2021.
- [33] D. Bahdanau, K. H. Cho, ve Y. Bengio, "Neural machine translation by jointly learning to align and translate", *3rd Int. Conf. Learn. Represent. ICLR 2015*, ss. 1–15, 2015.
- [34] A. Karpathy ve L. Fei-Fei, "Deep Visual-Semantic Alignments for Generating Image Descriptions Andrej", *Am. Lit. Transition, 2000-2010*, ss. 152–164, 2014.
- [35] C. L. Giles, S. Lawrence, ve A. C. Tsoi, "Noisy time series prediction using recurrent neural networks and grammatical inference", *Mach. Learn.*, c. 44, sayı 1–2, ss. 161–183, 2001.
- [36] A. M. Rush, S. Chopra, ve J. Weston, "A Neural Attention Model for Sentence Summarization Alexander", *Inov. Pendişik. Fis.*, c. 5, sayı 3, ss. 379–389, 2015.
- [37] Y. Shkarupa, R. Mencis, ve M. Sabatelli, "Offline Handwriting Recognition Using LSTM Recurrent Neural Networks", *Int. J. Adv. Res.*, c. 4, sayı 2, ss. 1541–1545, 2016.
- [38] T. Mikolov, M. Karafiat, L. Burget, J. Honza, ve S. Khudanpur, "Recurrent neural network based language model", *Proc. Annu. Meet. Assoc. Comput. Linguist.*, sayı September, ss. 8093–8104, 2010.
- [39] Y. Bengio, P. Simard, ve P. Frasconi, "Learning Long-Term Dependencies with Gradient Descent is Difficult", *Pediatr. Catalana*, c. 66, sayı 2, ss. 53–61, 1994.
- [40] Z. Cao, F. Wei, L. Dong, S. Li, ve M. Zhou, "Ranking with recursive neural networks and its application to multi-document summarization", *Proc. Natl. Conf. Artif. Intell.*, c. 3, ss. 2153–2159, 2015.
- [41] J. Schmidhuber, F. Gers, ve D. Eck, "Learning nonregular languages: A comparison of simple recurrent networks and LSTM", *Neural Comput.*, c. 14, sayı 9, ss. 2039–2041, 2002.
- [42] R. Salakhutdinov, A. Mnih, ve G. Hinton, "Restricted Boltzmann Machines for Collaborative Filtering", *Nonlinear Anal. Real World Appl.*, c. 10, sayı 5, ss. 2700–2708, 2007.
- [43] G. E. Hinton, "A practical guide to training restricted boltzmann machines", *Lect. Notes Comput. Sci.*, c. 7700 LECTU, ss. 599–619, 2012.
- [44] G. E. Hinton ve R. Salakhutdinov, "Reducing the Dimensionality of Data with Neural Networks", c. 313, sayı July, ss. 504–507, 2006.
- [45] H. Larochelle ve Y. Bengio, "Classification using discriminative restricted boltzmann machines", *Proc. 25th Int. Conf. Mach. Learn.*, ss. 536–543, 2008.
- [46] A. Coates, H. Lee, ve A. Y. Ng, "An analysis of single-layer networks in unsupervised feature learning", *J. Mach. Learn. Res.*, c. 15, ss. 215–223, 2011.
- [47] R. Salakhutdinov ve G. Hinton, "Replicated Softmax: an Undirected Topic Model", ss. 1–8, 2009.
- [48] X. Lu, Y. Tsao, S. Matsuda, ve C. Hori, "Speech enhancement based on deep denoising autoencoder", ss. 436–440, 2013.
- [49] P. Vincent, H. Larochelle, Y. Bengio, ve P. A. Manzagol, "Stacked denoising autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion", *J. Mach. Learn. Res.*, c. 11, ss. 3371–3408, 2010.
- [50] O. Kaynar, H. Arslan, Y. Görmez, ve Y. E. Işık, "Makine Öğrenmesi ve Öznitelik Seçim Yöntemleriyle Saldırı Tespiti", *Bilişim Teknol. Derg.*, c. 11, sayı 2, ss. 175–185, 2018.
- [51] İ. Topaloğlu ve M. E. Şahin, "Endüstri 4.0'ın İş Sağlığı ve Güvenliğine Katkıları ve Hata Türü ve Etkileri Analizi Risk Değerlendirme Metoduyla Ambulansta Bir İnceleme", *Tak. vekayi*, ss. 66–94, 2021.

- [52] M. Soori, B. Arezoo, ve R. Dastres, “Artificial intelligence, machine learning and deep learning in advanced robotics, a review”, *Cogn. Robot.*, c. 3, sayı April, ss. 54–70, 2023.
- [53] S. Zhao, F. Blaabjerg, ve H. Wang, “An overview of artificial intelligence applications for power electronics”, *IEEE Trans. Power Electron.*, c. 36, sayı 4, ss. 4633–4658, 2021.
- [54] L. Li, “Application of deep learning in image recognition”, *J. Phys. Conf. Ser.*, c. 1693, sayı 1, 2020.
- [55] V. S. R. Kosuru ve A. Kavasseri Venkitaraman, “A Smart Battery Management System for Electric Vehicles Using Deep Learning-Based Sensor Fault Detection”, *World Electr. Veh. J.*, c. 14, sayı 4, 2023.
- [56] M. E. Şahin ve F. Blaabjerg, “A hybrid PV-battery/supercapacitor system and a basic active power control proposal in MATLAB/simulink”, *Electron.*, c. 9, sayı 1, ss. 1–17, 2020.
- [57] F. Uysal ve M. Erkan, “Evrşimsel Sinir Ağları Temelli Derin Öğrenme Modelleri Kullanılarak Beyin Tümörü Manyetik Rezonans Görüntülerinin Sınıflandırılması”, ss. 19–27, 2023.
- [58] K. Baysal, “Derin öğrenme temelli yeni nesil güvenlik duvarının tasarlanması”, sayı 8.5.2017, s. 2003, 2022.
- [59] H. İ. Temel, “Yapay zeka temelli maksimum güç noktası takibi”, 2021.
- [60] A. K. Venkitaraman ve V. S. R. Kosuru, “Hybrid Deep Learning Mechanism for Charging Control and Management of Electric Vehicles”, *Eur. J. Electr. Eng. Comput. Sci.*, c. 7, sayı 1, ss. 38–46, 2023.
- [61] L. Greenemeier, “AI versus AI: Self-Taught AlphaGo Zero Vanquishes Its Predecessor”, *Scientific American*, 2017. <https://www.scientificamerican.com/article/ai-versus-ai-self-taught-alphago-zero-vanquishes-its-predecessor/> (Erişim zamanı; 11.16.2022).
- [62] P. Vitoria, L. Raad, ve C. Ballester, “ChromaGAN: Adversarial picture colorization with semantic class distribution”, ss. 2434–2443, 2020.
- [63] “Image Classification on ImageNet”, *Paperswithcode*. <https://paperswithcode.com/sota/image-classification-on-imagenet/> (Erişim zamanı; 11.15.2022).
- [64] A. Krizhevsky, I. Sutskever, ve G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks”, *Handb. Approx. Algorithms Metaheuristics*, ss. 1–1432, 2012.
- [65] C. Szegedy, S. Ioffe, V. Vanhoucke, ve A. A. Alemi, “Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning”, *Pattern Recognit. Lett.*, c. 42, sayı 1, ss. 11–24, 2017.
- [66] K. Simonyan ve A. Zisserman, “Very deep convolutional networks for large-scale image recognition”, *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, ss. 1–14, 2015.
- [67] O. Russakovsky vd., “ImageNet Large Scale Visual Recognition Challenge”, *Int. J. Comput. Vis.*, c. 115, sayı 3, ss. 211–252, 2015.
- [68] E. E. Maraş ve H. İ. Sarıyıldız, “İHA ile Derin Öğrenme Algoritmaları Kullanılarak Hasarlı Yapıların Tespit Edilmesi”, *Afyon Kocatepe Univ. J. Sci. Eng.*, c. 23, sayı 2, ss. 427–437, May. 2023.
- [69] M. Kanber ve Y. Santur, “Time Series and Data Science Preprocessing Approaches for Earthquake Analysis”, *Eur. J. Sci. Technol.*, sayı 49, s. 12, 2023.
- [70] G. Boost, “Makine öğrenimi yöntemleri kullanılarak Türkiye ’ nin kuzeybatısı için deprem tahmini”, c. 44, sayı 2, 2023.
- [71] “Türkiye’nin uzaydan tespit edilen deprem hasar haritası”, 2023. <https://www.arkeolojikhaber.com/haber-turkiyenin-uzaydan-tespit-edilen-deprem-hasar-haritasi-36362/>
- [72] E. Izci, M. Degirmenci, M. A. Ozdemir, ve A. Akan, “Derin Öğrenme ile EKG Aritmi Tespiti”, *2020 28th Signal Process. Commun. Appl. Conf.*, ss. 1–4, 2020.
- [73] S. Perla, R. Bisoi, ve P. K. Dash, “A hybrid neural network and optimization algorithm for forecasting and trend detection of Forex market indices”, *Decis. Anal. J.*, c. 6, sayı January, s. 100193, 2023.
- [74] A. B. Wardak ve J. Rasheed, “Uzun Kısa Vadeli Bellek Tekrarlayan Sinir Ağı Kullanarak Bitcoin Kripto Para Birimi Fiyat Tahmini”, *Eur. J. Sci. Technol.*, ss. 47–53, 2022.
- [75] M. Han ve M. Sarazen, “Boston Dynamics Robodog Opens a Door, Owns the Internet”, 2018. <https://syncedreview.com/2018/02/13/boston-dynamics-robodog-opens-a-door-owns-the-internet/> (Erişim zamanı; 01.10.2023).
- [76] U. Younas, “Deep Learning LSTM-based MPPT Control of 100kW Dual Stage Grid Tied Solar PV System”, ss. 1–33, 2023.
- [77] D. Belkhiri, M. Ajaamoum, K. Cherifi, ve A. Elidrissi, “Artificial Intelligence-based MPPT Techniques in Wind Energy Systems: A Literature Review”, *2023 3rd Int. Conf. Innov. Res. Appl. Sci. Eng. Technol. 2023*, sayı May, 2023.
- [78] P. Qashqai, H. Vahedi, ve K. Al-Haddad, “Applications of artificial intelligence in power electronics”, *IEEE Int. Symp. Ind. Electron.*, c. 2019-June, ss. 764–769, 2019.

Özgeçmişler



Ercan Akın, 2017 yılında İnönü Üniversitesi Elektrik-Elektronik Mühendisliği bölümünden, lisans eğitimini tamamlayarak, mezun olmuştur. 2017 yılından beri Çay İşletmeleri Genel Müdürlüğü kurumunda çalışmaktadır. 2022 yılında Recep Tayyip Erdoğan Üniversitesinde Elektrik-Elektronik Mühendisliği Tezli Yüksek Lisans programına başlamıştır. Başlıca araştırma alanları güç elektroniği, yapay sinir ağları ve yenilenebilir enerji sistemlerinin modellenmesi ve kullanılmasıdır.



Mustafa Ergin Şahin, 2002 yılında Karadeniz Teknik Üniversitesi (KTÜ) Elektrik-Elektronik Mühendisliği bölümünden mezun olup lisans derecesini almıştır. Yüksek Lisans eğitimini 2003-2006 yılları arasında Ankara Gazi Üniversitesi, Elektrik Elektronik Mühendisliği Anabilim Dalında tamamlamıştır. Doktora eğitimini ise 2008-2014 yılları arasında Karadeniz Teknik Üniversitesi Elektrik Elektronik Mühendisliği Bölümünde tamamlamıştır. Aalborg Üniversitesi Enerji Teknolojileri Bölümünde TÜBİTAK 2219 doktora sonrası araştırma programı kapsamında misafir araştırmacı olarak bir yıl süreyle yer almıştır. Halen RTE Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünde doçent olarak görev yapmaktadır. Başlıca araştırma alanları güç elektroniği, kontrol, elektromanyetik kirlilik ve yenilenebilir enerjinin kullanımınıdır. Devre analizi ve ölçme ile elektronik laboratuvarı üzerine iki kitabın yazarıdır. Aynı zamanda bir uluslararası derginin de kurucusu ve editörüdür.