



T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

SAĞLIK BİLİŞİMİ ANABİLİM DALI
SAĞLIK BİLİŞİMİ YÜKSEK LİSANS PROGRAMI
YÜKSEK LİSANS TEZİ

**PSİKIYATRİK HASTALIKLARIN SINIFLANDIRILMASI VE
TEDAVİSİNDE AKILLI SİSTEM UYGULAMALARI**

Kübra ECE

Tez Danışmanı

Prof. Dr. Türker Tekin ERGÜZEL

İSTANBUL-2024

T.C.
ÜSKÜDAR ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

SAĞLIK BİLİŞİMİ ANABİLİM DALI
SAĞLIK BİLİŞİMİ YÜKSEK LİSANS PROGRAMI
YÜKSEK LİSANS TEZİ

**PSİKIYATRİK HASTALIKLARIN SINIFLANDIRILMASI VE
TEDAVİSİNDE AKILLI SİSTEM UYGULAMALARI**

Kübra ECE

Tez Danışmanı

Prof. Dr. Türker Tekin ERGÜZEL

İSTANBUL-2024

ÖZET

PSİKİYATRİK HASTALIKLARIN SINIFLANDIRILMASI VE TEDAVİSİNDE AKILLI SİSTEM UYGULAMALARI

Bu çalışmada yapay zekâ yöntemlerini kullanarak, majör depresif bozukluk, travma sonrası stres bozukluğu, bipolar, şizofreni, psikoz, dikkat eksikliği/hiperaktivite bozukluğu dahil olmak üzere belirli psikiyatrik hastalıkların erken tespit edilmesini ve sınıflandırmasını kolaylaştıran çalışmalar incelenmiştir. Bu çalışmalarda hangi yapay zekâ tekniklerinin kullanıldığı ve elde edilen sonuçların doğrulukları ile ilgili bilgiler verilmektedir.

Psikiyatrik hastalıkların semptomlarının birbirleri ile karıştırılma ihtimalinin yüksek olmasından ötürü doğru teşhis noktasında oluşan problemlere yapay zekâ yaklaşımları ile yaklaşan araştırmacıların yüksek doğruluk oranı elde etmiş olmaları umut verici bir durumdur. Doğru teşhisin konulması kişiyi doğru tedaviye yönlendirecektir.

Dünya için büyük bir yük olarak kabul edilen psikiyatrik hastalıkların doğru tedavi edilmesi bu yükü kaldırma noktasında yapay zekâ tekniklerinin iyi bir performans sergilediği yapılan araştırmalarla kanıtlanmıştır. Yapay Zekâ (YZ), bir bireyin psikiyatrik bir bozukluğa yakalanma olasılığını daha kesin bir şekilde değerlendirmeyi mümkün kılacak risk modellemeleri geliştirmek ve tanı tarama araçları oluşturmak konusunda önemli bir potansiyele sahiptir. Aynı zamanda Yapay zekâ teknikleri ile büyük veri setleri analiz edilebilir ve işlenebilir.

Anahtar Kelimeler: Psikiyatrik Hastalıklar, Psikoloji, Yapay Zekâ Teknikleri, Yapay Zekâ,

ABSTRACT

SMART SYSTEM APPLICATIONS IN THE CLASSIFICATION AND TREATMENT OF PSYCHIATRIC DISEASES

This study investigates the use of artificial intelligence (AI) methods to facilitate the early detection and classification of specific psychiatric disorders, including major depressive disorder, post-traumatic stress disorder, bipolar disorder, schizophrenia, psychosis, attention-deficit/hyperactivity disorder, among others. The research explores the AI techniques employed in these studies and provides information on the accuracy of the results obtained.

Given the high likelihood of symptoms of psychiatric disorders being confused with each other, researchers employing AI approaches to address the challenges in accurate diagnosis have achieved promising results in terms of high accuracy rates. Accurate diagnosis is crucial for guiding individuals towards appropriate treatment.

The effective use of AI techniques in research has been proven to be a promising avenue for lifting the substantial burden of psychiatric disorders globally. Artificial Intelligence (AI) has significant potential in developing risk models that more accurately assess an individual's likelihood of developing a psychiatric disorder and creating diagnostic screening tools. Simultaneously, AI techniques enable the analysis and processing of large datasets, contributing to a better understanding of psychiatric disorders.

Keywords: Artificial Intelligence Techniques, Artificial Intelligence, Psychiatric Diseases, Psychology,

TEŐEKKÜR

Bu alıőmanın gerekleőtirilmesinde, iki yıl boyunca deęerli bilgilerini benimle paylaőan, kullandıęı her kelimenin hayatıma kattıęı önemini asla unutmayacaęım saygıdeęer danıőman hocam; Prof. Dr. Tőrker Tekin ERGÜZEL'e, alıőmam boyunca benden bir an olsun yardımlarını esirgemeyen deęerli arkadaőlarıma ve alıőma süresince tüm zorlukları benimle göęüsleyen ve hayatımın her evresinde bana destek olan deęerli aileme sonsuz teőekkürlerimi sunarım.



BEYAN FORMU

Bu alıřmadaki bütn bilgi ve belgeleri akademik kurallar erevesinde elde ettiđimi, grsel, iřitsel ve yazılı tm bilgi ve sonuları bilimsel ahlak kurallarına uygun olarak sunduđumu, kullandıđım verilerde herhangi bir tahrifat yapmadıđımı, yararlandıđım kaynaklara bilimsel normlara uygun olarak atıfta bulunduđumu, tezimin kaynak gsterilen durumlar dıřında zgn olduđunu, tarafımdan retildiđini ve skdar niversitesi Sađlık Bilimleri Enstits Tez Yazım Kılavuzuna gre yazıldıđını beyan ederim

16.02.2024

KBRA ECE

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
BEYAN FORMU	iv
İÇİNDEKİLER	v
ŞEKİLLER DİZİNİ	vii
SİMGELER VE KISALTMALAR DİZİNİ	viii
1.GİRİŞ	1
2. GENEL BİLGİLER	2
2.1. Yapay Zekâ.....	2
2.1.1. Yapay zekâ nedir?	2
2.1.2. Yapay zekanın amacı nedir?.....	3
2.1.3. Yapay zekanın gelişim süreci	3
2.1.4. Yapay zekâ ve insan zekasının karşılaştırılması	5
2.1.5. Yapay zekanın geleceği	6
2.2. Yapay Zekâ Teknikleri	10
2.2.1. Bulanık mantık.....	10
2.2.1.1. Bulanık mantık nedir?.....	10
2.2.1.2. Bulanık kümeler.....	11
2.2.1.3. Bulanık mantık teorisinin avantajları.....	14
2.2.1.4. Bulanık mantık teorisinin dezavantajları	15
2.2.2. Yapay sinir ağları	15
2.2.2.1. Yapay sinir ağları nedir?	15
2.2.2.2. Yapay sinir ağlarının özellikleri	18
2.2.2.3. Yapay sinir ağlarının gelişim süreci	20
2.2.2.4. Yapay sinir ağlarının kullanım alanları	21

2.2.2.5. Yapay sinir ağlarının avantajları ve dezavantajları	23
2.2.3. Genetik algoritmalar	23
2.2.3.1. Genetik algoritmalar nedir?	23
2.2.3.2. Genetik algoritmaların gelişim süreci	25
2.2.3.3. Genetik algoritmaların geleneksel arama yöntemleriyle karşılaştırılması.....	26
2.2.3.4. Genetik algoritmaların avantajları	26
2.2.4. Derin öğrenme algoritmaları.....	27
2.2.4.1. Derin öğrenme algoritmalarının tanımı	27
2.2.4.2. Derin öğrenme yöntemleri	27
2.2.4.3. Derin öğrenme katmanları	29
2.2.4.4. Derin öğrenme algoritmaları.....	29
2.2.4.5. Derin öğrenmenin uygulama alanları	29
2.2.5. Karınca algoritmaları	30
2.2.5.1. Karınca kolonisi optimizasyonu tanımı	30
2.2.5.2. Karınca kolonisi optimizasyonu algoritmaları.....	32
2.2.5.3. Karınca kolonisi optimizasyonu algoritmalarının uygulandığı problemler.....	36
2.2.6. Psikiyatride yapay zekâ	37
2.2.6.1. Bulanık mantık.....	38
2.2.6.2. Yapay sinir ağları	45
2.2.6.3. Optimizasyon metotları.....	48
2.2.6.4. Derin öğrenme algoritmaları.....	49
2.2.7. Fiziksel hesaplamalı sistemler	54
2.2.7.1. Nöromorfik bilgisayarlar	54
2.2.7.2. Kuantum bilgisayarlar.....	61
3.GEREÇ VE YÖNTEM.....	67
4.SONUÇ VE ÖNERİLER.....	68
KAYNAKLAR.....	71

ŞEKİLLER DİZİNİ

Şekil 1: Klasik küme teorisi	12
Şekil 2: Bulanık küme teorisi	13
Şekil 3: Bulanık mantık sisteminin temel bileşenleri	13
Şekil 4: Üçgen, yamuk ve çan eğrisi üyelik fonksiyonları	14
Şekil 5: Nöron	16
Şekil 6: Biyolojik sinir hücresi ve yapay sinir ağı.....	17
Şekil 7: Biyolojik sinir sistemindeki bileşenleri ve yapay sinir ağındaki karşılıkları	17
Şekil 8: Yapay sinir ağı örneği	18
Şekil 9: Genetik algoritmaların adımları	25
Şekil 10: Gerçek karıncaların en kısa yolu bulması	31
Şekil 11: Tek köprülü yol seçim deneyi	31

SİMGELER VE KISALTMALAR DİZİNİ

- IBM:** International Business Machines
- ABD:** Amerika Birleşik Devletleri
- AI:** Yapay Zekâ
- AB:** Avrupa Birliđi
- YSA:** Yapay Sinir Ağları
- GA:** Genetik Algoritma
- CNN:** Konvolüsyonel Sinir Ağları
- RNN:** Tekrarlayan Sinir Ağları
- LSTM:** Long Short-Term Memory
- KKO:** Karınca Koloni Optimizasyonu
- KS:** Karınca Sistemi
- MMKS:** Maks-Min Karınca Sistemi
- MKKO:** Melez Karınca Kolonisi Optimizasyonu
- GKKO:** Global Karınca Kolonisi Optimizasyonu
- ANTS:** Karıncalar
- TSP:** Gezgin Satıcı Problemi
- BDI-II:** Beck Depresyon Envanteri-II
- ANFIS:** Adaptive Neuro-Fuzzy Inference System
- SAD:** Sosyal Anksiyete Bozukluđu
- DEHB:** Dikkat Eksikliđi ve Hiperaktivite
- fMRI:** Fonksiyonel manyetik rezonans görüntüleme
- sMRI:** Yapısal manyetik rezonans görüntüleme
- SSANN:** Summation-based Synergetic Artificial Neural Network
- TSSB:** Travma sonrası stres bozukluđunu

OKB: Obsesif Kompulsif Bozukluk

EHR: Elektronik Sağlık Kayıtları

STDP: Spike-Timing Dependent Plasticity

SNN: Spiking Neural Network



1.GİRİŞ

Ruh sađlıđı bozuklukları, küresel düzeyde kamu sađlıđı için önemli bir sorunu temsil etmektedir. Psikiyatrik bozukluklar, sadece bireyi deđil, aynı zamanda aileyi ve toplumu da etkiler. Bu hastalıkları dođru bir şekilde teşhis etmek, kategorize etmek ve uygun bakımı sađlamak hayati öneme sahiptir. Dolayısıyla bu alana duyulan ilgi nedeniyle psikiyatrik bozukluklarda yapay zekâ tekniklerinin kullanılarak yapılan arařtırmaların sayısında önemli bir artış olmuřtur. Bu incelemede yapay zekâ ile ilgili genel bir bilgi verildikten sonra, belirli psikiyatrik bozukluklarda kullanılan yapay zekâ yaklaşımlarını içeren çalıřmalar ele alınmıřtır.

2. GENEL BİLGİLER

2.1. Yapay Zekâ

2.1.1. Yapay zekâ nedir?

Yapay zekâ günümüze damgasını vuran önemli bir bilim dalıdır. Zekâ kavramı Türk Dil Kurumu sözlüğünde; “İnsanın düşünme, akıl yürütme, öğrenme, kavramları ve nesnelere zihinde canlandırabilme, objektif gerçekleri algılama, sonuç çıkarma, bedeni kontrol edebilme, duyguları doğru algılayabilme, değerlendirebilme, icat edebilme, vb. yeteneklerinin ve becerilerinin tamamı; anlık, dirayet, zeyreklik, feraset” olarak tanımlanmaktadır.

Yapay zekâ terimi ise birçok insanda farklı çağrışımlar yapmaktadır. Dolayısıyla birçok tanımı bulunmaktadır. Genellikle halk arasında insan zekâsı ile ilişkilendirilen bilişsel fonksiyonları taklit eden makineler olarak algılanır. (Russell & Norvig, 2010). Oxford İngilizce Sözlükte ise yapay zekâ görsel algılama, konuşma tanıma, karar verme ve diller arasında çeviri gibi normalde insan zekâsını gerektiren görevleri yerine getirebilen bilgisayar sistemleri olarak tanımlanmaktadır.

Tanım olarak Yapay zekâ insan bilişini algılayabilen, akıl yürütebilen, kavrayabilen, anlamlandırabilen, genelleştirebilen, deneyimlerden öğrenebilen bir bilişim teknolojisidir. (Gondal Khalid Masud, 2018)

Bir başka anlamıyla Yapay Zekâ (AI), minimum insan müdahalesi ile akıllı davranışı modellemek için bir bilgisayarın kullanılmasını ifade eden genel bir terimdir.(Hamet & Tremblay, 2017)

Yapay zekâ ile ilgili yukarıda yapılan tanımlamalar göz önüne alındığında asıl olarak vurgulanan noktanın yapay zekanın herhangi bir işlevi yerine getirirken insan beyni gibi öğrenme fonksiyonunu gerçekleştiren bilgisayar sistemleri olmasıdır.

Uzun yıllardır insanoğlunu beynin çalışma sistemini merak etmiş ve bununla ilgili olarak önemli araştırmalar ve çalışmalar yapmıştır. Yine bu bağlamda insana benzer bir cihaz yapma hedefi hep var olmuştur. Bu hedef doğrultusunda yapay zekâ çalışmaları artarak devam etmiş ve günümüzde önemli bir yere gelmiştir.(Öztemel, 2020) Ancak

yapay zekâ konusu ile ilgili yapılan çalışmalar aynı zamanda yeni sorular gündeme getirmiştir. Bununla konuyla alakalı MIT (Massachusetts Technical University) araştırma grubunda yapay zekâ ile ilgili çalışmalar yapan Marvin Minsky Yapay zekanın “hareket eden bir ufuk” olduğunu ifade etmiştir.(Sönmez, 2020)

2.1.2. Yapay zekanın amacı nedir?

Geçmişten günümüze kadar gelişerek devam eden yapay zekanın birçok amacı vardır. Günümüzde önemli bir gelişme kateden yapay zekâ eğitim, bilimsel araştırmalar, mühendislik, sağlık gibi çeşitli alanlarda birçok amaç için kullanılmaya devam ediyor. Şüphesiz ki bunlardan en önemlisi öğrenme ve anlama açısından insana en çok benzeyen sistemleri oluşturmaktır.(Mijwil et al., 2022)

Yapay zekanın diğer amaçlarını ise şu şekilde sıralayabiliriz:

1. Bilgisayar modellerinin yardımıyla beynin işlevlerini araştırmak
2. İnsanın yaşam kalitesini arttırmak
3. İnsan hayatını kolaylaştıran akıllı sistemler ve makineler üretmek
4. Eğitim alanında strateji geliştirme ve muhakeme yeteneğini kazandırmak
5. Kullanılan makinelerin verimliliğini arttırmak (Bozüyük et al., 2005)

2.1.3. Yapay zekanın gelişim süreci

Bulduğumuz çağ itibariyle çeşitli alanlarda kullanılan ve günümüzde önemli düzeyde gelişme kateden yapay zekanın temeli 17. Yüzyıla dayanmaktadır. Bu dönemde gerek yönetici gerek halk arasında insan ve hayvan davranışlarını taklit eden otomatlar yapılmaya başlanmıştır. Bu durum dönemin felsefi bakış açısını da etkilemiştir. Nitekim dönemin ünlü filozoflarından biri olan Descartes (1596-1650), insanı saat benzeri bir düzencele çalışan makinelere benzetmiştir.(Coşkun & Deniz Gülleroğlu, n.d.)

Yapay zekâ tarihi için önemli dönüm noktalarında bir tanesi ise 1884 yılında İngiliz matematikçi Charles Babbage (1792-1871) tarafından icat edilen Fark Motoru adlı ilk hesap makinesidir. Bu makine basit matematiksel işlemlerle beraber ara işlem sonuçlarının saklanabildiği bir belleğe sahipti. İnsan davranışlarının taklit edilmesinde ziyade insan beyninin taklit edilmesini amaçlanarak yapılan bu buluş yapay zekanın gelişim süreci içinde önemli bir yer tutmaktadır. (Schultz Duane P. & Schultz Sydney Ellen, 2007)

Modern anlamda yapay zekanın gelişim göstermeye başladığı dönem 2. Dünya savaşının yaşandığı yıllardır. Bu savaşın yaşandığı dönemde İngiliz matematikçi, bilgisayar bilimcisi ve kriptolog olan Alan Mathison **Turing** (23 Haziran 1912 – 7 Haziran 1954) tarafından “Bombe” adı verilen bir kod kırma makinesi icat edilmiştir. Bu icat ise 2. Dünya savaşının kaderini değiştirmiştir.(Acar, 2020) Alan Turing 1950 yılında yayınladığı “Computing Machinery and Intelligence” isimli makalesinde yapay zekayı teorik olarak ele almaktadır. Turing bu makalesinde bilgisayarların insanlar gibi düşünmek üzere eğitilebileceğini savunuyor. Yine aynı makalede günümüzde geçerliliği devam eden ve bir makinenin hangi zekâ seviyesini karşılaması gerektiğini bulmaya çalışmak için kullanılan Turing Testini geliştirmiştir. Bu teste göre eğer bir bilgisayar, karşısındakini konuştuğu kişinin bir insan olduğuna inandırabilirse, o zaman düşünme yeteneğine sahip olacağını iddia ediyor. Alan Turing’in bu makalede ele aldığı asıl konu “Makineler düşünebilir mi?” idi. Dolayısıyla bu makaleyle birlikte “Makine” ve “Düşünme” kelimelerinin birleşimi yapay zekanın temelini oluşturmuştur. (Turing, 1950)

Teorik zemini Turing tarafından hazırlanan ve literatürde “Artificial Intelligence” olarak adlandırılan yapay zekâ terimi ilk kez 1956 yılında Dartmouth Koleji’nde yapılan “Dartmouth Konferansında” matematikçi John McCarthy tarafından dile getirilmiştir. Bu konferansa aynı zamanda yapay zekâ alanında öncü isimlerden olan Marvin L. Minsky (Massachusetts Institute of Technology-MIT), Nathaniel Rochester (International Business Machines-IBM) ve Claude Shannon (Bell Laboratories) katılmıştır.(Dick, 2019) Bu konferansın ardında 1961’de Aziz, 1963’te Benzeşim, 1965’te Eliza, 1970’te Bilgin ve 1979’da Stajyer gibi yapay zekâ programları geliştirilmiş olup bu alanda yapılan çalışmalarda artış meydana gelmiştir.(Coşkun & Deniz Gülleroğlu, n.d.)1972 yılında ise ilk insansı robot olan Wabot -I adıyla , Japonya’da bulunan Waseda Üniversitesi’nde icat edilmiştir.(Acar, 2020)

Yapay zekâ tarihinde 1974 ile 1980 yılları “Yapay Zekâ Kışı” (Artificial Intelligence Winter) olarak adlandırılmaktadır. Bu dönemin bu şekilde adlandırılmasının nedeni ise devletlerin o dönemde yapay zekâ ile ilgili yapılan olumsuz eleştirilerden etkilenmesinden ötürü bu alana yatırım yapmamalarıdır. Dolayısıyla bu dönem yapay zekâ çalışmalarının duraksadığı bir dönem olmuştur. İngiltere’nin yapay zekâ yarışlarında Japonya’ya karşı rekabet edebilmek için fon sağlamasıyla birlikte yapay zekâ alanı 1980’ler de bir kez daha ivme kazanmıştır. (Öztürk & Şahin, 2018a)

Yıl 1997' yi gösterdiğinde dünya satranç şampiyonu Garry Kasparov'un IBM 'nin ürettiği "Deep Blue" isimli bilgisayar programı tarafından bir maçta mağlup olması büyük etki yaratmış olup aynı zaman da bilgisayarların bazı alanlarda insanlardan daha iyi olduğunu göstermiştir.(Schultz Duane P. & Schultz Sydney Ellen, 2007)Hanson Robotics tarafından yaratılan bir yapay zekaya ve fiziksel bir bedene sahip robot Sophia ile mühendisleri arasındaki konuşmalarla başlayan ve ABD'deki Talk-Show'a katılan ardından Suudi Arabistan devleti tarafından vatandaşlık verilmesi yapay zekanın çarpıcı örneklerinden bir tanesidir.

2.1.4. Yapay zekâ ve insan zekasının karşılaştırılması

Yapay zekâ insan zekasının taklidi sonucu ortaya çıkmıştır. Öğrenme kapasitesi insan zekasının birincil ölçütüdür. Dolayısıyla makineler öğrenme becerisi kazandırma fikri, insan zekâsı örnek alınarak oluşturulmaya çalışılan yapay zekâ sistemlerinin temelini oluşturmaktadır. İnsanlarda öğrenme olayının beyinde gerçekleştiği düşünüldüğünden, beyin yapısını incelemek ve bunu makineler üzerinde oluşturmak mümkün görünmektedir. (Coşkun & Deniz Gülleroğlu, n.d.) İnsanlarda öğrenme olayı nöron olarak adlandırılan beyin hücrelerinin birbirleriyle olan etkileşimleri göz önüne alınarak yapay sinir ağları oluşturulmuş ve öğrenme olayı simüle edilmiştir. (A. Yılmaz & Kaya, 2021) Yapay zekanın önemli isimlerinden biri olan McCarty'e göre; insan zekâsı ve öğrenme olayının tam olarak anlaşılması halinde makineler bunu taklit ederek öğrenme yeteneğine ve zekaya sahip olacaklardır. (Coşkun & Deniz Gülleroğlu, n.d.)

Yapay zekâ alanında çalışan Cem Say, insan beynini bilgiyi işleyen üstün bir bilgisayara benzetmiştir. Say'a göre bilgisayar ve insan beyni arasındaki en önemli fark bilgisayarda işlem yapılırken her işlemcinin kendisinden bir önceki işlemin tamamlanmasını beklerken, insan beyninde bu işlemin milyarlarca nöron tarafından aynı anda yapılabilmesidir.(Karabağ, 2021)

İnsanlarla karşılaştırıldığında bilgisayarlar çok daha hızlı ve doğru hesaplama yapabilmektedir. Ancak bilgisayarların hesaplama alanında gösterdikleri beceri seviyesi diğer konularda düşük kalmaktadır. Uzmanlara göre bu durumun nedeni insan beyninin tam olarak programlanabilir ve genel bir amaca hizmet eden bir bilgisayar olmamasıdır.(Nabiyev, 2010) Dolayısıyla yapay zekanın tamamen insan beyni gibi çalışmasını beklememek gerekir.(Bostrom, 2018)

Ancak yapay zekânın hiçbir zaman insan beyninin yetenekleriyle boy ölçüşmeyeceğini ve yapay zekânın insan beyninin gerçekleştirebildiği görevleri yerine getiremeyeceğini savunan uzmanlar bunu aşağıdaki gerekçelere dayanmaktadır:

- İnsan beyninde trilyonlarca işlem birimi olmasına rağmen, bir bilgisayarda bunlardan sadece yüzlercesi olabilir.
- İnsan beyninin binlerce işlemine kıyasla bilgisayarlar her saniye milyarlarca işlem gerçekleştirmektedir.
- İnsan beyni dayanıklıdır ve bir hata olması durumunda çökmez ancak bilgisayarlarda çökme durumu söz konusu olabiliyor.
- İnsan beyni analog sinyalleri işlerken, bilgisayarlar ikili sinyalleri kullanır.
- İnsan beyni yaratıcı iken bilgisayarlar sadece programcıların yapmak istediklerini yaparlar.
- İnsan beyni sezgisel olabilir, ancak bilgisayarlar mantıkla sınırlıdır.

Nilsson'a göre insan zekâsı ile yapay zekâ arasındaki bu farklar günümüz şartlarında geçerliliğini yitirmeye başlamıştır. Teknoloji alanındaki gelişmeler ile yapay zekânın da artık insan zekâsı ile yarışacak konumda olduğunu açıklamaktadır. Bunu örneklendirecek olursak insanlara benzer şekilde, bilgisayarlarda makine öğrenmesi ile deneyimlere bağlı olarak gelişmeye devam etmektedirler. (Nilsson, 2018)

2.1.5. Yapay zekânın geleceği

Geçmiş yıllarda yapay zekâ yalnızca insanlar tarafından gerçekleştirilebilen akıllı görevleri nasıl yerine getirildiğini inceleyen bir bilim dalıydı. Son yıllarda, yapay zekâ hızla gelişmiş ve insanların yaşam tarzlarını değiştirmiştir.(Zhang & Lu, 2021) Günümüzde sağlık, eğitim, ulaşım, hukuk, finans vb. gibi birçok alanda kullanılmaktadır. Hemen hemen tüm yapay zekâ standart alt alanları, konuşma tanıma ve üretme, doğal dil işleme, görüş ve doğal dilin işlenmesi (üretme ve anlama), çoklu aktör sistemleri, görüntü ve video oluşturma, planlama, karar verme ve robotik için görüş ve motor kontrolün entegrasyonu ile gibi alanlarda büyük ilerlemeler katetmişlerdir. Ayrıca, oyunlar, sağlık tanıları, lojistik programlar ve otonom sürüş gibi

birçok alanda çığır açan uygulamalar ortaya çıkmıştır. Dil çevirisi ve kişisel destek gibi alanlarda da önemli gelişmeler görülmüştür.

Yapay zekâ (AI) daha karmaşık ve yaygın bir şekilde kullanıldıkça, hükümetler ve kamu kurumları AI'nın geliştirilmesine ve uygulanmasına daha fazla odaklanmıştır. Uluslararası hükümetlerin yapay zekâ konularına artan dikkati, konunun karmaşık olduğunu ve gizlilik, adalet, insan hakları, güvenlik, ekonomi, ulusal ve uluslararası güvenlik gibi diğer politika öncelikleriyle kesiştiğini yansıtmaktadır.(University Stanford, 2021)) Son AI100 raporu yayımlandığından bu yana geçen beş yıl içinde, 60'tan fazla ülke ulusal AI girişimlerine katılmış ve ilgili konularda etkili uluslararası iş birliğini teşvik etmeyi amaçlamıştır.(<https://www.oecd.ai/dashboards>, n.d.)

- Dünya genelinde, son beş yıl içerisinde hem şirketlerin hem de hükümetlerin yapmış olduğu AI araştırma ve geliştirme (AR-GE) yatırımları önemli ölçüde artmıştır.(Daniel et al., 2021) ABD hükümeti 2020 yılında yapay zekâ ile ilgili teknolojilere yaklaşık olarak 1,5 milyar dolarlık bir AR-GE yatırımı yapmıştır.(Final Report - National Security Commission on Artificial Intelligence, 2021) Çin hükümeti ise 2018 yılında yapay zeka AR-GE yatırımlarına 9.4 milyar dolar ayırdığı tahmin ediliyor.(Acharya & Arnold, 2019)Son 5 yıl içerisinde Avrupa da yapay zeka alanına önemli düzeyde yatırımlar yapmıştır ve AB (Avrupa Birliği) liderliğinde dört ana stratejinin bulunduğu bir plan yürürlüğe girmiştir. Bu 4 ana strateji aşağıdaki gibidir.(Europe and AI: Leading, Lagging Behind, or Carving Its Own Way? - Carnegie Endowment for International Peace, n.d.)
- AB'de yapay zekâ gelişmesini ve yayılmasını sağlamak
- AB'yi yapay zekanın geliştiği yer haline getirmek
- Yapay zekanın insanlar için çalışmasını ve toplum için iyi bir güç olmasını sağlamak
- Stratejik sektörlerde liderlik oluşturmak

Yukarıda yer alan hedeflere ulaşılması için dünya genelindeki hükümetler multidisipliner araştırmalar yapmak ve yapay zekâ ile ilgili konuların incelenmesi, geliştirilmesi ve düzenlenmesi için daha büyük yatırımlar yapmalıdırlar. (University Stanford, 2021)

Gelecek dönemde yapay zekanın otomotiv endüstrisi, finansal piyasalar, sağlık endüstrisi, perakende sektörü, medya sektörü, akıllı ödeme sistemleri ve akıllı ev alanında önemli gelişmelerin olacağı öngörülmüyor.

Otomotiv endüstrisi alanında, özellikle otonom sürüşler öne çıkmaktadır. Otomotiv endüstrisi, yapay zekâ ve nesnelerin interneti gibi yeni nesil bilgi teknolojileri ile birleşerek otonom sürüşlerinin gelişmesine yol açmıştır. Sürücüsüz araçlar alanında Avrupa'da ve ABD'de önemli gelişmeler yaşanmıştır. Çin'in de bu alanda geliştiği ve aradaki farkı kapattığı söylenebilir. Google 2014 yılında ilk sürücüsüz prototip aracını duyurmuştur. 2015 yılında ise İsviçre ve Fransa birlikte sürücüsüz otobüsler üretmişlerdir. Almaya'dan Audi ise 2017 yılında "Audi AI" isimli markayı kurmuştur ve yapay zekayı olimpiyat oyunlarında kullanmıştır.

Finansal piyasalarda ise akıllı risk kontrolü, akıllı danışmanlık, piyasa tahmini ve kredi derecelendirmesi gibi durumlarda kullanılmaktadır. Ayrıca derin öğrenme ve makine öğrenmesi gibi yöntemleri kullanan finans sektörü için yapay zekâ önemli bir pazar alanıdır. Finans kurumları ilgili finansal riskleri değerlendirmek, ilgili finansal varlıkların gerçek zamanlı risk uyarısı sağlamak, yatırım ve finans yönetimi ile ilişkili işgücü maliyetlerini azaltmak, rasyonel ve bilimsel bir risk yönetim sistemi kurmak ve işletmenin büyümesi için temel oluşturmak amacıyla büyük veriyi kullanmaktadır.

Sağlık sektöründe yapay zekâ ile ilgili kullanılan algoritmalar kanser tespiti yapmak, yeni ilaçlar geliştirmek ve tıbbi yardım sağlamayı amaçlamaktadır. Dünya çapında tıbbi girişimlerin ilerlemesi, büyük ölçüde tıbbi bilgilerin kapsamlı bir şekilde yayılmasına bağlıdır. Buna verilebilecek en önemli örnek ise IBM tarafından üretilen Watson isimli akıllı robottur. IBM ekibi önemli düzeyde bilgi ve veriyi bu akıllı robota yüklemişlerdir. Bu devasa veri tabanına binlerce hastaya ait tıbbi kayıtlar, ilaç kullanım raporları ve tıbbi bilgiler dahil edilmiştir. O günden beri yapay zekâ algoritmalarının analizi ve işlenmesi, tıbbi teşhisin doğruluğunu ve verimliliğini artırmak ve paydaşlara tıbbi yardım sunmak amacıyla yapılmıştır.

Perakende sektöründe ise yapay zekâ kullanılarak fiziksel perakende mağazalarında insan olmadan gerçek perakende satış yapmak, böylece maliyetleri azaltıp verimliliği artırmak mümkündür. Ayrıca online satışlarda yapay zekanın öneri sistemi uygulaması ile doğru Pazar tahminleri yapmak ve stok maliyetlerini azaltmak söz konusu olabilir.

Birçok e-ticaret web sitesi, kullanıcının potansiyel tercihlerine dayalı bir online ürün öneri modeli oluşturan öneri sistemini kullanmıştır.

Medya endüstrisinde içerik iletişim robotları ve marka iletişim robotları tarafından bir dakikada 10.000 makale yayınlanabilir. Bu robotlar, kullanıcılara istedikleri içeriğin tek tıkla üretilmesini sağlar. Bu yapay zekâ destekli medya platformu, medya dağıtımını ve teslimat kurallarını analiz edebilir, popüler etkinlikleri, kamuoyunu ve halkla ilişkiler pazarlama içeriğini birleştirebilir ve kullanıcıların okumak istediği içerikleri otomatik olarak oluşturabilir.

Akıllı ödeme sistemleri açısından bakıldığında, günümüzde birçok insan nakit kullanmadan alışveriş yapma alışkanlığı edinmiştir. Ödeme işlemi cep telefonu ile kolayca tamamlanabilir. Müşteriler, satın alımlarını QR kodu taratarak yapmadılarsa, yeni bir ödeme yöntemi olan yüz taraması ve sesli ödeme yöntemini kullanabilirler. Alışveriş yapanların cüzdanlarını yanlarına almalarına, QR kodu taratmalarına ve hatta şifre girmelerine gerek yoktur. Kendi yüzleri ve sesleri üzerinden ödeme yapma seçeneğine sahiptirler. Sesli ödeme, biyolojik özellikler göz önüne alınarak oluşturulan yeni bir teknolojidir.

Akıllı evler, günlük yaşamın çeşitli yönlerini entegre etmek için gelişmiş teknolojiyi kullanarak genel konforu artıran etkili konut tesisleri ve günlük aile işlerini yönetme sistemleridir. Kapsamlı bir akıllı ev sistemi, tek bir cihazın ötesinde farklı amaçlara hizmet eden sayısız ev eşyasından oluşur. Bir ailenin kullanıcı tabanı sadece bir kişi değil, birden fazla kullanıcı içerir. Akıllı ev sistemlerinin amacı, ev eşyalarını ve bireyleri akıllı ve verimli bir şekilde düzenleyerek, kendine bağlı, öğrenebilen ve adapte olabilen bir sistem haline getirmektir.

Bilgi, mantık, düşünce, sistem ve biyolojiyi içeren çok disiplinli bir alan olan yapay zekâ, bilgi işleme, desen tanıma, makine öğrenimi ve doğal dil işleme dahil olmak üzere bir dizi teknikte kullanılmıştır. Bilgi sistemleri, akıllı robotlar, uzman sistemler ve otomatik programlama da dahil olmak üzere birçok alanda uygulamalara sahiptir. Yapay zekâ da hem mantıklı düşünce hem de taklit gerekir, ancak duygu da vazgeçilmez bir bileşendir. Yapay zekâ (AI) alanındaki bir sonraki büyük gelişme, bilgisayarların mantıksal düşünmeye ek olarak duygusal bir şekilde akıl yürütebilmesine izin verebilir. (Zhang & Lu, 2021)

2.2. Yapay Zekâ Teknikleri

2.2.1. Bulanık mantık

2.2.1.1. Bulanık mantık nedir?

Günlük yaşamımızdaki sorunları değerlendirdiğimizde, bunların gerçek dünyanın belirsiz, öngörülemeyen, doğrusal olmayan ve sonuçta kesin olmaktan uzak bir nitelikte olduğunu söyleyebiliriz. Çevremizin beklentilerinin sürekli değiştiği düşünüldüğünde, hayatımızdaki her duruma bir kural uygulamanın zaman ve enerji kaybına neden olacağı açıktır.(Sanca et al., 2022) İhtiyaçları karşılayabilen çözümler üretmek için birçok matematiksel model geliştirilmiştir. Bu modeller, dil, düşünce ve duyu modellemesi potansiyelinin kapsamlı bir analizini sağlamada yetersiz kalmaktadır. Dolayısıyla meydana gelen belirsizlikleri modellemek için yeni yöntemler geliştirilmiştir. Bu yöntemlerden bir tanesi ise Bulanık Mantık (Fuzzy Logic) tır. Bulanık mantık Aristoteles'in mantığına karşı olarak ortaya çıkmıştır.(Furkan Keskenler & Keskenler, 2017)

1965 yılında Berkeley'deki California Üniversitesi'nde Bilgisayar Teknolojileri ve Elektrik Mühendisliği (Computer Sciences and Electrical Engineering) bölüm başkanı olan, aynı zamanda Professional Biography adlı biyografi sitesinde "bulanık mantığın babası, çok seçkin bir bilim adamı, mühendis ve sistem kuramcısı" olarak tanımlanan Azerbaycan asıllı Prof. Dr. Lütüfî A. Zadeh, Bulanık Mantığın modern anlamda ilk kurucusu olarak kabul edilmiştir. Zadeh 1965 yılında yayınladığı The Theory of Fuzzy Logic and Fuzzy Sets (Bulanık Mantık ve Bulanık Kümeler Kuramı) isimli makalesiyle Bulanık Mantık alanında bilim dünyası için çok önemli çalışmalarda bulunmuştur.(Furkan Keskenler & Keskenler, 2017)

1975 yılında ise, Bulanık Mantık ilk kez Assilian ve Mamdani tarafından bir buhar motorunun kontrol sistemine entegre edilmesiyle kullanılmıştır. Böylece Mamdani, Zadeh'in dilbilimsel kurallar yönteminin bilgisayarın kolayca anlayabileceği bir şekilde sunulduğunu göstermiştir. (Eğrisöğüt Tiryaki & Kazan, n.d.)

Bulanık mantığın genel özellikleri Zadeh tarafından aşağıdaki şekilde ifade edilmiştir:

- Bulanık mantıkta, kesin değerlerin yerine yaklaşık değerler kullanılır.
- Bulanık mantık, bilgiyi "çok az", "az", "küçük" ve "büyük" gibi dilbilgisel ifadelerle tanımlar.

- Bulanık mantıkta, her değeri temsil eden bir üyelik derecesi [0-1] aralığında bulunur.
- Herhangi bir mantıksal ifadeyi bulanık bir ifadeye dönüştürmek mümkündür.
- Son derece karmaşık ve zorlu matematiksel modellere sahip sistemler için bulanık mantık uygun bir tekniktir. (Furkan Keskenler & Keskenler, 2017)

Genel olarak, değişik biçimlerde ortaya çıkan karmaşıklık ve belirsizlik gibi tam ve kesin olamayan bilgi kaynaklarına Bulanık (fuzzy) kaynaklar adı verilir.(Şen, 2009) Çok fazla bilgi kaynağının bulunması nedeniyle insan sorunlarının köküne inildiğinde durum bulanıklaşır. Bireyler, tüm bilgi kaynaklarıyla aynı anda etkileşimde bulunamaz ve hepsini anlayamazlar. Sorunlar, ne kadar derinlemesine araştırılırsa, mantıktan ve doğruluktan o kadar uzaklaşır.(Karataş, 2018)

Bulanık mantık, hayatımızdaki sorunları, belirsizlikleri ve çıkmazları matematiksel fonksiyonlara dönüştürerek modellenmesi ve makinelere aktarılması ile sonuçlanan, hesaplama dayalı bir yaklaşımdır.(Sanca et al., 2022)Başarılı bir metod olan Bulanık Mantık karmaşık, modellenmesi güç, doğrusal olmayan ve bilgilerinin niteliklerinin kesin olmadığı durumlardaki süreçlerin kontrolünde etkili bir tekniktir. İnsanların düşündüğü gibi, çok uzun, uzun, orta, kısa, çok kısa gibi ara değerlere dayanarak işlev gösterir.(Eğrisöğüt Tiryaki & Kazan, n.d.) Başka bir ifade ile 0-1 değerleri yerine 0.5, 0.90 gibi ara değerleri de kullanarak işlem yapmaktadır.(Furkan Keskenler & Keskenler, 2017)

2.2.1.2. Bulanık kümeler

Klasik mantıkta, sınıflandırmalar mutlak olduğu için kısmi üyelik söz konusu olamaz. Bir öge ya bir kümenin bir parçasıdır ya da değildir. Kümenin bir parçası olan öğelerin değerleri 1, kümenin bir parçası olmayan öğelerin değerleri ise 0 olarak kabul edilir. Buna karşılık, bulanık mantık, insanın akıl yürütme sürecini taklit eder ve Aristoteles mantığına zıt olarak yaklaşık ve belirsiz senaryolarda çalışabilir. Bulanık mantıkta bir öge birden fazla küme içinde bulunabilir.(Sanca et al., 2022)

Klasik mantıkta, bir u elemanın A kümesi ile ilişkisi için $\mu_A(u) = 1$ ise u , A kümesinin elemanı olarak kabul edilir, ancak $\mu_A(u) = 0$ ifadesi kullanılırsa u , A kümesinin elemanı değildir.(Eğrisöğüt Tiryaki & Kazan, n.d.)

Bulanık mantık açısından bakıldığında, A kümesi U evreninde tanımlanan bulanık bir küme ve $[0, 1]$ aralığında değerler alabilen $\mu_A(x)$ üyelik fonksiyonu ile ifade edilen bir kümedir.

$$A = \{ (x, \mu_A(x)) / x \in U \}$$

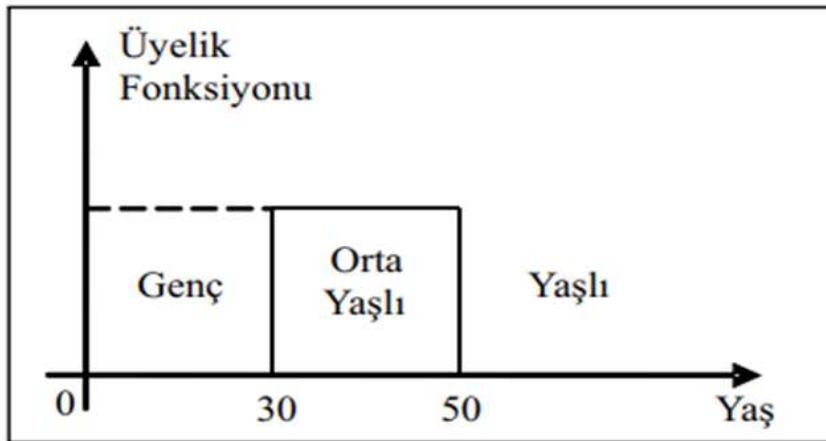
$\mu_A: X \rightarrow [0, 1]$ şeklinde ifade edilir. (Sanca et al., 2022)

Üyelik fonksiyonları, bulanık problemlerin çözümünü kolaylaştırır. (Ölmez, 2010) “Üyelik derecesi”, bulanık küme A'nın üyelik fonksiyonunun aldığı değerlere işaret eder; x'in bu evrene ne kadar ait olduğunu ölçen değer $\mu_A(x)$ şeklindedir. (Sanca et al., 2022)

Bulanık ve klasik küme teorisini karşılaştırmak için bir yaş problemi örneğini ele alacak olursak;

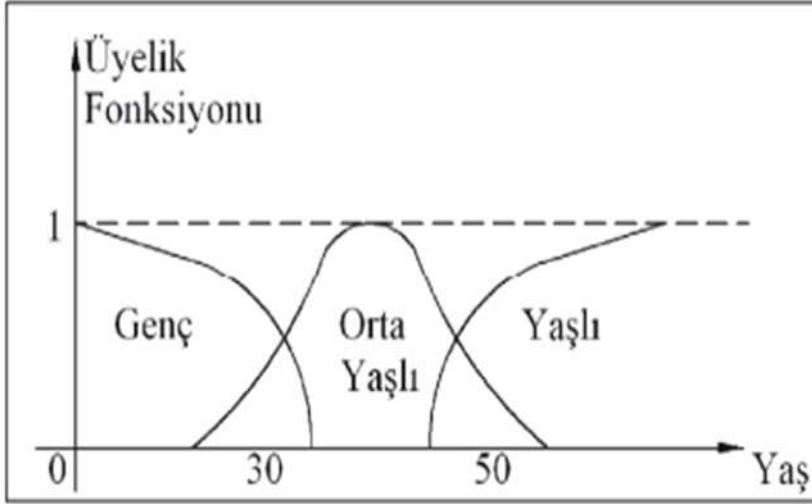
Şekil 1'de Klasik küme, Şekil 2'de ise Bulanık küme üyelik fonksiyonları gösterilmektedir.(Eğrisöğüt Tiryaki & Kazan, n.d.)

Şekil 1'de yer alan Klasik Küme teorisine göre, 30 yaş altındaki insanlar genç olarak kabul edilir, 30 ile 50 arasındaki insanlar orta yaşlı olarak ve 50 yaşın üzerindeki insanlar ise yaşlı olarak kabul edilir. Bu kurallara göre, 49 yaşındaki bir kişi orta yaşlı olarak kabul edilirken, 51 yaşındaki bir kişi yaşlı olarak kabul edilir.



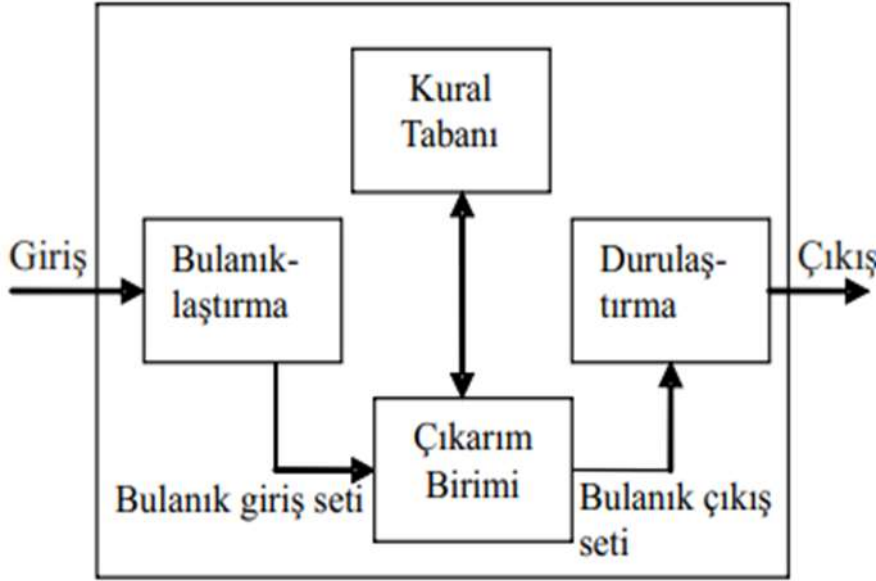
Şekil 1:Klasik küme teorisi(Eğrisöğüt Tiryaki & Kazan, n.d.)

Şekil 2'de gösterilen Bulanık Mantık teorisine göre ise, 50 yaşındaki bir kişi belirli bir oranda orta yaşlı ve belirli bir oranda yaşlı olarak sınıflandırılır. Farklı bir deyişle ifade edecek olursak bulanık mantıkta daha esnek bir yaklaşım ve kısmi üyelik vardır.



Şekil 2: Bulanık küme teorisi (Eğrisöğüt Tiryaki & Kazan, n.d.)

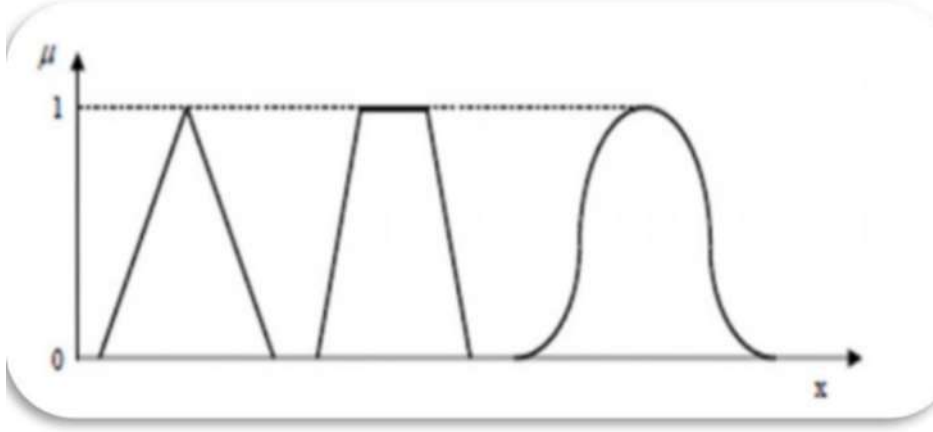
Şekil 3'te gösterildiği üzere, Bulanık mantık sisteminin temel bileşenleri bulanıklaştırma birimi, çıkarım birimi, kural tabanı ve durulaştırma birimi olmak üzere 4 aşamadan oluşur.



Şekil 3: Bulanık mantık sisteminin temel bileşenleri (Eğrisöğüt Tiryaki & Kazan, n.d.)

Bir bulanık mantık tabanlı sistem tasarlamak için yapılacak olan ilk adım, sistem verilerinin bulanıklaştırılmasıdır. Üyelik fonksiyonları kullanılarak elde edilen veri, bulanıklaştırma aşamasında bulanık bir forma dönüştürülür. Bu aşamada giriş verileri “0” ve “1” arasında bir değere dönüştürülür.

Bulanık üyelik fonksiyonları, bulanık kümeleri ifade etmek için kullanılır. Bu fonksiyonlara örnek olarak üçgen, yamuk, çan eğrisi, L tipi, tekil ve sigmodial ifadeler verilebilir. Şekil 4 üçgen, yamuk ve çan eğrisi üyelik fonksiyonlarını göstermektedir.



Şekil 4:Üçgen, yamuk ve çan eğrisi üyelik fonksiyonları(Sanca et al., 2022)

Bulanık mantık (BM) sistemlerinde, çıktı verilerini elde etmek için kural tabanları oluşturulmalıdır. Çünkü kural tabanı, doğru sonuçların elde edilmesini sağlar ve bulanık mantık sistemlerini kurar. Kurallar, giriş ve çıkış değerleri arasındaki mantıksal ilişkiyi tanımlamak için kullanılır. Bu kurallar, IF (eğer)- THEN (ise) yapısı kullanılarak ifade edilir.

Kural tabanına bir örnek;

“**if** sıcaklık çok düşük **and** nem çok düşük **then** hava kuru”

(Sıcaklık çok düşük ve nem düşük ise hava kurudur.)

Durulaştırma aşamasında ise, bulanık olan verilerin sayısallaştırıp kesin değerlere çevrilmesi sağlanır.(Sanca et al., 2022)

2.2.1.3. Bulanık mantık teorisinin avantajları

- Az sayıda kurala sahip olup, kolayca anlaşılabilir ve kullanılabilir olması
- Uygulama maliyetinin düşük olması
- Esnek ve sağlam bir çerçeveye sahip olması
- Belirsiz durumları ele alıp kolay uygulanabilir olması (Sanca et al., 2022)

2.2.1.4. Bulanık mantık teorisinin dezavantajları

- Üyelik fonksiyonlarını deneme yanılma yoluyla bulmasından ötürü uzun zaman alabilmesi
- Bulanık sistemlerde kullanılan üyelik fonksiyonlarını başka sistemlere transferinin mümkün olmaması
- Bulanık sistemlerinin öğrenme yetisinin olmaması (Sanca et al., 2022)

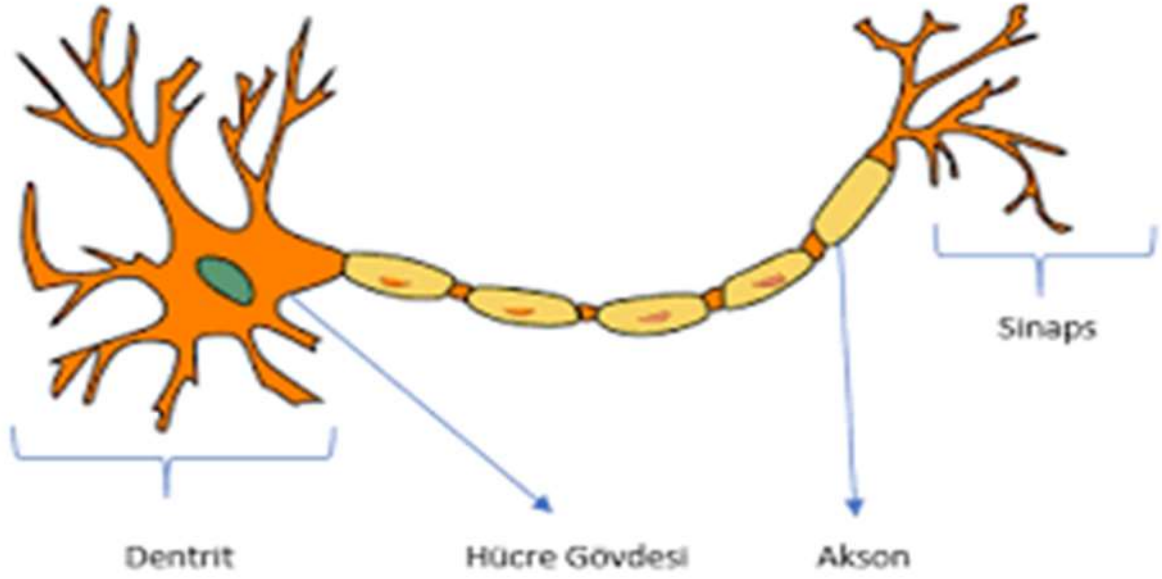
2.2.2. Yapay sinir ağları

2.2.2.1. Yapay sinir ağları nedir?

İnsanlar en önemli görevlerinden biri zekâ üretimi olan beyni modelleyerek, kendilerine benzer davranabilen ve karar verebilen modeller yaratmaya çalışmaktadırlar.(Ersoy & Karal, 2012) Yapay sinir ağları, insan beyninden ilham alınarak öğrenmeyi matematiksel olarak simüle etme girişimlerinin bir sonucudur. (Öztürk & Şahin, 2018b)

En önemli bölümü beyin olan merkezi sinir sistemi, nöron ya da sinir adı verilen hücrelerden oluşur. Canlıların temel fonksiyonlarını gerçekleştirdiği en küçük organlara nöron denir. Nöronlar beynin haberleşme sistemini oluştururlar ve sinyal alma, işlem yapma, elektrokimyasal sinyallerin sinir ağları içinde iletimini sağlarlar. Şekil 5'te biyolojik bir nöron yapısı gösterilmektedir. Sinir sisteminin en temel ögesi olan nöronlar 4 bölümden oluşmaktadır. (Şen, 2004)

1. Hücre gövdesi
2. Dendrit
3. Akson
4. Sinapslar



Şekil 5:Nöron(<https://Ennurcitir.Wordpress.Com/2020/02/19/Yapay-Sinir-Aglari>, n.d.)

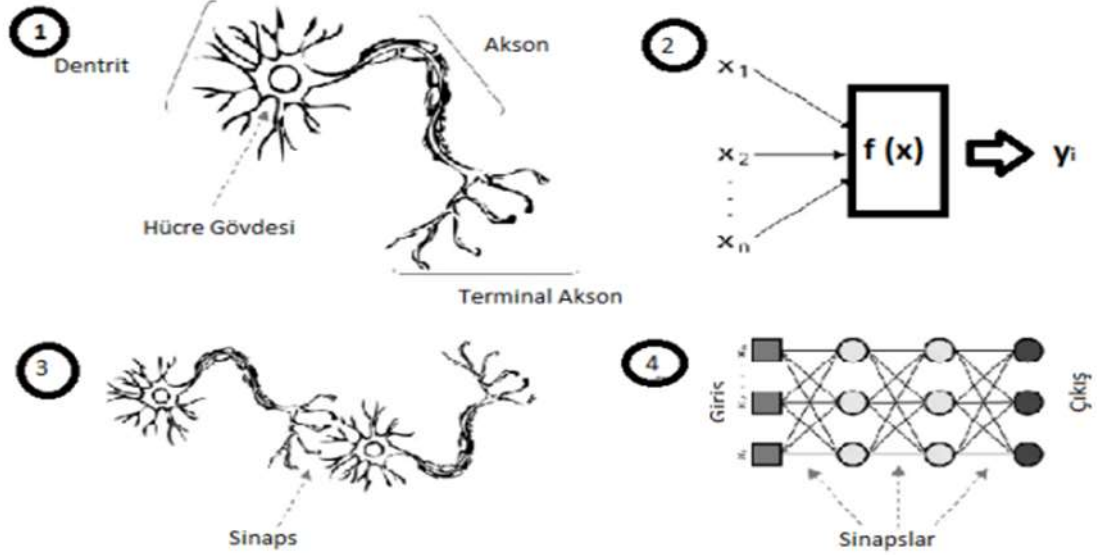
Sinir hücresinin çıkışı ile yanındaki bir diğer sinir hücresinin girişi arasındaki iletişim, sinapslar aracılığıyla mümkün hale gelir. Dendritlerin görevi ise sinapslardan aldığı bilgiyi hücre gövdesine taşımaktır. Aksonlar, hücre gövdesinde toplanan bilgi uyarı eşliğini aştığında, uyarılmış hücreden komşu hücrelere sinyal iletimine yardımcı olur. Bu nedenle aksonlar taşıma hatları şeklinde de isimlendirilir. Aksonlar ve dendritler görev bakımından birbirine benzerler ancak dendritler aksonlara göre daha kısadrlar. (Şen, 2004)

İnsan beyninin bilgi depolama ve öğrenme kapasitesinden ilham alınarak, öğrenme sürecinin matematiksel modellenmesi yapay sinir ağlarının (YSA) ortaya çıkmasına neden olmuştur. Yapay Sinir Ağları (YSA), farklı şekillerde birbirine bağlanan nöronları içeren ağlardır ve biyolojik sinir sisteminin işlevlerini taklit eder. Bu ağlar, veriler arasındaki ilişkileri gösterme, öğrenme ve depolama yeteneğine sahiptirler. (Ersoy & Karal, 2012)

Yapay sinir ağları, bir görevi gerçekleştirmek için birçok nöronu birleştirerek yapısal, istatistiksel, matematiksel ve felsefi problemlere çözüm üreten bir bilim dalıdır. Yapay sinir ağları genel olarak insan beyninin biyolojik sinir yapısını taklit eden bilgisayar programlarıdır. Bu programlar, sinir sensörlerinin yardımıyla yeni bilgiler üretip oluşturabildiği gibi, daha önce öğrenilmiş veya sınıflandırılmış bilgilere

dayanarak kararlar da verebilmektedir. (Furkan Keskenler & Fahri Keskenler, 2017)YSA biyolojik sinir ağlarını taklit eden sentetik yapılardır. (Öztürk & Şahin, 2018b)

Şekil 6’da gerçek bir sinir hücresi ile yapay sinir ağı gösterilmiştir.



Şekil 6: Biyolojik sinir hücresi ve yapay sinir ağı (Matarollo et al., 2013)

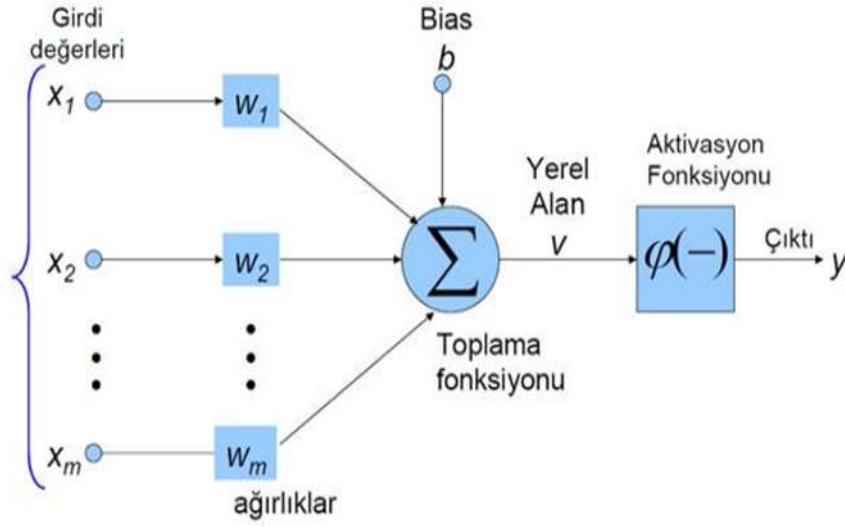
Şekil 7’de ise Biyolojik sinir sisteminde yer alan bileşenlerin yapay sinir sistemindeki karşılıklarını gösterilmiştir.

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Şekil 7: Biyolojik sinir sistemindeki bileşenleri ve yapay sinir ağındaki karşılıkları (Öztürk & Şahin, 2018b)

Yapay sinir ağının görevi Şekil 8’de gösterildiği gibi, girdi seti olarak verilen bilgiye yanıt olarak bir çıktı üretmektir. Bu işlem için ağ, belirli örnekler üzerinde

eđitilir. Bu noktada, ađ kararlar verebilir ve genelleme yapabilir. ıktılar daha sonra bu đrenilmiř yeteneđe gre belirlenir. (Furkan Keskenler & Fahri Keskenler, 2017)



řekil 8:Yapay sinir ađı rneđi(Furkan Keskenler & Fahri Keskenler, 2017)

2.2.2.2. Yapay sinir ađlarının zellikleri

Yapay sinir ađları, sahip olduđu zellikleri sayesinde birok geleneksel bilgi iřleme yntemlerinden farklılık gstermektedir. Aslında, bazı zellikleri diđer birok yntemden daha iyi performans gsterdiđi sylenebilir. (řen, 2004)

Yapay sinir ađlarının sahip olduđu temel zellikler ařađıdaki gibidir:(ztrk & řahin, 2018a)

- Dođrusallıđın olmaması
- Eksik verileri iřleme
- Genelleme yapma
- đrenme
- Paralellik
- Hata toleransı
- ok sayıda parametre ve deđiřken kullanmak
- Uyarlanabilir

Yapay sinir ağlarının sahip olduğu paralellik özelliği sayesinde taşınan bilgiler birbirinden bağımsızdırlar. Üstelik bu prensip sayesinde bir birimde meydana gelen hata tüm sistemde belirli bir hataya neden olmaz. (Şen, 2004)

Yapay Sinir Ağ Modelleri:

1. Tek katmanlı algılayıcılar
2. Çok katmanlı algılayıcılar
3. İleri beslemeli yapay sinir ağları
4. Geri beslemeli yapay sinir ağları

1) Tek katmanlı algılayıcılar: Bu sistemin içinde sadece giriş ve çıkış bulunmaktadır. Tek katmanlı sensörlerin çıkış fonksiyonu lineerdir ve 1 veya -1 değerlerini kabul eder. Eğer çıkış 1 ise ilk sınıfa, -1 ise ikinci sınıfa kabul edilir.

2) Çok katmanlı algılayıcılar: Çok katmanlı algılayıcılar, yapısal olarak lineer olmayan aktivasyon fonksiyonlarına sahip birçok nöronun bağlantısında belirli bir üstünlüğe sahip yapılar olarak tanımlanır. Çok katmanlı algılayıcılar, bazı yöntemlerin etkisiz olması sonucunda ortaya çıkmaktadır.

3) İleri beslemeli yapay sinir ağları: İleri beslemeli yapay sinir ağlarında nöronlar, girişten çıkışa kadar düzenli katmanlar şeklinde bulunurlar. Bir katmandan yalnızca kendinden sonraki katmanlara bağ bulunmaktadır. Yapay sinir ağına giren veri, herhangi bir değişiklik olmadan doğrudan orta noktaya veya gizli katmandaki hücrelere iletilir. İşlendikten sonra çıkış katmanı aracılığıyla dış ortama aktarılır.

4) Geri beslemeli yapay sinir ağları: Geri beslemeli yapay sinir ağları ile ileri beslemeli yapay sinir ağları karşılaştırıldığında, geri beslemeli yapay sinir ağında bir nörona ait çıktı sadece kendinden sonra gelen nöron katmanına girdi olarak verilmez aynı zamanda önceki ya da kendi katmanındaki bir nörona da girdi olarak bağlanabilir. Aynı yapay sinir ağı, geri besleme özellikleri sağlayan bağlantıların nasıl bağlandığına bağlı olarak çeşitli davranışlar ve yapılar sergileyebilen geri beslemeli yapay sinir ağlarına dönüştürülebilir. (Öztürk & Şahin, 2018b)

Yapay Sinir Ağlarının Temel Bileşenleri

- 1) Öğrenme algoritması
- 2) Aktivasyon fonksiyonu

Öğrenme Algoritması: Veriyi kaynaktan öğrenme, yapay sinir ağlarının en kritik özelliklerinden biridir. Ağda yer alan veri YSA 'da ağırlık olarak adlandırılan biyolojik ağda ise sinaps olarak isimlendirilen uçlarda muhafaza edilir.

Aktivasyon Fonksiyonu: Yapay sinir hücreleri, giriş verilerini aktivasyon fonksiyonunda işleyerek karşılık gelen net çıkış sonuçlarını üretir. Genel olarak, bu fonksiyon doğrusallık göstermez. Doğru fonksiyonun seçilmesi önemlidir. Çünkü sonuç performansı etkileyecektir. Tek veya çift kutuplu bir fonksiyon kullanmak mümkündür. (Öztürk & Şahin, 2018b)

2.2.2.3. Yapay sinir ağlarının gelişim süreci

Yapay sinir ağlarına yönelik çalışmalar 1940'lı yıllarda başladığı söylenebilir. Warren McCulloch ve Walter Pitts, 1943 yılında ilk yapay sinir ağı modelini oluşturdular. (McCulloch & Pitts, 1943) İlk yapay sinir ağı hücresi McCulloch ve Pitts'in elektrik devrelerini kullanarak insan beyninin hesaplama ve analiz yeteneğinden ilham alınarak geliştirilmiştir. McCulloch ve Pitts, bu yapay sinir hücreleri ile herhangi bir mantıksal ifadenin formülasyonunun mümkün olabildiğini göstermişlerdir.

1949 yılına gelindiğinde ise öğrenme ile ilgili temel teori olan "Hebbian öğrenme", Donald Hebb' in "Organization of Behavior" adlı kitabında ele alınmıştır. Hebb'in kuralı, araştırmacılara bir sinir ağının öğrenme ve adaptasyon kapasitesinin, bağlantı sayısı ile ilişkili olduğuna dair bir sonuca varmalarını sağladı.

1951 yılına gelindiğinde ise, ilk nuro-bilgisayar üretilmiştir.

1954 yılında ise Farley ve Clark tarafından rassal ağlar ile adaptif tepki üretme terimi ortaya atılmıştır.

1958 yılına gelindiğinde Rosenblatt, öğrenme kuralını ve algılayıcı (perceptron) modelini oluşturarak günümüzde kullanılan kuralların temelini attı.

1959 da Stanford Üniversitesinde Bernard Widrow ve Marcian Hoff tarafından ADALINE ve MADALINE diye adlandırdıkları yapay sinir ağı modelini geliştirmişlerdir. ADALINE modeli, Rosentblatt'ın algılayıcı modeli ile benzer özelliklere sahip olmakla birlikte daha gelişmiş bir öğrenme algoritmasına sahiptir ve yapay sinir ağları üzerine sonraki araştırmaların temelini oluşturmuştur. MADALINE modeli ise gerçek bir soruna uygulanan ve hâlâ kullanılan ilk sinir ağıdır. Telefon hatlarındaki ses yankılarını gidermek için bir filtre olarak kullanılmaktadır. Bu modeller, mühendislik uygulamaları için yapılan ilk yapay sinir ağı araştırmalarını temsil eder.

Tüm bu çalışmalar devam ederken 1956 senesinde yapay zekâ kavramı ortaya çıkmıştır ve çalışmaların büyük çoğunluğu bu alana yönelmiştir. 1960 ve 1980 yılları arasında YSA için duraklama dönemi denilebilir. 1980 yılında YSA alanında yapılan araştırmalar tekrar ivme kazanmaya başladı.

1982 yılında Kohonen'e ait "Kendi kendine öğrenme nitelik haritaları" adlı çalışması yayınlanmıştır. (Furkan Keskenler & Fahri Keskenler, 2017)Yine aynı yılda Hopfield, Yapay Sinir Ağlarının geniş bir konu yelpazesini ele alabilme yeteneğini göstermiştir ve doğrusal olmayan Hopfield ağını geliştirerek optimizasyon gibi teknik sorunları çözmeyi amaçlamıştır. (Bozüyük et al., 2005; McCulloch & Pitts, 1943)

1986 yılında YSA için önemli bir kavram olan çok katmanlı algılayıcıların gelişiminde önemli bir kilometre taşı olan Rumelhart'ın paralel programlama üzerine çalışmalarını içeren ve iki cilt halinde yayımlanan eseri (McClelland & Rumelhart, 1986; Rumelhart & McClelland, 1986, 1988) bu araştırmaların temelini oluşturmuştur. Bu çalışma yapay sinir ağlarını tekrar popüler hale getirmiştir.

Yapay sinir ağları, ilk yıllarda teori ve laboratuvar deneyleri ile sınırlıydı, ancak 1990'larda günlük sistemlere entegre edilmeye başlandı ve geliştirilen uygulamaları sayesinde şimdi insanlar için pratik bir kullanım sunmaktadır. (Furkan Keskenler & Fahri Keskenler, 2017)

2.2.2.4. Yapay sinir ağlarının kullanım alanları

Yapay sinir ağlarının uygulamaları, genellikle veri filtreleme, ilişkilendirme, tahmin, sınıflandırma ve yorumlama süreçleriyle ilgili alanlarda kullanılmaktadır.

Bunlardan kısaca bahsedecek olursak;

Tahmin: Bu prensipte çalışan yapay sinir ağıları giriş değerlerinden çıkışları tahmin eder.

Veri Filtreleme: Yapay ağılara yönelik bu kodlamalar, toplanan veriler arasında kendisi için en işe yarayan veriyi kullanır.

Sınıflandırma: Sistemin daha hızlı sonuçlar üretmesine yardımcı olan giriş değerlerini sınıflandırır.

Veri yorumlama: Daha önce eğitilmiş ağılardan gelen girişleri analiz ederek bir olayın yeni yorumlarını üretebilmektedir.

Veri ilişkilendirme: Konuları daha önce öğrendiklerine bağlayarak ortaya çıkan bilgi eksikliklerini doldurur. (Öztürk & Şahin, 2018b)

Teknolojinin gelişmesi ile hayatımızda daha fazla yer alamaya başlayan Yapay sinir ağıları otomotiv, elektronik, enerji, uzay bilimleri, bankacılık, finans, askeri ve sağlık alanında etkin olarak kullanılmaktadır. İnsansız robot teknolojinin gelişimi ile YSA daha fazla ilgi görmeye devam edecektir. (Öztürk & Şahin, 2018b)

Yapay sinir ağlarının uygulama alanlarına örnek verilecek olursak; (Furkan Keskenler & Fahri Keskenler, 2017)

- Üretim planlama
- Kan analizi sınıflandırma
- Beyin modelleme çalışmaları
- Kalite kontrol, parmak izi tanıma
- Otomatik araç kontrolü
- Kredi kartı dolandırıcılığı tespiti
- Akıllı araç ve robotlar için optimal rota belirleme
- Mekanik parça ömrünün tahmini
- Ses tanıma, kontrol
- Meteorolojik verilerin yorumlanması
- Elektrik işareti tanıma
- El yazısı tanıma

- Hastalık teşhisi ve tedavisi
- Radar ve sonar sinyallerinin sınıflandırılması
- İstenmeyen e-posta filtreleme

2.2.2.5. Yapay sinir ağlarının avantajları ve dezavantajları

Yapay sinir ağları bazı avantaj ve dezavantajlara sahiptir. YSA'nın avantajları arasında, değişkenleri otomatik olarak değiştirme, doğrusal olmayan çok giriş ve çıkışlı sistemlerin basit modellenmesi, istatistik ve diğer modelleme teknikleri için gerekli olan verilerin kabul edilmemesi gibi durumlar yer almaktadır.

Yapay sinir ağlarının dezavantajları arasında ise, güvenli sonuçlar elde etmek için daha fazla veriye ihtiyaç duyulması, giriş ve çıkış değişkenleri arasındaki ikili ilişkinin bilinmemesi, eğer çok fazla adaptasyon sağlarsa rastgele görünebilmesi gibi durumlar sayılabilir.(Bozüyük et al., 2005)

2.2.3. Genetik algoritmalar

2.2.3.1. Genetik algoritmalar nedir?

Genetik algoritmanın tanımı yapmadan önce algoritmanın ne demek olduğuna bakmak gerekir. Algoritma " Bir problemi çözmek için tekrar edilen tarifler kümesidir." şeklinde tanımlanabilir. Genetik algoritmalar ise, biyolojik sistemlere benzer bir öğrenme mekanizmasına sahip bilgisayar programlarıdır. (Pirim, 2006)

Genetik algoritmaların temeli, doğal seçilim ve doğal genetik prensiplerine dayanır ki bu da Charles Darwin'in genetik alanındaki "doğal sistemde güçlünün hayatta kalma" teorisinden türemiştir. Genetik algoritmalar, problemin potansiyel çözümlerinin bir popülasyonu üzerinde çalışarak, en uygun bireyleri bir sonraki nesle aktarmanın ve bu bireylerin gelecek nesillerde çözüme daha yakın bireyler yaratmasının fikrine dayanır. Genetik algoritmalar, olasılık kullanır, ancak bu rastgele bir arama stratejisi değildir; bu yaklaşımın etkinliğini doğadaki canlıların evriminde de görebilmemiz mümkündür. (Karaoğlan, 2007)

Genetik algoritmalar, doğal seçilim ve doğal genetik yasalarına dayanan bir arama türüdür. Doğal seçilim, tabiat şartlarına uyum sağlamış olan canlının hayatta kalıp neslini devam ettirmesi, uyum sağlayamayan canlıların ise yok olması demektir. Doğal genetik yasalarına göre canlılar nesilden nesle genlerini aktarırken, başka genlerle çaprazlanır, değişime uğrar ve yeni genleri oluştururlar. Bu iki doğal oluşumu

birleřtirerek, genetik algoritmalar en iyi (optimal nokta) arayışında bulunurlar. Önceki nesilden en uyumlu bireyler, yeni neslin üyelerini oluşturmak için kullanılır. Bu teknik, geleneksel yöntemler kullanıldığında son derece zorlayıcı ve bazen çözümsüz olan sorunları çözmeyi mümkün kılar. (Karaođlan, 2007)

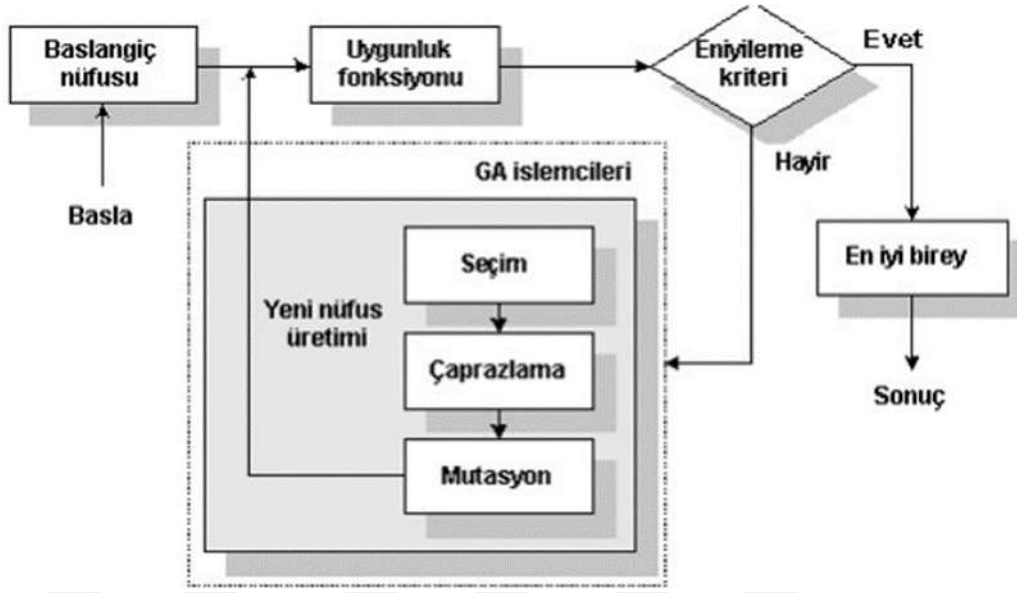
Genetik algoritmaların üzerinde çalıştığı bireyler, kromozom adı verilen bir dizi içinde düzenlenir. Genetik algoritmaların uygulandığı problemlere bađlı olarak, popülasyonun birey bileřimi deđiřir. Popülasyonun her üyesi ne kadar kesin bir şekilde tanımlanırsa, o kadar etkili bir şekilde problem çözümlür. Bařlangıç popülasyonu oluşturmak amacıyla kullanılan iki metot vardır:

- 1) Bir sayı üretici tarafından rasgele üretilmiř olası çözümler
- 2) Problem için belirli kořul ve kısıtları karřılayan olası çözümler

Genetik algoritmaların yapısında kritik bir rol oynayan uygunluk fonksiyonu sayesinde, bireylerin problemleri için en uygun çözümlün hangisi olduđunu bulabiliriz. Oluřturulan popülasyonun her üyesinin probleme uygun bir çözüml olup olmadığını belirleme sürecinde her bir kiři için belirlenen deđere "uygunluk fonksiyonu" denir. Her bir probleme özel olarak bir uygunluk fonksiyonu seçilmektedir. Tüm problemler için aynı uygunluk fonksiyonunun kullanılması dođru sonuç vermeyebilir. (Gündođdu, 2007)

Genetik algoritmalar ile yeni bir nesil oluşturulması için ařađıda yer alan 3 ařamadan geçmesi gerekmektedir. (Bozüyük et al., 2005)

- 1) Önceki nesilde yer alan her bir bireyin uygunluk deđeri hesaplanmalıdır.
- 2) Uygunluk deđerleri (uygunluk fonksiyonu) dikkate alınarak bireylerin seçme iřlemi yapılmalıdır.
- 3) Çaprazlama(crossover) ve mutasyon(mutation) gibi genetik algoritmalar kullanılarak seçilen bireyleri uyuşturma yapılmalıdır.



Şekil 9:Genetik algoritmaların adımları(Gündoğdu, 2007)

2.2.3.2. Genetik algoritmaların gelişim süreci

John Holland, Michigan Üniversitesi'nde bilgisayar bilimi ve psikoloji alanında uzmanlaşmış bir araştırmacı olarak, genetik algoritmalar üzerine ilk çalışmayı yürüten kişidir. John Holland'un genetik algoritma mantığı, Darwin'in evrim teorisine dayanmaktadır. Evrim teorisine göre, doğada en uyumlu olan birey yaşam hakkını elde eder. John Holland, "en iyi uyum sağlayan birey" fikrini dikkate alarak genetik algoritmaları geliştirmeye başlamıştır ve evrim prensiplerini oluşturmuş olduğu popülasyona uygulamıştır.

1975 yılında John Holland, evrim teorisinin prensiplerini bilgisayar ortamına uygulamıştır ve ortaya çıkan bulgularını yazdığı kitapta toplamıştır. 'Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence' adlı kitap, geliştirdiği genetik operatörler ve algoritmaların tartışmasını içermektedir. John Holland'ın 1975 yılındaki araştırması, genetik algoritmaların önemini ortaya koymasına rağmen, bu algoritmaların diğer alanlarda ilerletilmesi için daha fazla adım atılmamıştır.

1985 yılına gelindiğine ise, Holland'ın öğrencisi David E. Goldberg adlı inşaat mühendisinin gaz boru hatlarının kontrolü üzerine yaptığı doktora tezi, genetik algoritmaların çeşitli alanlarda uygulanabilirliğini ve ürettikleri etkili çözümleri

göstermiştir. David E. Goldberg, bu çalışması nedeniyle 1985 National Science Foundation Genç Araştırmacı ödülüne layık görülmüştür.

David E. Goldberg, 1989'da alanında bir klasik sayılan "Genetic algorithms in search, optimization, and machine learning " adlı kitabını yayımlayarak genetik algoritmalar ile ilgili ön yargıları ortadan kaldırmış olup aynı zamanda yaygın kullanım alanlarıyla ilgili bilgiler vermiştir. (Gündoğdu, 2007; Karaoğlan, 2007)

2.2.3.3. Genetik algoritmaların geleneksel arama yöntemleriyle karşılaştırılması

Genetik algoritmalar ile geleneksel arama teknikleri arasındaki dört temel fark şunlardır:

- 1) Genetik algoritmalar, çözümü ararken tek bir noktaya odaklanmak yerine bir çözüm grubunu kullanırlar.
- 2) Genetik algoritmalar, çözümleri parametre değerlerinde aramak yerine, çözümleri genetik kodlarında ararlar. Parametreler, kodlanabilir oldukları sürece çözümleri üretebilir. Bu nedenle, genetik algoritmalar, görevlerin ayrıntıları hakkında bilgi gerektirmeden görevleri nasıl gerçekleştireceklerini bilirler.
- 3) Genetik algoritmalar çözümü bulmak için türev ya da herhangi ek bir bilgiye ihtiyaç duymazlar. Bunların yerine uygunluk fonksiyonunu kullanırlar.
- 4) Genetik algoritmalar, deterministik kurallar yerine olasılıksal kuralları kullanır.(Gündoğdu, 2007)

2.2.3.4. Genetik algoritmaların avantajları

- Genetik algoritmaların (GA) yalnızca amaç fonksiyonunu başlangıç bilgisi olarak gerektirmesi, araştırmacının kesin bilgiye sahip olmaması veya alanında uzman olmaması durumlarında kullanılması önemli fayda sağlamaktadır.
- GA, mevcut potansiyel sonuçları değerlendirmenin yanı sıra yeni ve geliştirilmiş sonuçlar üretme amacına hizmet ettiği için diğer seçeneklere büyük ölçüde yardımcı olmaktadır.
- Genetik algoritmalar (GA), klasik yöntemlere göre daha uzun sürebilecek görevleri yeterince hızlı ve doğru bir şekilde tamamlayabilir, fakat bu konuda çok net olmayabilirler.

- GA, doğal evrimsel süreçlere dayanan bir arama türüdür. Bu teknik, geleneksel yöntemlerle çözülmesi son derece zor ve zaman zaman çözümsüz olan sorunları çözebilmektedir.
- Genetik algoritmaların (GA) gerçek optimal değeri bulma garantisi olmasa da birçok nesil sonrasında ideale çok yakın çözümler bulabilirler.
- Genetik algoritmaların optimizasyon problemlerini çözmede son derece başarılı olduğu kanıtlanmış ve çeşitli mühendislik problemlerin çözümü içinde kullanılmıştır.
- Çok amaçlı problemler ele alınırken genetik algoritmalar geniş bir çözüm yelpazesi sunmaktadırlar ve karar verecek kişiye en iyi sonucu seçme imkânı tanırırlar. (Karaođlan, 2007)

2.2.4. Derin öğrenme algoritmaları

2.2.4.1. Derin öğrenme algoritmalarının tanımı

Günümüzde mühendislik uygulamalarının odak noktası, insan gibi davranan ve düşünen programlar oluşturmaktır. Makine öğrenimi, insan olgularını mühendislik uygulamalarına dahil etmek için kullanılan terimdir.(Goldberg & Holland, 1988) Makine öğrenimindeki esas nokta, insan beynindeki sinirsel aktiviteden faydalanarak makineye öğrenmeyi ve ona benzer şekilde davranmasını sağlamaktır. (Fukushima, 1975) İnsan beyninde yer alan nöronların çalışma prensibinden yola çıkılarak yapay sinir hücre modeli oluşturulmuştur. Zamanla geliştirilen bu yapay sinir hücre modeli makine öğrenmesinde yaygın bir şekilde kullanılmıştır. (Dođan & Türkođlu, 2019)

2.2.4.2. Derin öğrenme yöntemleri

a) Konvolüsyonel Sinir Ağları (Convolutional Neural Network):

Hayvanların görme sisteminden esinlenilerek ortaya çıkan Konvolüsyonel Sinir Ağları (CNN), çok katmanlı ileri beslenmeli bir yapay sinir ađı türüdür. Derin öğrenme uygulamaları içinde en sık kullanılan yapay sinir ađıdır. Çođunlukla sınıflandırma ve tespit işleminde kullanılmasının yanı sıra görüntü analizlerinin yapılmasında da kullanılmaktadır.

b) Tekrarlayan Sinir Ağı (Recurrent Neural Network):

Tekrarlayan Sinir Ağları (RNN'ler), ağı giren verilerin yanı sıra önceki zaman serisinden gelen örnekleri de kabul eder. Bu sinir ağı, ardışık gelen verileri kullanmayı hedeflemektedir.

Geleneksel sinir ağlarında girişlerin birbirinde bağımsız olmasına karşın Tekrarlayan Sinir Ağlarında dizide yer alan verilerin çıkışı bir önceki hesaplama dayanmaktadır. Tekrarlayan Sinir Ağları (RNN'ler), sıklıkla dil çevrimleri için kullanılmasının yanı sıra ardışık yapıların bir dizisinden bir sonraki noktayı tahmin eder,

c) Uzun-Kısa Süreli Hafıza (LSTM- Long Short-Term Memory):

RNN mimarilerinde, zaman dizeleri arasında bağlam boşlukları varsa bir sonraki dizesini tahmin etmek zordur. Bu durumdan kurtulmak için Hochreiter ve Schmidhuber, çalışmalarında uzun ve kısa vadeli bellek (LSTM) önerdiler. RNN ağları ve LSTM ağları özünde aynıdır ancak gizli durumu hesaplamak için LSTM ağları, bir yapı kullanırlar. LSTM, bellek hücrelerini içermektedir. Bu, giriş verilerini ve önceki durumu depolayan bir hücredir.

d) Kısıtlı Boltzmann Makinesi (RBMRestricted Boltzmann Machine):

Boltzmann makinesi, giriş veri seti üzerinde olasılıksal dağılımları öğrenebilen bir sinir ağıdır. Özellik öğrenimi, regresyon ve sınıflandırma görevlerini gerçekleştirebilme yeteneğine sahiptir. İki katmandan oluşan bu yapıda giriş (görünür) katmanı ve gizli katman bulunur.

e) Derin İnanç Ağı (DBN-Deep Belief Network):

Derin İnanç Ağı, birbirini takip eden kısıtlanmış Boltzmann makineleri katmanlarından oluşan bir sinir ağı tekniğidir. Bu, sırayla kısıtlanmış Boltzmann makinelerini eğitip öğrenerek gerçekleştirilir.

f) Derin Oto-kodlayıcılar (Auto Encoder):

Derin oto-kodlayıcılar, denetimsiz öğrenmeye dayalı bir makine öğrenimi sistemidir. Bu sinir ağına Diabolo ağı da denir. Giriş veri setini sıkıştırarak, en az kayıpla en fazla öğrenmeyi amaçlamaktadır.

2.2.4.3. Derin öğrenme katmanları

- a) Giriş (Input) Katmanı
- b) Konvolüsyon (Convolution) katmanı
- c)Aktivasyon (Relu) katmanı
- d)Havuzlama (Pooling) Katmanı
- e) Tam Bağlı (Full-Connected) Katman
- f) Dropout Katmanı
- g) Sınıflandırma (Classification) katmanı
- h) Yumuşatma (Softmax) Katmanı
- i) Normalizasyon (Normalization) Katmanı

2.2.4.4. Derin öğrenme algoritmaları

- a.LeNet
- b. AlexNet
- c. ZF Net
- d. VggNet
- e. GoogleNet
- f. ResNet

2.2.4.5. Derin öğrenmenin uygulama alanları

- Doğal Dil İşleme
- Görüntü/Video işleme
- Biyomedikal Sinyal/Görüntü İşleme
- Endüstri
- Ses (Audi-Wave-Speech)
- Nesne Tespiti (Object Detection) (Doğan & Türkoğlu, 2019; Şeker et al., 2017)

2.2.5. Karınca algoritmaları

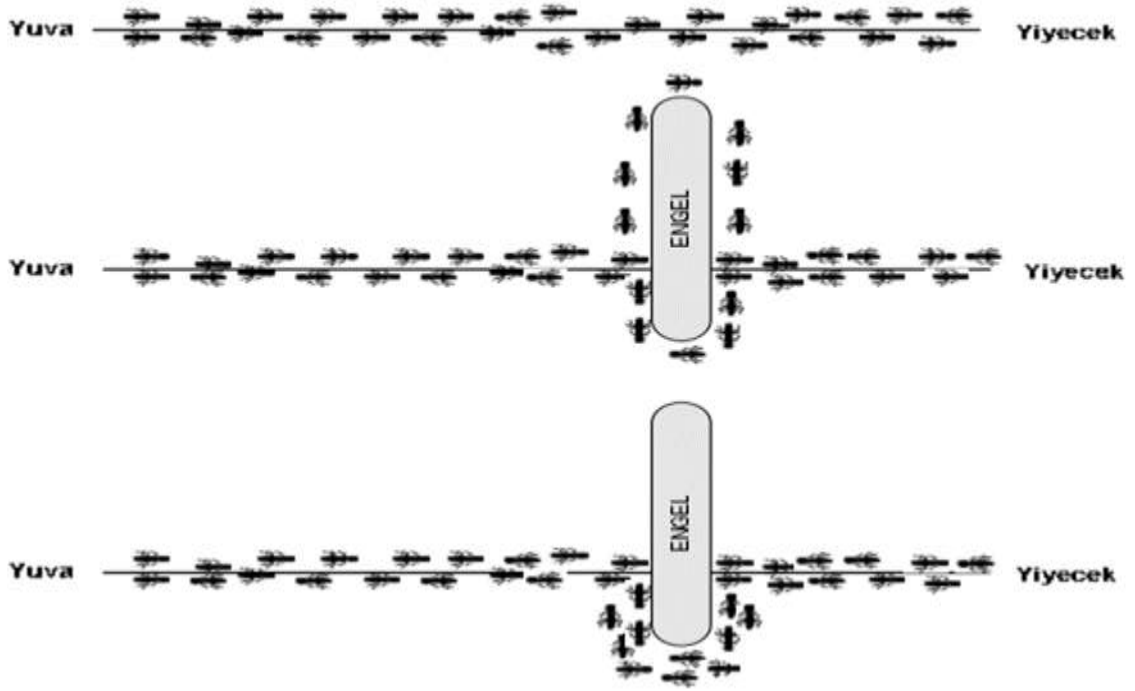
2.2.5.1. Karınca kolonisi optimizasyonu tanımı

Sürü zekâsı tabanlı meta-sezgisel metotlardan biri olan Karınca Koloni Optimizasyonu (KKO), karıncaların günlük yaşamlarında nasıl yiyecek aradıklarını taklit ederek 1991 yılında Dorigo tarafından geliştirilmiştir. (Elen & Ekmekçi, 2020) Karıncalar bireysel olarak basit yeteneklere sahip olmalarına karşın, koloni halinde iken yüksek düzeyde organize olmuşlardır. Karıncalar, köprü inşa etme, kendi boyutlarından çok daha büyük nesnelere taşıma ve yuvadan yiyeceğe en kısa yolu bulma gibi zor problemler için yaratıcı çözümler üretirler. Karınca Kolonisi Optimizasyonu (KKO) hesapsal optimizasyon problemlerini çözmek için yapay karınca kolonisi kullanılan meta-sezgisel tekniklerinden bir tanesidir. Başka bir deyişle KKO, gerçek karıncaların davranışlarından ilham almıştır. (Ş. Yılmaz, 2008)

Karıncalar, yiyecek kaynaklarından yuvalarına en kısa yolun uzunluğunu belirlemek için görme duyularını kullanmak zorunda değillerdir. Aynı zamanda çevrelerindeki değişikliklere uyum sağlayabilirler. Eğer dışarda yapılan bir müdahale nedeniyle şu anda izledikleri yol uzun hale gelirse, yeni en kısa yolu bulabilirler. (Söyler & Kesintürk, 2007)

Karıncalar, Şekil 10'da gösterildiği gibi düz bir çizgide yolculuklarına başlarlar ve bu esnada arkalarında "feromon" adı verilen bir madde bırakırlar. (Söyler & Kesintürk, 2007) Böceklerin koku yoluyla diğer böceklerle sosyal bağlar kurmak için salgıladığı uçucu maddeye "feromon" adı verilmektedir. (Elen & Ekmekçi, 2020) Bu madde, sonraki karıncaların yol bulmasını kolaylaştırmaktadır.

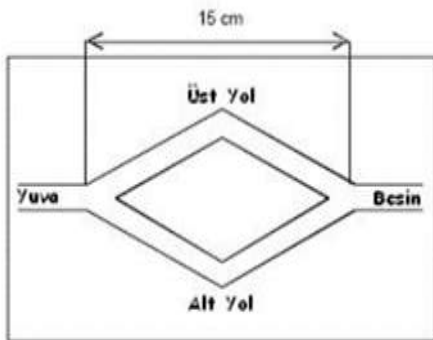
Karıncalar, önlerine herhangi bir engel konulduğunda feromonları takip edemediklerinden dolayı izleyecekleri iki yoldan birini rastgele seçerler. Daha kısa olan yolda birim zamana düşen geçiş sayısı daha fazla olduğundan salgılanan feromon miktarı da daha fazla olacaktır. Bu nedenle zamanla kısa yolu tercih eden karınca sayısı daha fazla olacaktır. Belli bir zaman sonra ise tüm karıncalar kısa olan yolu tercih edeceklerdir. (Söyler & Kesintürk, 2007)



Şekil 10: Gerçek karıncaların en kısa yolu bulması (Söyler & Keskinürk, 2007)

Karıncalar, başlangıçta rastgele bir yol seçtikten sonra, zamanla feromon yoğunluğunu takip ederek en kısa yolu bulurlar. Bu davranış, kolektif bilginin en yaygın örneklerinden biri olan otokatalitik davranış modelini temsil eder. (Elen & Ekmekçi, 2020)

Karıncaların yol seçim davranışları ile ilgili yapılan deneylerde de feromon izi takibinin bir karınca kolonisi içinde en kısa yolu bulduğunu göstermiştir. (Ş. Yılmaz, 2008) Bu alanda yapılan ilk deney Şekil 11’de gösterilen tek köprü deneyidir. (Deneubourg et al., 1990)



Şekil 11: Tek köprülü yol seçim deneyi (Ş. Yılmaz, 2008)

Bu deneyde; her bir yol üzerinde yiyecek ile yuva arasında aynı uzunluğa sahip bir köprü bulunmaktadır. Ardından karıncalara yiyecek ve yuva arasında rahatça hareket etmeleri için izin verildi ve iki yoldan hangisi seçeceklerini gözlemlemeye başladılar. Sonuç olarak, karıncalar bazı salınım hareketlerinin olabileceği ilk aşamadan sonra aynı yola yönelme eğilimi göstermişlerdir. Karıncalarda gözlemlenen bu davranışın nedeni ise yol tercihlerini etkileyen ve yolda birikmiş o feromon maddesidir. Feromon yayma mekanizması sayesinde, birden fazla köprüünün olduğu ve köprüyü oluşturan yolların uzunluklarının birbirinden farklı olduğu durumlarda karıncaların en kısa yolu seçtiği gözlemlenmiştir. Başlangıç aşamasında yol tercihi yaparken kısa olan yolu seçen karıncalar uzun yolu seçenlere göre yiyeceğe önce ulaşırlar ve geri dönmeye başladıklarında kısa yolda feromon miktarı daha fazla olduğundan dolayı karıncalar kısa olan yolu seçmeleri konusunda uyarılırlar. İleri hareket eden karıncalar ise feromon miktarına göre yol seçimini yaparlar. Sonuç olarak karıncalar kısa olan yolu tercih ederler. Dolayısıyla karıncaların başlangıçtaki rastgele hareketlerinin önemi azalır ve stokastik feromon takip davranışları ön plana çıkar. (Ş. Yılmaz, 2008)

Karıncaların yol seçim özelliği, belirli özelliklerin aynen alındığı ve bazı özelliklerin ise eklenmesi ile gerçek problemlerin çözümünde kullanılabilir düzeye getirilmiştir. Gerçek karıncalardan aynen alınan özellikler şunlardır;

- Karıncaların birbirleri ile feromon aracılığıyla kurduğu iletişim
- Feromon düzeyinin yüksek olduğu yolların önce tercih edilmesi
- Kısa yolların üstünde yer alan feromon miktarının daha fazla olması

Ekleme yapılan özellikler ise şöyledir;

- Zamanın ayrı olarak hesaplandığı bir ortamda yapay karıncaların yaşamasının mümkün olması
- Yapay karıncaların tam olarak kör olmayıp konu ile ilgili tüm bilgilere sahip olabilmesi,
- Belli bir düzeyde hafızaya sahip olabilen yapay karıncaların, sorunların çözümü için oluşturdukları bilgileri muhafaza edebilmesi(Ş. Yılmaz, 2008)

2.2.5.2. Karınca kolonisi optimizasyonu algoritmaları

Dorigo tarafından 1991'de ilk Karınca Kolonisi Optimizasyonu algoritmasını oluşturulmuştur. İşleme süresi ve çözüm kalitesi açısından algoritmanın performansını

artırmak ve daha iyi sonuçlar elde etmek amacıyla birçok KKO (Karınca Kolonisi Optimizasyonu) algoritması geliştirilmiştir. (Ş. Yılmaz, 2008)

Karınca Sistemi:

Karınca sistemi, karıncaların besin arama davranışının modellenmesiyle oluşturulan ilk KKO (Karınca Kolonisi Optimizasyonu) algoritmasıdır. Dorigo ve arkadaşları bu algoritmayı Gezgin Satıcı Problemini çözmek amacıyla geliştirmişlerdir. (Elen & Ekmekçi, 2020)

Genel olarak Karınca sisteminin çalışma şekli şu şekildedir;

Her karınca, olasılığa dayalı durum geçiş kuralına göre bir şehir seçerek tam bir tur oluşturur. Bu esnada karıncalar, kısa kenarlarla bağlı yüksek feromon miktarının olduğu alanlara gitmeyi tercih ederler. Her karınca turunu tamamladıktan sonra, global feromon güncelleme kuralı devreye girer. Tüm kenarlardaki feromonun bir kısmı buharlaşır, ardından her bir karınca, turunun ne kadar kısa olduğuna bağlı olarak turunun kenarlarına belirli bir miktar feromon salgılar. Yani çok kısa turların içinde bulunan kenarlara yüksek miktarda feromon verilir. Ardında bu süreç tekrarlanır.

Karınca sistemindeki her karınca, belirli özelliklere sahip bir ajan olarak karakterize edilir. Karınca, ziyaret edilecek noktayı, bağlantı kenarındaki mesafe ve iz (feromon) miktarına bağlı olarak belirlenen bir olasılıkla seçer; ancak geçerli bir tur tamamlanana kadar önceki ziyaret edilen noktalardan geçemez. Bu yetki yasak listesi adı verilen bir yapı tarafından kontrol edilir. Karınca bir turunu tamamladıktan sonra ziyaret ettiği kenarlara iz bırakan feromon maddesini yayar. (Ş. Yılmaz, 2008)

En temel KKO (Karınca Kolonisi Optimizasyonu) algoritması KS (Karınca Sistemi) algoritmasıdır. Daha sonrasında geliştirilen algoritmalar KS temelinde, bu algoritmanın daha da geliştirilmesi amacıyla yapılan güncellemeleri içermektedir. (Elen & Ekmekçi, 2020)

Rank Temelli Karınca Kolonisi Algoritması:

Rank temelli karınca koloni algoritmasında, sadece belirli sayıdaki karıncaların geçtiği yolların feromon izlerinin yenilenmesi yapılmaktadır. Tur uzunluklarına göre karıncalar sıralanır ve belli sayıdaki karıncaların geçtiği yollardaki feromon miktarı

turun uzunluđuna gre yenilenir. Sonu olarak, en yksek feromon gncelleme seviyesi, global en iyi zmde bulunmaktadır. (Syler & Kesintrk, 2007)

Karınca-Yođunluk, Karınca-Nicelik ve Karınca-evrim:

Karınca sistemi altında, Colorni, Dorigo ve Maniezzo (1991)  farklı yntem geliřtirmişlerdir. Bunlar, Karınca-Yođunluk, Karınca-Nicelik ve Karınca-evrim algoritmalarıdır. Bu  algoritmanın birbirinden farkı feromon izi gncelleme yntemidir. Karınca – yođunluk ve karınca-nicelik algoritmalarında karıncalar bir zm oluřturulurken feromon salgırlar; karınca-evrim algoritmasında ise karıncalar tam bir turu tamamladıktan sonra feromon salgırlar.

Karınca-evrim algoritması sonuların ne kadar iyi retildiđiyle orantılı olarak bıraktıkları global bilgiyi kullanırlar. Aslında, daha kısa yollar oluřturan karıncaların iz miktarına olan etkisi diđer karıncalardan daha fazladır. Karınca-nicelik ve karınca-yođunluk algoritmaları ise yerel bilgiyi kullanmaktadırlar.

Yapılan arařtırmalar sonucunda karınca-evrim algoritmasının performansının diđer iki algoritmadan daha iyi olduđu gsterilmiştir. (ř. Yılmaz, 2008)

Maksimum-Minimum Karınca Sistemi:

1997 yılında Sttzle ve Hoos tarafından geliřtirilmiştir. Maks-Min Karınca Sistemini (MMKS), Karınca sisteminden ayıran iki tane ana özelliđi vardır:

- 1) zm sađlamak iin, her bir iterasyon sırasında sadece bir karıncanın feromonu yenilemesine izin verilmektedir. Bu karınca ise, nceki iterasyonda en iyi zm sađlayan karıncadır.
- 2) Arama dalgalanmalarını nlemek iin feromon izlerine sınırlı bir aralık belirlenmektedir.

Feromon izleri st sınırdan bařlatılır ve bu da bařlangıta yksek oranda iyileřme sađlar. MMKS'de, alt ve st sınırlar uygun řekilde seilmezse, tm karıncaların aynı yolu takip etmesi, iyi bir zm bulmayı zorlařtıracaktır. (ř. Yılmaz, 2008)MMKS algoritmasının her bir evriminde, yalnızca en bařarılı karıncanın feromon gncellemesine izin verilmektedir. (Elen & Ekmeki, 2020)

Ant-Q:

Ant-Q algoritması, Q-öğrenmeden bazı kavramları içeren ve KS'nin bir uzantısı olan algoritmadır. Gambardella ve Dorigo tarafından 1995 yılında önerilmiştir. Bu algoritmadaki asıl farklılık feromon güncelleme değeri hesaplanırken öğrenme basamağı parametresinin(γ) de dikkate alınmasıdır. (Ş. Yılmaz, 2008)

Çoklu Karınca Sistemi:

Bu yaklaşımda ise iki ya da daha fazla koloninin çözümünün birleştirilmesi temeline dayanmaktadır. (Ş. Yılmaz, 2008)

Melez Karınca Kolonisi Optimizasyonu:

Melez Karınca Kolonisi Optimizasyonu (MKKO), KKO algoritmasına ek olarak yerel arama içermektedir. MKKO yerel aramayı ise şu şekilde uygulamaktadır; ilk olarak karıncalar kendi çözümlerini oluştururlar, ardından yerel arama rutininin uygulaması ile her çözüm kendi yerel optimumuna taşınır. Daha sonra, feromon izi güncelleme kuralı, yerel olarak optimal çözümleri ile kenarlardaki feromon izlerini güncellemek için uygulanır. (Ş. Yılmaz, 2008)

Global Karınca Kolonisi Optimizasyonu:

Global Karınca Kolonisi Optimizasyonu (GKKO), bütün düğümlere uğramak gibi bir kısıtlamanın olmadığı durumlarda kullanılmak için geliştirilen bir KKO algoritmasıdır. Diğer KKO algoritmalarından farklı olarak, karıncaların bir tam tur yapma zorunluluklarının olmamasıdır. GKKO'da feromon güncellemesi sadece global olarak yapılmaktadır. Bu güncelleme, sadece en iyi turu yapan karıncanın değil, tüm karıncaların yolları için uygulanmaktadır. (Ş. Yılmaz, 2008)

Karıncalar:

Karıncalar (ANTS), 1999 yılında Maniezzo tarafından önerilmiş KS'nin uzantısı olan bir algoritmadır. ANTS, Yaklaşık Nondeterministik Ağaç Araştırma'nın (Approximated Nondeterministic Tree Search) cümlesinin İngilizce anlamının baş harflerinden oluşmaktadır. Bir ajan veya karınca, ANTS algoritmasında iyi sonuçlar elde etmek için geçmiş çözüm bilgilerine dayanarak geçmişte etkili olduğu kanıtlanmış

faaliyetleri seçmelidir. Ancak, bu seçenekleri araştırmak için ajanın önce seçilmemiş faaliyetleri denemesi gerekmektedir (yeni çözümler keşfetme). (Ş. Yılmaz, 2008)

Karınca Kolonisi Sistem:

Dorigo ve Gamberdella (1997), KS performansını artırmak amacıyla Karınca Kolonisi Sistem (KKS) algoritmasını geliştirmişlerdir. Karınca kolonisi sistemi'ni karınca sistemi' den ayıran 3 temel farklılık vardır. Bunlar;

- 1) Karıncalar yeni bir çözüm oluştururken yerel feromon güncelleme kuralını uygulamaktadırlar.
- 2) En iyi karınca turunun olduğu kenarlara global güncelleme kuralı uygulanmaktadır.
- 3) Durum kuralı yeni kenarların araştırılması, bir öncekinin ve problem hakkında biriktirilen bilginin kullanılması arasında dengenin kurulması için yeni bir yol sağlamaktadırlar. (Ş. Yılmaz, 2008)

2.2.5.3. Karınca kolonisi optimizasyonu algoritmalarının uygulandığı problemler

Dorigo 1991 yılında karınca algoritmalarını Gezgin Satıcı Problemi (TPS) veya Kuadratik Atama Problemi (QAP) gibi optimizasyon problemlerine çözüm olarak geliştirmiştir. Bilimsel alanda birçok karınca tabanlı algoritmaların temel alındığı çalışmalar yapılmaktadır. Bu problemler şunlardır;(Ş. Yılmaz, 2008)

- Gezgin Satıcı Problem
- Araç Rotalama Problemi
- Kuadratik Atama Problemi
- Atölye Tipi Çizelgeleme Problemi
- En Kısa Ortak Süper Ardıllık Problem
- Çizge Boyama Problemi
- Ardışık Sıralama Problemi
- Dinamik Kombinasyonel Optimizasyon Problemler

Gezgin Satıcı Problem:

Gezgin Satıcı Problemi (TSP), seyahat eden bir satıcının görmesi gereken tüm şehirleri ziyaret ederken, herhangi bir şehirden başlayıp en uygun maliyetle en kısa yolu bulup tekrar başladığı yere dönmesini vurgulayan bir optimizasyon problemidir. Bu

problemin çözümü için günümüze kadar birçok algoritma geliştirilmiş olup çözüme kavuşturulmaya çalışılmıştır.

Gezilen şehir sayısı arttıkça problemde daha karmaşık hale gelmektedir. 1800'lü yıllarda matematikçiler William Rowan Hamilton ve Thomas Penyngton Kirkman, TSP ile ilgili matematiksel problemler üzerinde çalışmışlardır. Gezgin satıcı probleminin çözümünde amaç, belli bir sayıda şehir ve bir şehirden diğerine hareket maliyeti verildiğinde her şehri bir kez ziyaret ederek ve sonunda başlangıç şehrine dönen en ucuz turun bulunmasıdır.(Ş. Yılmaz, 2008)

Gezgin Satıcı Problemi (TSP), karınca kolonisi optimizasyonu içerisinde önemli bir yere sahiptir. Bunun nedeni ise TSP' nin bu yöntemle çözülmeye çalışılan ilk problem olmasıdır. TSP'nin Karınca Kolonisi Optimizasyonu algoritmaları ile çözülmesi için seçilmesinin nedenleri şunlardır;

- TSP'nin zor bir problem olması
- Hesapsal optimizasyon alanında en fazla çalışılan problemlerden biri olması
- TSP'nin tanımlanması ve ifade edilmesinin kolay bir problem olması
- Karınca kolonisi metaforunun uyum sağlamasının diğerlerine göre daha kolay olması (Ş. Yılmaz, 2008)

2.2.6. Psikiyatride yapay zekâ

Küresel düzeyde, kamu sağlığı için en büyük sorunlardan biri psikiyatrik bozukluklardır. Psikiyatrik bozuklukların yaratmış olduğu etki bireyin dışında aynı zamanda aileleri ve toplumu da etkilemektedir. Yapılan çalışmalara göre, psikiyatrik bozukluğu olan hastaların fiziksel morbiditeye ve erken ölüme sahip olmaları, günlük yaşamları ve genel toplumu önemli ölçüde olumsuz etkilemektedir. COVID-19 pandemisi ile anksiyete, depresyon ve travma sonrası stres bozukluğu gibi hastalıkları yaşayanların sayısında artış meydana gelmiştir. Artan bu yük nedeniyle, psikiyatrik bozuklukları prodromal aşamada doğru bir şekilde tanımlamak ve bireyselleştirilmiş tedavi sağlamak gerekir; bu amaçla yüksek performanslı yapay zekâ (AI), çok boyutlu klinik ve biyolojik verileri analiz edebilir.

Psikiyatri araştırmalarında ve tanısında, yapay zekâ temelli uygulamalar hızla gelişmiştir. Küresel anlamda aratan bu ilgi ve yaygınlaşan ruh sağlığı krizine karşı önlem alma ihtiyacından dolayı, son yıllarda psikiyatrik bozukluklara yönelik yapay

zekâ temelli yaklaşımlar üzerinde daha fazla araştırma yapılmıştır. Yapay zekâ, ruhsal hastalıkların teşhis edilme ve anlaşılma şeklini önemli ölçüde değiştirme potansiyeline sahiptir. Genel olarak, psikiyatrik bozuklukların patofizyolojisinde büyük ölçüde heterojenlik bulunmaktadır. Yapay zekâ teknolojileri, bir kişinin psikiyatrik bir bozukluğa yatkınlığını veya olasılığını daha kesin bir şekilde belirlemek için, daha doğru risk modelleme yapabilir ve teşhis tarama araçlarını oluşturabilir. (Jie Sun et al., 2023)

2.2.6.1. Bulanık mantık

2.2.6.1.A. Majör depresif bozukluklar:

Yapılan çalışmalar, depresyonu belirli semptomları olan en yaygın ruhsal bozukluk olduğunu göstermektedir. Bu semptomlar arasında keder, ilgisizlik, kötümserlik, iştah bozukluğu, kilo alımı veya kaybı, intihar düşünceleri, yorgunluk ve aralıklı olarak ortaya çıkan fiziksel ağrılar bulunmaktadır. Ancak bir hasta bu semptomlardan sadece bir kısmını yaşayabilir ve bu semptomların şiddeti her hastada aynı düzeyde olmayabilir. Semptomların şiddeti yüksek olduğu zaman kişileri intihara sürükleyebilir. Depresyon, intihar edenler arasında en yaygın görülen ruhsal bozukluklardan biri olarak bilinir. Depresyonun birçok nedeni olduğu düşünülse de stres, klinik ve prelinik araştırmalara göre depresyonun yaygın olmasında temel faktördür. Depresyonda olanların çoğunlukla negatif düşüncelerden etkilendiği kanıtlanmıştır. Sadece dünyayı kasvetli bir yer olarak algılamakla kalmazlar, aynı zamanda her şeyin başlangıçta düşündüklerinden daha da kötü olduğunu inanırlar. Bu negatif düşünceler, birçok araştırma anketine göre ruhsal bozuklukların ana nedenidir ve stresin doğrudan bir sonucudur. Aynı zamanda, hastanın negatif düşünceleri ile depresyon derecesi arasında doğrudan bir ilişki olduğuna inanılmaktadır.

Birinci basamak sağlık hizmetinde, depresyon belirtileri tartışmalı, gizemli ve belirsizdir. Bazı hastaların diğerlerinden daha fazla belirti sergilemesi mümkündür, bazılarında ise daha az belirti görülebilir. Cinsiyet, yaş, eğitim düzeyi, iş durumu, refah durumu, etnik köken ve ırk gibi faktörlerin belirtilerin şiddeti üzerinde etkisi olduğu unutulmamalıdır. 2012'de Iyer ve Khan, depresyon belirtilerini şu şekilde açıklamışlardır:

- Sürekli üzüntü, endişeli veya boş ruh hali
- Umutsuzluk, karamsarlık

- Suçluluk, değersizlik, çaresizlik
- Önceki hobilere ve seks gibi aktivitelere karşı ilgisizlik
- Uyku bozuklukları
- İştah bozuklukları
- Enerjinin azalması, yorgunluk, yavaşlama
- İntihar düşünceleri, intihar girişimleri
- Huzursuzluk, sinirlilik
- Konsantre olma, hatırlama veya karar vermede zorluk
- Baş ağrıları, sindirim bozuklukları ve kronik ağrılar gibi tedaviye yanıt vermeyen fiziksel belirtiler

Mental bozuklukların belirtileri ölçülemez doğası, psikolojiyi karmaşık bir alan haline getirmiştir. Bu, bu hastalık için özel bir tıbbi testin bulunmadığını ve tanı belirsizliği olabileceği anlamına gelir. Anketler, depresyonu teşhis etmenin en önemli yöntemidir. Beck Hamilton Depresyon Değerlendirme Ölçeği, Depresyon Envanteri (BDI-II) (HDRS), Zung'un ölçeği, Mental Bozuklukların Birinci Basamak Değerlendirmesi (PRIM-MD) ve doktorların hastalarının depresyon düzeylerini ölçmek için kullandığı 9 maddeli Fiziksel Sağlık Anketi (PHQ9) gibi birçok popüler anket bulunmaktadır. Bu duygu ölçme araçları, depresyonun var olup olmadığını ve hangi düzeyde olduğunu göstermektedir.

Bulanık mantık, depresyon teşhisinde karmaşık ve belirsiz verilerle başa çıkmak için etkili bir yöntem olarak kullanılmaktadır. Bu yaklaşım, kesin sınıflandırmalar yapmak yerine belirsiz durumlarla başa çıkar ve daha esnek ve insana benzer karar vermeyi sağlar. Depresyon belirtileri subjektif ve belirsiz olduğu için bulanık mantık teşhis sürecinde sıkça kullanılır. Bulanık mantık kullanarak depresyon teşhisi yapmak, belirtileri değerlendirmek ve risk seviyelerini belirlemek mümkündür. Örneğin, sürekli melankoli, umutsuzluk ve suçluluk gibi belirtiler, bulanık kümelerle ilişkilendirilerek değerlendirilebilir. Bu sayede bulanık mantık, belirtilerin karmaşıklığı ve çeşitliliği ile daha etkili bir şekilde başa çıkabilir.

Fazel Zarandi ve ark. yaptığı çalışma ile geliştirilen genel tip-2 bulanık uzman sisteminin, depresyon teşhisi için başarılı bir yöntem olduğu belirtilmiştir. Bulanık mantık, belirsiz verileri yönetmek ve karmaşık ilişkileri simüle etmek için etkili bir metottur. Tip-1 bulanık mantık sistemlerine kıyasla, genel tip-2 bulanık uzman sistemler

daha karmaşık ve belirsiz verilerle başa çıkmak için daha uygun bir yöntemdir. Bu çalışmada depresyon teşhisi, Beck Depresyon Envanteri-II (BDI-II) testi kullanılarak yapılmıştır. BDI-II depresyon belirtilerini ölçmek için yaygın olarak kullanılan araçlardan biridir. Bu test, hastaların kendi kendilerine rapor vermelerini gerektiren bir anket şeklinde uygulanmaktadır. BDI-II testi, bireylerin depresyon belirtileri hakkında kendilerini değerlendirmelerini sağlayan 21 sorudan oluşmaktadır. Bu sorular, bireylerin duygusal, bilişsel ve somatik belirtilerini değerlendirmek amacıyla hazırlanmıştır. Bireyler, her bir soruya belirli bir puan vererek kendi durumlarını değerlendirirler. Test sonuçları, belirli bir eşik değeri üzerinden değerlendirilerek bireyin depresyon düzeyi belirlenir. Genel tip-2 bulanık uzman sistem, çalışma katılımcılarının depresyon seviyelerini değerlendirmek için BDI-II testi ile entegre edildi. Bu entegrasyon sayesinde hastaların yanıtları kullanılarak depresyon teşhisi konulması ve hassas bir tedavi planı başlatılması hedeflenmiştir. Bu makalede şu şekilde bir yöntem izlenilmiştir;

- 1) İlk olarak, genel tip-2 üyelik fonksiyonları oluşturmak için aralıklı anlaşma yaklaşımı (IAA) ve zSlices yöntemi kullanıldı. Bu aşama belirsizlikleri ele almak ve verileri modellemek için önemlidir.
- 2) Hastaların sorunları Beck Depresyon Envanteri-II (BDI-II) aracı kullanılarak değerlendirildi. Bu test hastaların kendi depresyon belirtilerini ve özsaygılarını değerlendirebilme imkânı sunar.
- 3) Hastaların yanıtlarına dayanarak, bulanık mantık işlemleri kullanıldı. Bu prosedürler depresyon teşhisi koymak ve belirsiz verilerle ele almak için uygulanmıştır.
- 4) Geliştirilen genel tip-2 bulanık uzman sistem, hastaların verdiği cevaplara göre depresyon teşhisi koymak için kullanıldı. Bu sistem tarafından göz önünde bulundurulan iki ana hedef doğruluk ve teşhis süresidir.

Bu çalışmanın sonucunda ise geliştirilen genel tip-2 bulanık uzman sistemi, depresyon teşhisi için başarılı bir yöntem olarak ortaya çıkmıştır. Depresyon teşhisinde yüksek doğruluk düzeyine sahip olan bu yöntem diğer geleneksel tekniklerle karşılaştırıldığında daha doğru sonuçlar vermektedir. Aynı zamanda teşhis süresinde de başarılı olduğu söylenebilir. Özellikle normal ve ciddi depresyon seviyelerini doğru bir şekilde teşhis etme konusunda yüksek başarı oranları elde edilmiştir. (Fazel Zarandi et al., 2019)

Abolfazl Ghorbani ve ark. Artificial Intelligence in Medicine dergisinde yayınladıkları “Using type-2 fuzzy ontology to improve semantic interoperability for healthcare and diagnosis of depression” isimli makalede de bulanık mantık ve depresyon arasındaki ilişki incelenmiştir. Çalışma, bulanık mantık ve ontoloji yaklaşımlarının, depresyon gibi zihinsel sağlık sorunlarının karmaşık ve belirsiz doğasını ele almadaki potansiyel uygulamalarını araştırmaktadır. Bulanık mantık özellikle depresyon gibi konularda belirsizlikleri ele almak ve karmaşık kavramları açıklamak için kullanılan etkili bir tekniktir. Tip-2 bulanık mantığın, daha dinamik ve karmaşık ortamlardaki belirsizliği ele almak için oluşturulduğu vurgulanmaktadır. Bu çalışma, depresyon teşhisi ve tedavisine ilişkin karar verme süreçlerinde tip-2 bulanık mantık ve ontolojinin önemli bir potansiyel oluşturduğunu göstermektedir. Bu çalışmada tip-2 bulanık mantık ve ontoloji tekniklerinin entegrasyonu ile depresyonun semantik uyumluluğu artırmak ve tanı ve tedavi süreçlerinde daha doğru kararlar vermeyi amaçlamaktadır.

Çalışmada önerilen sistem 4 aşamadan oluşmaktadır:

- 1. Aşama:** Hastanın elektronik kayıt deposudur ve kişisel bilgilerin yanı sıra hastanın adını, cinsiyetini, yaşını ve tıbbi geçmişini de barındırır.
- 2. Aşama:** Hastaların tıbbi bakım bulanık ontoloji veri tabanıdır. Anlamsal olarak açıklandıktan sonra hastanın tüm değişkenleri (dopamin, kortizol, büyüme hormonu, norepinefrin ve tiroid gibi) ve psikolojik semptomları bu veri tabanında tutulur. Bulanıklaştırma için bu veriler girdi değişkenleri olarak kabul edilir. Daha sonra tip-2 bulanık mantık kullanılarak bu değişkenlerin her biri için bir üst limit ve bir alt limit belirlenir. Ayrıca giyilebilir sensörlerden elde edilen bilgiler sensör ontoloji içerisinde tutulmaktadır. Hastanın kalp atış hızı, vücut ısısı, hareket derecesi ve aktivite düzeyi bu veriler arasında yer almaktadır.
- 3. Aşama:** Giriş değişkenlerini çıkış değişkenlerine tanımlamak için ontoloji veri tabanında belirtilen kural ve düzenlemeleri kullanan bulanık çıkarım sistemidir. Tip indirgeyici, Çıkarım fonksiyonunun tip-2 bulanık çıktısını tip-1 bulanık kümelerine dönüştürme işlemini yapar. Bu adımda, tip-2 bulanık çıktılar tip-1 bulanık kümelerine indirgenir. Defazifikasyon, tip azaltıcının ortalama değerini, yani hastalık şiddetini hesaplar. Bu değerler daha sonra daha fazla işleme, işaretleme ve insan bilgisi ile entegrasyon için bir bulanık ontolojiye aktarılır. Bu amaçla, veriler hastalığın seviyesini tanımlamak için üç dil değişkenine (normal, orta ve yüksek) haritalanır.

4. **Aşama:** Kontrol ve karar verme katmanını oluşturan uygulamalar veya akıllı ajanlar, mevcut duruma ve hastanın bozulan sağlık durumuna göre bilinçli kararlar alabilmektedir.

Bu aşamalar ile, hastaların tıbbi verilerinin bulanık mantık ve ontolojiye uygun şekilde işlenerek daha doğru tanımlar yapılmasını ve tedavi süreçlerinin iyileştirilmesini amaçlamaktadır.

Bulanık mantığın depresyonda kullanılmasının birçok avantajı bulunmaktadır. Bunlar arasında;

- Depresyon gibi ruhsal hastalıkların belirtileri ve semptomları genellikle belirsizdir. Bu belirsizlikle başa çıkmanın en önemli yöntemlerinden biri ise bulanık mantıktır. Çünkü bulanık mantık kesin sınırlar yerine belirsizlik aralıklarını kullanarak işlem yapar.
- Bulanık mantıkta sözlü ifadeler matematiksel ifadelere çevrilerek kullanılır. Depresyon hastaları ise semptomlarını sözel olarak dile getirirler. Dolayısıyla bulanık mantık bu sözel ifadeleri dönüştürerek işlem yaptığından depresyonun tanı ve tedavisinde doğru karar verme noktasında önemli rol oynamaktadır.
- Bulanık mantık yöntemi kullanılarak kişiye özel tedavi planı oluşturulabilir.
- Bulanık mantık karmaşıklıklara ve belirsizliklere odaklanarak, daha kesin ve doğru sonuçlar ortaya çıkarabilir. Bu da depresyon teşhisi ve tedavisi konusunda daha iyi kararlar alınmasına yardımcı olabilir. (Ghorbani et al., 2023)

Depresyonun teşhis ve tedavisinde bulanık mantık kullanılması ile ilgili yapılan çalışmalara diğer bir örnek ise Anand Singh Rajawata ve ark. tarafından yayımlanan “Fusion Fuzzy Logic and Deep Learning for Depression Detection Using Facial Expressions” isimli makaledir. Bu makalede ise yüz ifadeleri üzerinden Bulanık mantık ve Evrişimsel Sinir Ağı yöntemlerinin birleştirilmesiyle depresyon teşhisinin yapılması amaçlanmaktadır. Bu çalışmada bulanık mantık kullanılarak yüz ifadelerinin analizi, depresyon belirtilerinin tespitinin yapılması sağlanmaya çalışılmıştır. Bu yaklaşım, depresyon belirtilerini göstermek için yüz ifadelerinin karmaşık detaylarını ve duygusal ifadelerini bulanık mantık kurallarıyla değerlendirmiştir. Ayrıca, derin öğrenme modelinin bulanık mantık ile birleştirilmesi, yüz ifadesi verilerindeki depresyon durumlarının daha doğru bir şekilde analiz edilmesine olanak tanımıştır. Bulanık

mantık, yüz ifadelerinin analizindeki karmaşıklığı ele almıştır, bu da onun depresyonu ve belirtilerini tespit sürecinde önemli bir rol oynamasını sağlamıştır.

Bu teknik ile insan tanıma karşılaştırılabilir %94,3 gibi yüksek ve kesin bir doğruluk oranı elde edilmiştir. (Rajawat et al., 2023)

2.2.6.1.B. Sosyal anksiyete bozukluğu:

Sosyal anksiyete bozukluğu diğer insanlarda olumsuz bir değerlendirme alma korkusudur. (Evren, 2010) Sosyal anksiyete bozukluğunun %80' i 20' li yaşına kadar tanısını almış olmakla beraber kronik olarak seyreden önemli bir halk sağlığı sorunudur. Yapılan araştırmalar sosyal anksiyete bozukluğunun kadınlarda erkeklere oranla daha yüksek olduğunu ortaya koymuştur ve genel olarak psikiyatrik hastalıkların öncüsü olarak görülmektedir. Sosyal anksiyete bozukluğunun en önemli özelliği başkaları tarafından olası bir olumsuz değerlendirme karşısında aşırı korku ve kaçınma davranışı sergilemeleridir. (Crane et al., 2021)

Sosyal anksiyete bozukluğunun teşhis ve tedavi edilmesindeki zorluk kişileri depresyon, yeme içme bozukluğu, uyuşturucu kullanımına yönlendiren bir durum. Dolayısıyla Sosyal Anksiyete Bozukluğu tanısının konulmasını kolaylaştıran sistemlerin tasarlanması gerekmektedir.

Sina Fathi ve ark. sosyal anksiyete bozukluğu için yapay zekâ temelli bir karar destek sistemi geliştirmişlerdir. "Development and use of a clinical decision support system for the diagnosis of social anxiety disorder" isimli araştırmada sosyal anksiyete bozukluğunun (SAD) teşhis ve sınıflandırılması için klinik karar destek sisteminin geliştirilmesinde Adaptive Neuro-Fuzzy Inference System (ANFIS) tekniği ve 5-kat çapraz doğrulama kullanılmıştır. Çalışmada gerçek dünya veri setleri kullanılarak, veri ön işleme, özellik seçimi, kümeleme ve anormallik tespiti adımlarını içeren bir metodoloji geliştirilmiştir. ANFIS tekniği bulanık mantık ve yapay sinir ağlarının birleştirilmesi ile oluşturulmuş bir tekniktir. Bu yöntem ile SAD semptomlarının belirsiz doğasını bulanık mantık ele alırken gürültülü verileri yapay sinir ağları işlemektedir. Araştırmanın sonucunda sosyal anksiyete bozukluğunun tanısında yapay zekâ tekniklerinin etkin bir şekilde kullanılabilceği, anormallik tespiti ve özellik seçimi adımlarının, karmaşıklığı azalttığı ve model doğruluğunu artırdığını göstermektedir. ANFIS tekniği ile elde edilen doğruluk oranı %98,67 olarak tespit edilmiştir.

Bu çalışma, Sosyal Anksiyete Bozukluğu (SAD) teşhisi için etkili olan bulanık mantık tabanlı bir karar destek sistemi oluşturmanın ne kadar önemli olduğunu vurgulamaktadır. Karmaşık ve belirsiz ruhsal hastalıkların teşhisi için bu yaklaşım oldukça faydalı olabilir. (Fathi et al., 2020)

2.2.6.1.C. Psikoz:

Psikoz, dünya nüfusunun yaklaşık olarak %2-3'lük kısmını etkileyen, nöropsikiyatri çatısı altında olan ruhsal hastalıklardan bir tanesidir. (Chattopadhyay et al., 2008) Psikoz, kişinin gerçeklikle olan bağlantısının kopmasına yol açan duygular, düşünce ve davranış bozuklukları olarak tanımlanabilir. (Bora, 2023)

Psikozun özellikleri;

- Gerçeklikle olan temasın kaybolması
- Halüsinasyon ve sanrılarının görülmesi
- Paranoya olarak isimlendirilen inançların sürdürülmesi
- Karmaşık duygusal ifadelerin gösterilmesi

Psikozun belirtileri perimenapozal sendrom gibi psikiyatrik olmayan birçok hastalıkla benzerlik gösterebilir. Dolayısıyla semptomlar arasındaki bu benzerlik psikotik hastalıkları izole etmeyi zorlaştırmaktadır. Günümüzde artan psikoz vakalarının teşhisi için birçok çalışma yapılmaktadır. Bu çalışmalar da yapay zekâ tekniklerinden de faydalanılmaktadır.

S. Chattopadhyay ve ark. bu konu ile ilgili bir çalışma yapmışlardır. Bu çalışmada amaç yetişkin psikozlarının tespit edilecek bir sınıflandırma sistemi geliştirmektir. Psikoz belirtilerinin karmaşıklığı ve belirsizliğini ele almak için bulanık mantık kullanılmıştır. Psikoz verilerini, bulanık kümeleme yöntemi kullanılarak bulanık sınıflayıcılar geliştirilmiştir.

S. Chattopadhyay ve ark. yapmış oldukları çalışma ile bulanık mantık tabanlı uzman sistemler (ES) geliştirilerek, doktorların mantığını taklit eden bir yaklaşım benimsemişlerdir. Çalışmadaki ilk adım hastalar ile yapılan görüşmeler ve klinik gözlemler ile elde edilen verilerin toplanmasıdır. Bu veriler 40 psikiyatrist ile yapılan görüşmeler sonucunda toplanmıştır. Uzmanlar **Brief Psychiatric Rating Scale – F2 (BPRS-F2)** ölçeği kullanılarak psikoz ile ilgili 24 semptom belirlenmiştir. Belirlenen

semptomlar arasında somatik kaygı, anksiyete, depresyon, intihar düşünceleri, suçluluk, düşmanlık, elasyon, grandiyozite, şüphecilik, halüsinasyonlar, alışılmadık düşünce içeriği, tuhaf davranış, öz ihmal, dezoryantasyon, kavramsal dağınıklık, duygusal çekilme, motor yavaşlama, gerginlik, iş birliği yapmama, heyecan, dikkatsizlik ve motor hiperaktivite gibi durumlar bulunmaktadır. Yapılan görüşmeler de Şizofreni, mâni, depresyon ile psikoz, sanrılı bozukluk, şizoafektif bozukluk, organik psikoz ve katatoni gibi 7 ana hastalık belirlenmiştir. Çoklu regresyon analizi yöntemiyle semptomlar ile hastalıklar arasındaki ilişkileri anlaşılmaya çalışılmıştır. Elde edilen bu veriler **Bulanık C-Ortalama (FCM)** ve **Entropi Tabanlı Bulanık Kümeleme (EFC)** algoritmaları kullanılarak kümelendi. Bu teknikler, verilerin daha iyi organize edilmesini ve analiz edilmesini sağlamaktadır. **Bulanık C-Ortalama (FCM)**, verileri kümelere ayırarak, her bir kümenin özelliğini belirlemeye çalışırken **Entropi Tabanlı Bulanık Kümeleme (EFC)** ise daha karmaşık veri yapılarının analizinin yapılmasına yardımcı olmaktadır. Genetik algoritmalarla da sınıflayıcıların performansları arttırılmaya çalışılmıştır. Geliştirilen sistemin performansını değerlendirmek için hem rastgele test vakaları hem de teşhisi konulmuş vakalar kullanılmıştır. Sonuç olarak, bulanık mantık, psikoz teşhisinde daha esnek ve anlaşılır bir yaklaşım sunarak, karmaşık verilerin işlenmesine ve belirsizliklerin yönetilmesine yardımcı olmuştur.

Bulanık mantık temelli sınıflayıcıların geleneksel yöntemler ile karşılaştırıldığında daha doğru teşhis verdiği görülmektedir. Bu çalışma, bulanık mantık tabanlı uzman sistemlerin psikoz teşhisinde etkili bir araç olabileceğini ve tıbbi alanda kullanıldığında önemli avantajlar sağlayabileceğini göstermektedir. (Chattopadhyay et al., 2008)

2.2.6.2. Yapay sinir ağları

2.2.6.2.A. Dikkat eksikliği ve hiperaktivite:

Dikkat eksikliği ve hiperaktivite bozukluğu çocukluk döneminde başlayan aşırı hareketlilik, dikkatsizlik ve dürtüsellik ile karakterize olan psikiyatrik hastalıklardan biridir. Tanısı alanında uzmanlaşmış kişiler tarafından konulmaktadır. DEHB okul dönemi çağındaki çocukların en az %5-10'unda görülmektedir. Bu bozukluğa sahip olan çocukların uzun vadeli olarak eğitim ve iş hayatların da olumsuzluklar meydana getirme riski bulunmaktadır. Bu nedenle DEHB' yi erken dönemde teşhis edecek yöntemlerin geliştirilmesi önem arz etmektedir. Yapılan çalışmalar bu alanda yapay zekâ tekniklerinin kullanılmasının etkili bir sonuç doğuracağını göstermektedir.

Jian Peng ve ark. Dikkat Eksikliği ve Hiperaktivite Bozukluğunun teşhis ve sınıflandırılmasında yapay sinir ağlarının önemini ortaya koyan bir çalışma yapmışlardır. Yayınladıkları makalede, DEHB teşhisini fonksiyonel manyetik rezonans görüntüleme (fMRI) ve yapısal manyetik rezonans görüntüleme (sMRI) taramaları kullanılarak tespitini yapmaya çalışmışlardır. Bunu SSANN (Summation-based Synergetic Artificial Neural Network) adı verilen bir çift 3D CNN veri entegrasyon yöntemi ile tespit etmeyi hedeflemişlerdir.

Önerdikleri model de ilk aşamada iki farklı 3D CNN dalı oluşturuluyor. Birinci dal, fMRI verilerinden özellikler çıkarırken ikinci dal ise sMRI verilerindeki özellikleri çıkarmıştır. Daha sonrasında her iki dalın çıkış matrisleri önerilen bir toplama yöntemi ile birleştirilmiştir. Birleştirilmiş matrisler ise bir sinir ağına bağlanmıştır. En son adımda ise sinir ağı çıkışı DEHB'nin varlığını veya yokluğunu belirlemek için ikili sınıflandırma tahminini üretmiştir.

Makalede önerilen SSANN modeli ile DEHB-200 veri setinden %72,89 gibi bir doğruluk oranı elde edilmiştir. Bu sonuçlar aynı veri setindeki değerlendirme yöntemlerinden daha iyi bir performans göstermiştir.

Yapay sinir ağları Dikkat eksikliği ve hiperaktivite bozukluğunda çoklu veri kaynaklarını kullanarak daha doğru sonuçlar elde etmeyi sağlamakla beraber fMRI ve sMRI gibi görüntüleme tekniklerindeki verileri analiz edebilir. Aynı zamanda veri setlerindeki karmaşık özelliklerden anlamlı sonuçlar çıkarabilir ve bu verileri işleyerek DEHB'nin teşhisinde objektif bir tutum sergileyebilir. (Peng et al., 2021)

2.2.6.2.B. Bipolar:

Bipolar bozukluk, yaşamın hemen hemen her alanında yüksek mortalite, morbidite ve fonksiyon kaybına neden olabilen, depresif ve manik ya da hipomanik dönemlerin olduğu ruhsal bir bozukluktur. (Yeloğlu & Hocaoğlu, 2017) Hastaların büyük bir kısmı genellikle depresif olduğu dönemde doktora başvurduklarından dolayı çoğunlukla depresyon tanısı almaktadırlar. (Yasin et al., 2021) Bipolar bozukluğunun başlangıcının bilinmemesi, zamanın, gidişatının ve tedaviye verdiği cevabın karmaşık olması ve anlaşılamayan çok farklı süreçlerle bağlantısının olması nedeniyle homojen bir hastalıktan ziyade heterojen bir yapıya sahip olduğu düşünülmektedir. Bipolar bozukluğun 2 yıl içerisinde %60 tekrarlanma oranı söz konusudur. (Yeloğlu & Hocaoğlu, 2017)

Bipolar bozukluğunun doğru teşhisinin ve tedavisinin yapılması ve diğer psikiyatrik rahatsızlıklar ile karıştırılmaması için yapay zekâ yöntemleri ile ilgili çeşitli çalışmalar yapılmaktadır.

Sana Yasin ve ark. Yapay sinir ağları ile EEG (Elektroensafalografi) sinyallerinin gerekli analizlerini yaparak Bipolar bozukluk ve Majör Depresif bozukluk tanı ve sınıflandırmasında nasıl kullanıldığını ve etkinlik düzeyi ile ilgili bir çalışma yapmışlardır. Majör depresif bozukluk ve bipolar bozukluk için güçlü biyobelirteçler EEG sinyallerinde bulunabilir. Bu sinyaller, hastaların beyin aktivitesindeki değişimleri yansıtarak teşhis sürecini kolaylaştırmaktadır. EEG sinyal analizi zor bir iştir çünkü bu sinyaller doğaları gereği karmaşık ve yapılandırılmamışlardır. Yapay sinir ağları ise bu karmaşıklığın üstesinden gelmekte ve daha kesin teşhis sonuçları sunmaktadır. Bu çalışmada EEG sinyallerinin analizi için sinir ağları tabanlı bir metod geliştirmişlerdir. Burada yapılan ilk işlem EEG verilerini toplayıp kaydettikten sonra gürültüden arındırılmasıdır. Ardından Yapay sinir ağlarını kullanarak EEG sinyallerinin özellikleri çıkartılmaktadır. Daha sonrasında sinir ağlarının eğitilip performansı test edilip doğruluk değerlendirilmesi yapılmaktadır. Sana Yasin ve ark. bu çalışmada yapay sinir ağlarından feedforward neural network (FFNN) ve probabilistic neural network (PNN) gibi yöntemleri kullanmışlardır. Feedforward neural network (FFNN), bipolar bozukluk tanısında %98,75 gibi yüksek bir doğruluk oranı elde ederken, probabilistic neural network (PNN) daha düşük bir doğruluk oranı göstermiştir. Bu çalışmanın sonucunda EEG tabanlı sinir ağlarını kullanarak Majör Depresif Bozukluk ve Bipolar Bozukluk tanısında yüksek düzeyde sınıflandırma doğruluğu elde edilmiştir. Ayrıca, frontal lob ve sol/sağ hemisfer gibi beyin bölgelerinin depresyon ve bipolar bozukluk tespitinde önemli bir rol oynadığı belirtilmiştir. Bu çalışmada EEG sinyallerinin kullanılmasının nedeni beyin aktivitesini yansıtmasından dolayı bipolar bozukluğun teşhisi için önemli bir veri kaynağı olduğu düşünülmektedir. Yapay sinir ağları, bu EEG verilerini işleyerek belirli desenleri tanıyabilir ve bipolar bozukluğun teşhisinde kullanılabilir. Bu nedenle, EEG sinyallerinin analizinde yapay sinir ağlarının kullanılması, bipolar bozukluk teşhisinde değerli bir araç olabilir ve bu alanda daha kesin ve güvenilir sonuçların elde edilmesine yardımcı olabilir. (Yasin et al., 2021)

Yu Lei ve ark. nin yapmış olduğu bir başka çalışmada dinlenme halindeki elektroensefalografi (EEG) sinyalleri ile bipolar bozukluk ve majör depresyonu ayırt etmek amacıyla konvolüsyonel sinir ağı (CNN) kullanılmıştır. Bu araştırma için 101

majör depresyon hastası, 82 bipolar bozukluk hastası ve 81 sağlıklı kontrol grubundan oluşan bir örneklem üzerinde çalışılmıştır. Klinik tanı, psikiyatristler tarafından DSM-5 (Mental Bozuklukların Tanısal ve İstatistiksel El Kitabı) esas alınarak yapılmıştır. Katılımcılara bir ekrana odaklama talimatı verilerek dinlenme halindeki EEG sinyallerinin toplanması sağlanmıştır. EEG verileri çok kanallı sistemler kullanılarak kaydedilerek beynin çeşitli bölgelerinden gelen sinyallerin analiz edilmesi sağlanmıştır. Bu çalışmada, ham EEG sinyalleri kullanılarak bipolar bozukluk ve majör depresyonu ayırt etmek için yeni bir konvolüsyonel sinir ağı (CNN) mimarisi geliştirilmiştir. Bu model, EEG verilerini doğrudan işleyerek, manuel özellik seçimi gerektirmeden, ham EEG sinyallerinden otomatik olarak faydalı bilgi ve desenler öğrenebilmiştir. Bu, geleneksel yöntemlere göre önemli bir avantaj sunmaktadır. Model, çeşitli uzunluklarda tek boyutlu çekirdekler kullanarak EEG verilerinin zamansal özelliklerini çıkarmaktadır. Ayrıca, farklı elektrotlardaki mekânsal bilgiyi entegre etmek için bir bottleneck katmanı kullanılmıştır.

Önerilen model, 10 katlı çapraz doğrulama yöntemi ile %96,88'lik bir sınıflandırma doğruluğu elde etmiştir. Bu sonuçlar, derin sinir ağlarının EEG verilerinden etkili özellikler öğrenebildiğini ve bu verilerle yüksek doğrulukta sınıflandırma yapabildiğini göstermektedir. Elde edilen yüksek doğruluk oranı, derin öğrenme yöntemlerinin EEG verileri ile birlikte kullanılmasının, mental bozuklukların tanısında önemli bir ilerleme sağlayabileceğini göstermektedir.(Lei et al., 2022)

2.2.6.3. Optimizasyon metotları

2.2.6.3.A. Trikotillomani:

Trikotillomani, hastanın kıllarını çekerek belirgin düzeyde saç kaybına neden olan ruhsal bir hastalıktır. Tipik olarak çocukluk döneminde başlamakla beraber en sık erken çocukluk ve ergenlik döneminde görülmektedir. Tipik belirtisi baştaki kılların çekilmesidir ancak bu durumdan diğer vücut bölümlerinden kirpikler, kaşlar ve sakal gibi bölgeler de etkilenmektedir. (Çoban, 2021)

2.2.6.3.B. Obsesif kompulsif bozukluk:

Obsesif Kompulsif Bozukluk (OKB), tekrarlayan düşüncelerle (obsesyonlar) ve/veya istemsiz tekrarlayan hareketlerle (kompulsiyonlar) belirginleşen bir rahatsızlıktır. Bu düşünceler ve davranışlar kontrolsüz bir şekilde ortaya çıkar, kişide anksiyeteye neden olur. Obsesyonlar ve kompulsiyonlar genellikle kişinin kimliği ile

ilgili olmayıp, bilinçli bir şekilde zihinden silinememe özelliği taşırlar ve obsesif düşüncenin rahatsızlık verici etkilerini azaltmaya yönelik sıkça tekrarlanır. Psikiyatrik rahatsızlıklar arasında sıkça görülmesinden dolayı OKB alanında yapılan çalışmalar son yıllarda giderek daha fazla ilgi çekmektedir. (B. Yılmaz, 2018)

Obsesif-kompulsif bozukluğun (OKB) ve saç kaybının ilişkilendirilmiş olduğu kompulsiyonlar, fenomenolojik gözlemlere göre bağlantılı olabileceği düşünülmektedir. Ancak OKB ve Trikotillomani'nin belirli benzerlikleri paylaştıkları bilinmesine rağmen her iki bozukluk arasında belli farklılıklar söz konusudur. Bu farklılığı ortaya çıkarmak ve doğru bir sınıflandırma yapabilmek için yapay zekâ tekniklerinden faydalanmak etkili bir yol olacaktır.

Türker Tekin Ergüzel ve ark. OKB ve Trikotillomani konularını sınıflandırmak için, EEG verileri ile hibrit yapay zeka yöntemini kullanmışlardır. Bu çalışmada öncelikle 39 OKB ve 40 Trikotillomani hastasının EEG verilerini toplanmıştır. Ardından geliştirilen Karınca Koloni optimizasyonu yöntemini kullanarak özellik seçimi yapılmıştır. Daha sonrasında ise Destek vektör makinesi (SVM) ile sınıflandırma yapılmıştır. Optimal özellik alt kümelerin seçimi ile de sınıflandırmanın doğruluğu artmıştır.

Bu çalışmanın sonucunda karınca koloni optimizasyonu ile Destek vektör makinesi gibi yapay zekâ teknikleri ile oluşturdukları hibrit çözümün minimal özellik alt kümelerini etkili bir şekilde seçtiği ve iyi bir performans sergilediği ortaya konmuştur. Kullanılan optimizasyon yöntemi sınıflandırmanın doğruluğunu artırarak hastalıklar arasındaki farklılığı ortaya koyma noktasında etkili bir araç olduğunu göstermiştir. (Erguzel et al., 2015)

2.2.6.4. Derin öğrenme algoritmaları

2.2.6.4.A. Şizofreni:

“Şizofreni toplumun %1’inde görülen, sanrı ve varsanı gibi pozitif semptomlar; duygulanımda sığlaşma, sosyal içe çekilme, konuşma miktarında azalma ve düşünce içeriğinde fakirleşme gibi negatif semptomlar; dikkatte, bellekte, yürütücü işlevlerde bozulma gibi bilişsel belirtilerle giden; duygu, düşünce, algılama ve davranışı etkileyen; farklı klinik tablolarla ortaya çıkabilen psikiyatrik bir hastalıktır.” Erkeklerde kadınlara oranla daha sık ortaya çıktığı bilinmektedir. (Summakoglu & Ertugrul, 2018) Dünya

Sağlık Örgütü'nün (WHO) verilerine göre dünyada yaklaşık 20 milyondan fazla insan bu hastalıktan etkilenmektedir. (Hassan et al., 2023) Erkeklerde genellikle 15-25, kadınlarda ise 25-35 yaşlarında ortaya çıkmaktadır. Şizofreninin bazı risk faktörlerinin olmasına rağmen nedeni tam olarak bilinmemektedir ancak stres faktörünün hastalığın ortaya çıkışında etkili olduğu düşünülmektedir. Ortalama yaşam boyu yaygınlığı %1'dir ve yaşam süresi %20 daha kısadır. (Summakoğlu & Ertuğrul, 2018)

Beyin deformitelerini azaltma da yardımcı olabilecek olan uzun süreli tedaviye başlamak için erken bir zamanda ve doğru bir teşhis yapmak önemlidir. Şizofreni teşhisi koymak için genellikle uzman kişiler tarafından halüsinasyonlar, işlevsel bozukluklar, düzensiz konuşmalar ve davranışsal belirtilerin gözlemlenmesiyle konulmaktadır. Bu zaman alıcı ve yorucu bir durum olmakla birlikte doğru bir tanı ve erken başlanan bir tedavi için yeni yöntemlerin geliştirilmesi gerekmektedir. (Hassan et al., 2023) Hastalıkları teşhis ve sınıflandırılmasın sıklıkla kullanılan yapay zekâ teknikleri bu alanda da başarılı bir şekilde kullanılmaktadır.

Abhishek Appaji ve ark. Derin öğrenme algoritmaları tekniğini retinal damar görüntüleri ile kullanarak şizofreni hastalığının teşhis ve sınıflandırılmasında etkili bir yöntem olduğunu göstermişlerdir. Bu algoritmalar, retinal damar görüntülerinden elde edilen verileri analiz ederek şizofreni hastalarını sağlıklı bireylerden ayırt etmeye yardımcı olur. Bu çalışmada ilk aşamada 139 şizofreni hastası ve 188 sağlıklı gönüllü olmak üzere toplam 327 katılımcıdan retinal fundus görüntüleri elde edilmiştir. Görüntüler önceden işlenmiş ve bir evrişimli sinir ağına (CNN) beslenmek üzere kodlanmıştır. Ardından 7 tane 2D CNN katmanı ve ardışık olarak bir düzleştirme katmanı, bir ReLU aktivasyon fonksiyonuna sahip yoğun bir katman ve bir sigmoid fonksiyonuna sahip bir yoğun katman içeren bir derin öğrenme modeli kullanılmıştır. Modelin performansı, alıcı işletim karakteristiği eğrisi altındaki alan (AUC) kullanılarak değerlendirilmiştir. CNN, şizofreni ve sağlıklı bireyleri sınıflandırmak için %95 doğruluk ve 0.98 AUC elde etmiştir. Bu çalışmanın sonucunda retinal vasküler görüntüleri kullanılarak geliştirilen derin öğrenme modeli, şizofreni hastalarını sağlıklı bireylerden yüksek doğrulukla sınıflandırabildi. Burada derin öğrenme algoritmalarını kullanmanın birkaç avantajının etkili olduğu söylenebilir. Bunlar;

- Derin öğrenme algoritmalarının büyük verilerden yararlanıyor olması

- Geleneksel makine öğrenmelerine kıyasla özellikleri otomatik olarak çıkartması ve manuel işlem yapılmasına gerek duyulmaması
- Verileri girdiden çıktıya kadar öğrenip özelliklerin otomatik olarak çıkartması ve daha yüksek bir sınıflandırma performansı göstermesi sayılabilir.

Şizofrenide derin öğrenme algoritmalarının kullanılmasıyla, retinal damar görüntülerinden elde edilen verilerin analizi sayesinde hastalığın teşhisi ve sınıflandırılması daha doğru ve etkili bir şekilde gerçekleştirilebilir. Bu sayede hastaların erken teşhis edilmesi ve uygun tedaviye erken başlanması gibi önemli avantajlar elde edilebilir. (Appaji et al., 2022)

Fatıma Hasan, Syed Fawad Hussain ve ark. yapmış olduğu çalışmada, Evrişimli Sinir Ağı (CNN) ve makine öğrenmesi algoritmaları birleştirilerek EEG verilerini kullanıp Şizofreni teşhisinde yüksek doğruluk sağlanabileceğini göstermişlerdir. Bu çalışma da toplanan EEG verileri 2. derece Butterworth filtresi ile ön işlemden geçiriliyor. Daha sonra CNN ile özellik çıkarma işlemi yapılıyor. Elde edilen bu özellikler farklı makine öğrenme sınıflayıcılarına iletiliyor. CNN ve Lojistik regresyon sınıflayıcısı beraber kullanılarak sınıflandırma işlemi yapıldıktan sonra çapraz doğrulama yöntemi kullanılır. Ardından belirli kanallar seçilir ve bu kanallardan gelen sinyaller kullanılarak veri boyutu azaltılmış olur. Bu yöntem veri boyutunu azalttığından dolayı işleme karmaşıklığını da azaltır ve yüksek bir doğruluk oranı sağlar. Bu çalışmada Non-subject based testinde %98, subject based testinde ise %90 gibi bir doğruluk oranı ortaya çıkmıştır. (Hassan et al., 2023)

2.2.6.4.B. Travma Sonrası Stres Bozukluğu:

Amerikan Psikiyatri Birliği, travma sonrası stres bozukluğunu (TSSB) yaşanan negatif bir olay sonucunda meydana gelen, kaçınma davranışları gözlenen, olumsuz duygusal ve bilişsel değişiklikler ile ürkme ve uyarılma durumlarının artması ve bir aydan daha uzun süren klinik bir olgu olarak tanımlamaktadır. (Amerikan Psikiyatri Birliği. Mental Bozuklukların Tanısal ve Sayımsal El Kitabı, Beşinci Baskı(DSM-5), 2014)Epidemiyolojik araştırmalara göre, kadınların TSSB ve çeşitli anksiyete bozukluklarına yakalanma olasılığı erkeklerden iki kat daha fazladır. (Singh et al., 2024)

Travmaya maruz kalan kişiler genellikle akut psikolojik travma yaşarlar ve bu zamanla geçer. Ancak TSSB nedeniyle hastaların %10-20'sinde semptomlar devam

eder. TSSB'nin nedeni tam olarak bilinmemekle birlikte, travma şiddeti, erken yaşam olayları, önceden var olan hastalıklar ve genetik etkilerin bir karışımı olduğu düşünülüyor. Risk faktörlerini anlamak TSSB riski taşıyan kişilerin tedavi düzenlemelerine ve daha etkili tarama yöntemlerinin geliştirilmesine imkân sağlayacaktır.

Teknolojide yaşanan gelişmeler psikiyatrik rahatsızlıkların doğru teşhis ve tedavisi için etkili yöntemler sunmaktadır. Bu yöntemlerin büyük çoğunluğu ise yapay zekâ tekniklerini içermektedir.

Arjun Singh ve ark. travma sonrası stres bozukluğunun tespiti için derin öğrenme algoritmalarını kullandıkları bir çalışma yapmışlardır. Bu çalışmada "Çoklu Strateji Arayıcı Archimedes Optimizasyon Temelli Elman Tekrarlayan Sinir Ağı (MSSAO-ERNN)" tekniği kullanılarak TSSB belirtilerini erken tespit etmeyi amaçlamaktadırlar. Bu teknikte hastaların konuşma örnekleri kullanılmıştır. Konuşma örneği verileri Texas Instruments/Massachusetts Institute of Technology (TIMIT), Northern New England (NNE) ve Far Eastern Memorial Hospital (FEMH) veri kümelerinden elde edilir. Bu örnekler veri kalitesini artırmak için ön işlemden geçirilir ve gereksiz verilerin azaltılması için veri özellikleri çıkarılır. Bu aşamadaki amaç ses verilerinin bozulmalarını gidermek ve analiz için uygun hale getirmektir.

İlk aşama olan ön işleme aşamasında eksik verilerin doldurulması anlamına gelen imputation adımı eksik olan veriler tahmin edilen değerler ile değiştirilir. Bu aşama modelin performansını artırmaktadır. Normalizasyon adımı ise veriler belirli bir aralığa çekilmektedir. Pre-emphasis aşamasında ise sinyalin yüksek frekans bileşenlerini yükseltmek, özellikle veri iletimi sırasında oluşabilecek bozulmaları ve gürültüyü azaltmak amaçlanmıştır. Pencereleme ile büyük veri setlerinden küçük parçalar alınarak, sinyalin sürekliliğini artırır. Veri etiketleme ile de doğru tahminlerde bulunmak için ham verilere belirli bilgilendirici etiketler eklenmektedir.

2. aşama ise özellik çıkartma aşaması olarak bilinmektedir. Bu aşamada ise ses sinyallerindeki önemli özellikler çıkarılmaktadır. Özellik çıkartma, gereksiz verilerin azaltılmasına yardımcı olur ve modelin daha az makine gücü ile çalışmasını sağlar. Kullanılan bu özellikler Vokal yol özellikleri, Niteliksel özellikler, Uyarım özellikleri Prosodik özellikler ve Sürekli özelliklerdir. Bu özellikler insan konuşma stilini sınıflandırmak için kullanılır.

Son aşamada ise Çoklu Strateji Arayıcı Archimedes Optimizasyon Temelli Elman Tekrarlayan Sinir Ağı MSSAO-ERNN tekniği kullanılarak sınıflandırma yapılmıştır. Bu aşamada ön işleme ve özellik çıkartma adımlarından elde edilen verilerle gerçekleştirilir. Makalede, önerilen yöntem %97 doğruluk oranı gibi yüksek bir başarı elde etmiştir. Makalede, yalnızca ses örnekleri üzerinden yapılan tespitlerin geçerli olduğu ve diğer duygu ifadeleri veya hastalık türleri için bu yöntemin uygulanamayabileceği gibi sınırlamalar da vurgulanmıştır. Gelecekte, duygular ve yüz ifadeleri üzerinden TSSB tespiti yapılması gerektiği önerilmektedir.

Travma sonrası stres bozukluğunun tespitinde derin öğrenme algoritmalarının kullanılması, karmaşık veri yapılarını işleyerek özellik çıkarabilir ve yüksek doğruluk oranları sağlayarak tedavisinde etkili olabilir. (Singh et al., 2024)

2.2.6.4.C. Opiyat kullanım bozukluğu:

Opiyat kullanım bozukluğu, kısıtlı tedavi seçeneklerine sahip psikososyal bir bozukluk olmakla beraber önemli bir halk sağlığı sorunudur. Avrupa Uyuşturucu ve Uyuşturucu Bağımlılığı İzleme Merkezi (EMCDDA)'nin 2018 raporunda Avrupa Birliği'ndeki tüm uyuşturucu tedavi taleplerinin yaklaşık olarak %36'sının opioid kaynaklı olduğu belirtilmiştir. (Erdal Vardar, n.d.)

2017 yılında ABD'de 70.200 aşırı dozda ölüm meydana gelmiştir. 2012 yılında her 100 hastaya karşılık 81.3 opioid reçetesi verilmiştir. 2017 yılında bu reçetelerin azaltılmasına yönelik çalışmalar yapılmış olmasına rağmen bu oran 58.5'e düşmüştür. Opioid reçetelenmelerinin bu kadar yüksek olmasına "opioid" salgını adı verilmiştir. Klinisyenlerin daha doğru karar vermesine yardımcı olmak, opioidle ilgili sorunları önlemek ve tespit etmek için gerekli çalışmaların yapılması önem arz etmektedir.

Aditya Kashyap ve ark. derin öğrenme tekniklerini Elektronik sağlık kayıtlarından (EHR) opioid reçetesi ve opioid kullanım bozukluğunu tespit etmek için eğittikleri bir çalışma yapmışlardır. Bu çalışmada yoğun bakımda yatmakta olan hastaların elektronik sağlık kayıtlarını (EHR) içeren MIMIC-III (Medical Information Mart for Intensive Care) veri tabanı kullanılmıştır. Bu veri tabanı hem yapılandırılmış (örneğin, laboratuvar sonuçları, demografik bilgiler) hem de yapılandırılmamış (örneğin, klinik notlar) verileri içermektedir. Araştırmacılar bu çalışma için hem opioid reçetesi tahmini hem de opioid kullanım bozukluğu tanısının tahmini için iki ayrı derin öğrenme modeli geliştirmişlerdir. Bu modellerin eğitimi sürecinde eksik olan verilerin işlenmesi ve

gerekli özelliklerin seçilmesi için EHR verileri ön işleme tabi tutulmaktadır. Bu modeller EHR verilerinin hem yapılandırılmış hem de yapılandırılmamış kısımlarını kullanarak eğitilmişlerdir. Yapılandırılmamış verilerden anlamlı bilgiler çıkartarak analizinin yapılması için ise Doğal Dil işleme (NLP) teknikleri kullanılmıştır. Bu modellerin öğrenme süreçlerinde ise çeşitli performans parametreleri (örneğin, F1 skoru, AUC-ROC) kullanılmıştır.

Eğitimi tamamlanan modeller farklı test setleri ile değerlendirilip performansları ölçülmüştür. Literatürde yer alan önceki modellerle karşılaştırıldığında derin öğrenme modellerinin etkinliğinin çok daha fazla olduğu ve yapılan araştırma sonucunda yüksek bir doğruluk oranının elde edildiği görülmektedir. Bu modelin tahmin gücü hem yapılandırılmış hem de yapılandırılmamış EHR verilerinin kullanılması ile artmıştır. Geliştirilmiş olan modellerin karar destek sistemlerine entegrasyonu sağlanarak opioid kullanım bozukluğu krizinin yönetimi açısından oldukça etkili olduğu vurgulanmaktadır. Bu makale ile derin öğrenme modellerinin EHR verilerini kullanarak opioid reçete ve opioid kullanım bozukluğunun teşhisinin tahminini yapmak için etkili bir yöntem olduğunu ve klinik uygulamalarda faydalı olabileceğini gösterilmiştir. (Kashyap et al., 2023)

2.2.7. Fiziksel hesaplamalı sistemler

2.2.7.1. Nöromorfik bilgisayarlar

2.2.7.1.A. Nöromorfik bilgisayarlar nedir?

Nöromorfik bilgisayarlar, biyolojik sinir sistemlerinden esinlenilerek tasarlanmış bilgisayar sistemleridir. (Schuman et al., n.d.) "Nöromorfik" terimi ilk olarak 1980'lerin sonlarında Carver Mead tarafından, beyinden ilham alarak hesaplama tekniklerini kullanan hibrit analog-dijital sistemleri tanımlamak için kullanılmıştır. O zamandan beri, alan sürekli olarak gelişmiş ve geniş bir donanım uygulamaları yelpazesini kapsamıştır ve şu anda, nöromorfik bilgisayarlar, mimarisi ve işlevleri biyolojik beyinlerin yapısı ve işleyişine göre modellenmiş non-von Neumann bilgisayarlar olarak sınıflandırılmaktadır. (Wang et al., 2024) İnsan beyninin işleyişini taklit etmeyi hedefleyen Nöromorfik bilgisayarlar öğrenme ve adaptasyon yeteneklerini geliştirmek için sinir hücrelerinin (nöronlar) ve sinapsların (nöronlar arasındaki bağlantılar) işlevlerini model almaktadırlar. (Schuman et al., n.d.)

Von Neumann bilgisayarlarında verileri ve talimatları depolayan bellek birimleri ve bilgiyi işleyen CPU'lar (Central Processing Unit) fiziksel olarak ayrılmasına rağmen, nöromorfik bilgisayarlarda sinapslar ve nöronlar belleği ve işlemi birlikte ele alırlar. Von Neumann bilgisayarlarında programlar açık talimatlarla tanımlanır ve veriler ikili değerlerle sayısal olarak kodlanır. Nöromorfik bilgisayarlarda ise farklı bir yaklaşım benimsenir. Girdiler olarak tepe noktaları (spikes) alırlar ve bu noktaların meydana geldiği zaman, büyüklükleri ve şekilleri sayısal bilgileri kodlamak için kullanılabilir. Programlar, sinir ağının yapısı ve parametreleri ile tanımlanır. Nöromorfik hesaplamada, ikili değerleri tepe noktalarına ve tepe noktalarını ikili değerlere dönüştürmek mümkündür ancak bunu gerçekleştirmenin kesin yöntemi hâlâ araştırılmaktadır. (Wang et al., 2024)

Nöromorfik bilgisayarlar ile ilgili bazı temel kavramlar;

Nöron: Nöromorfik sistemlerde bilgi işleyen temel birimdir. Biyolojik nöronların özelliklerini taklit eden yapay nöronlar, giriş sinyallerini alır, işler ve çıkış sinyalleri üretir.

Sinaps: Nöronlar arasındaki bağlantılardır. Nöromorfik sistemlerde, sinapslar nöronlar arasındaki iletişimi sağlar ve öğrenme süreçlerinde önemli bir rol oynar.

Spike-Timing Dependent Plasticity (STDP): Nöronların ateşleme zamanları arasındaki ilişkilere dayanan bir öğrenme mekanizmasıdır. Bu mekanizma, nöronların bağlantı güçlerini ayarlayarak öğrenmeyi sağlar. STDP, nöromorfik sistemlerde yaygın olarak kullanılan bir öğrenme kuralıdır.

Ateşleme (Spike): Nöronların belirli bir eşik değerini aştığında ürettiği elektriksel sinyaldir. Nöromorfik sistemlerde, ateşleme olayları bilgi iletiminde ve işlenmesinde kritik bir rol oynar.

Dinamik Davranış: Nöromorfik sistemler, zamanla değişen ve dinamik verileri işleme yeteneğine sahiptir. Bu, biyolojik sistemlerin karmaşık davranışlarını taklit etmeye yardımcı olur.

Enerji Verimliliği: Nöromorfik bilgisayarlar, geleneksel bilgisayarlara göre daha az enerji tüketme potansiyeline sahiptir. Nöronlar yalnızca ateşleme anında aktif hale gelir, bu da enerji tasarrufu sağlar.

Hafıza ve Öğrenme: Nöromorfik sistemler, öğrenme ve hafıza süreçlerini simüle edebilir. Bu, sinapsların güçlerinin ayarlanması yoluyla gerçekleşir ve sistemin çevresine uyum sağlamasına olanak tanır. (Schuman et al., n.d.)

Spiking Neural Network (SNN-Ateşleme Sinir Ağı): Biyolojik sinir sistemlerinin işleyişini taklit eden bir yapay sinir ağı türüdür. SNN'ler, zamanlama ve ateşleme olayları üzerinden bilgi iletimi gerçekleştirir. Bu ağlar, nöronların belirli bir eşik değerine ulaştığında ateşleme yapması ve bu ateşlemelerin diğer nöronlara sinyal göndermesi prensibine dayanır. SNN'ler, zamanın önemli bir rol oynadığı bir bilgi işleme biçimi sunar ve bu sayede dinamik verileri daha etkili bir şekilde işleyebilirler. SNN'ler, nöromorfik hesaplama çerçevesinde önemli bir rol oynar çünkü bu ağlar, biyolojik nöronların dinamiklerini ve etkileşimlerini modelleyerek, gerçek zamanlı ve enerji verimli bilgi işleme yetenekleri sunar. Nöromorfik mimariler, SNN'lerin özelliklerini kullanarak, geleneksel von Neumann mimarisine göre daha verimli ve paralel işlem yapabilen sistemler geliştirmeyi amaçlamaktadırlar. (Schuman et al., 2022)

2.2.7.1.B. Nöromorfik bilgisayarların temel ilkeleri nelerdir?

Nöromorfik bilişimin temel işlevsel özellikleri;

- **Yüksek paralellik:** Nöromorfik bir sistem, tüm sinapslarının ve nöronlarının aynı anda çalışabilmesi nedeniyle doğal olarak paralellik içermektedir. Ancak, paralelleştirilmiş von Neumann sistemleriyle karşılaştırıldığında, bireysel birimlerin gerçekleştirdiği hesaplamalar daha basittir.
- **İşlem ve belleğin bir arada bulunması:** Nöromorfik donanımda, bellek ve işlem fiziksel olarak birleştirilmiştir. Bu yapı, işleme biriminden ayrı bir ana belleğe veri erişimini engelleyerek enerji tüketimini azaltmaktadır.
- **Olay tabanlı hesaplama:** Sadece işlenecek tepe noktaları (spikes) ve mevcut veri olduğunda nöronlar ve sinapslar işlev görür. Genellikle, ağ nispeten az sayıda tepe noktaları ile çalışır, bu da enerji verimliliği artırır ve gereksiz hesaplamalardan kaçınılmasını sağlar.
- **Stokastiklik:** Nöronların ateşlenmesindeki rastgelelik gibi bir rastgelelik kavramı, gürültüyü hesaba katmak için nöromorfik bilgisayarlara dahil edilebilir.

- **Ölçeklenebilirlik:** Nöromorfik bilgisayarların ölçeklenebilirliği doğaldır. Bir sisteme daha fazla nöromorfik çip eklemek, daha fazla nöron ve sinapsa sahip olmasını sağlar ve bunları daha büyük ağları çalıştırmak için tek bir büyük nöromorfik uygulama olarak değerlendirmek mümkündür.
- **Dayanıklılık:** Nöromorfik sistemlerin seyrek yapısı, yerel birimlerin arızalarına karşı dayanıklılığı sağlar.

Nöromorfik bilgisayarlar büyük ölçüde paralel ve olay odaklı olmalarından ötürü, son derece düşük güçle çalışırlar. Genellikle, nöromorfik sistemin yalnızca küçük bir kısmı herhangi bir zamanda aktif olurken geri kalanı boşta; bu nedenle, bu sistemler genellikle geleneksel hesaplama sistemlerinden kat kat daha az güçle çalışabilirler.

Bugüne kadar nöromorfik bilgisayarlar için birincil hesaplama birimi olarak nöronlar ve sinapslar seçilmişlerdir. Bunun nedeni uygun bir soyutlama düzeyi sağlamış olmalarıdır. Ancak, bunların en iyi uygulama yöntemi olup olmadığı hala belirsizdir; glial hücreler gibi alternatif biyolojik ilhamlı bileşenler ve mimariler hesaplama için dikkate alınabilir. (Wang et al., 2024)

2.2.7.1.C. Nöromorfik bilgisayarlar ile geleneksel bilgisayarların karşılaştırılması

Nöromorfik bilgisayarlar ile geleneksel bilgisayarları karşılaştırdığımız zaman mimari, işlem yapma yöntemleri, öğrenme ve adaptasyon ve enerji tüketimi gibi birçok alanda belirgin farklılıklar göze çarpmaktadır. (Schuman et al., n.d.)

Mimari Yapı:

Nöromorfik bilgisayarlar biyolojik sinir sistemini taklit eden paralel bir mimariye sahip olup bellek ve işlemciyi bir arada bulundurarak nöronlar ve sinapslar gibi yapıları kullanırlar.

Geleneksel bilgisayarlar ise Von Neumann mimarisine dayanırlar ve işlemci ile bellek arasında belirgin bir ayrım söz konusudur. Veriler, işlemci ve bellek arasında taşınırken, bu durum "von Neumann darboğazı" olarak bilinen bir sorun yaratır.

İşlem Yöntemleri:

Nöromorfik Bilgisayarlar paralel işlemeyi ve dağıtık hesaplamayı destekler. Bu, çok sayıda basit işlem biriminin (nöronlar) aynı anda çalışabilmesi anlamına gelir, bu da daha hızlı ve verimli bilgi işleme sağlar.

Geleneksel Bilgisayarlar ise genellikle sıralı işlem yapar ve işlemci, bellek erişimi için belirli bir zaman dilimi beklemek zorundadır. Bu da işlem hızını kısıtlayabilir.

Enerji Verimliliği:

Nöromorfik Bilgisayarlar, düşük güç tüketimi ile çalışacak şekilde tasarlanmıştır. Bu, özellikle büyük veri setleri üzerinde çalışırken enerji tasarrufu sağlar.

Geleneksel Bilgisayarlar ise genellikle daha yüksek enerji tüketimine sahiptirler, çünkü işlemci ve bellek arasındaki veri transferi enerji gerektirir ve bu da güç tüketimini artırır.

Öğrenme ve Adaptasyon:

Nöromorfik Bilgisayarlar öğrenme ve adaptasyon yetenekleri ile öne plandadırlar. Bu sistemler, çevrelerinden öğrenme ve bu bilgiyi uygulama yeteneğine sahiptirler.

Geleneksel Bilgisayarlar ise genellikle belirli algoritmalarla programlanır ve öğrenme yetenekleri sınırlıdır. Yapay zekâ uygulamaları için özel yazılımlar gerektirir.(Schuman et al., n.d.)

2.2.7.1.D. Yapay sinir ağları ile nöromorfik hesaplama arasındaki ilişki

Nöromorfik hesaplama ve yapay sinir ağları arasında yakın bir ilişki bulunmaktadır. Her iki alanın da benzer fikirlere dayanması ve biyolojik sinir sistemlerinden ilham alması bu ilişkiyi şekillendirmektedir. (Schuman et al., n.d.)

Hem nöromorfik hesaplama hem de yapay sinir ağları insan beyninin işlem biçimini taklit etmeye çalışmaktadır. Yapay sinir ağları, sinir hücreleri veya nöronların bağlantılarını ve etkileşimlerini modelleyerek öğrenme ve karar verme süreçlerini simüle ederken, nöromorfik sistemler bu süreçleri fiziksel olarak gerçekleştiren donanımlar olarak tasarlanmıştır. Yapay sinir ağlarının paralel işlem kapasitesi nöromorfik sistemler tarafından fiziksel olarak gerçekleştirilebilir. Bu, çok sayıda nöronun aynı anda çalışabileceği ve büyük miktarda veriyi hızlı bir şekilde

işleyebileceği anlamına gelir. Bu paralel yapı, nöromorfik mimariler tarafından donanım düzeyinde desteklenerek daha verimli hesaplamalara olanak tanır. (Schuman et al., n.d.)

Nöromorfik sistemler, yapay sinir ağı öğrenme algoritmalarını uygulamaya koymak için bir ortam sunar. Bu sistemler, çevrelerindeki değişikliklerden öğrenme ve bu değişikliklere uyum sağlama yetenekleri ile ön plana çıkarlar. (Schuman et al., n.d.) Nöromorfik bilgisayarlar, öğrenme süreçlerini simüle etmek için sinaptik plastisite mekanizmalarını kullanır. Bu, YSA eğitiminde kullanılan geri yayılım algoritmalarına benzer bir öğrenme prosedürüdür. (Schuman et al., 2022)Yapay sinir ağları bu öğrenme mekanizmalarını yazılım düzeyinde simüle ederken, nöromorfik sistemler bu süreçleri donanım düzeyinde gerçekleştirebilir. (Schuman et al., n.d.)

Yapay sinir ağları, hata toleransı özellikleri ile bilinmektedirler. Aynı şekilde nöromorfik sistemler de donanım hatalarına karşı dayanıklılık gösterebilir. Bu, her iki sistemin de biyolojik sinir sistemlerinin özelliklerini yansıması açısından önemlidir

Nöromorfik sistemlerin sağladığı hız ve enerji verimliliği sayesinde yapay zekâ uygulamalarında daha etkili çözümler geliştirilebilmesini mümkün kılmaktadır.(Schuman et al., n.d.)

2.2.7.1.E. Nöromorfik bilgisayarların potansiyel uygulama alanları

Biyolojik sinir sistemini taklit eden nöromorfik bilgisayarların uygulama alanlarının geniş bir yelpazeye yayıldığını söylemek mümkündür. Bu uygulama alanlarından bazıları şunlardır:

Yapay Zekâ ve Makine Öğrenimi:

Nöromorfik bilgisayarlar, sinir ağları için optimize edilmiş tasarımları sayesinde yapay zekâ uygulamalarındaki hesaplamaları daha hızlı ve daha az enerji tüketimiyle işleyebilir. Özellikle derin öğrenme ve diğer makine öğrenimi algoritmaları bağlamında, bu büyük bir fayda sağlayabilir.

Otonom Sistemler:

Nöromorfik sistemler, robotlar ve otonom arabalar tarafından çevrelerini algılamak ve hızlı hareket etmek için kullanılabilir. Bu sistemlerin verileri gerçek zamanlı olarak işleme yetenekleri, karmaşık durumlara daha etkili bir şekilde yanıt vermelerini sağlar.

Görüntü ve Ses İşleme:

Nöromorfik bilgisayarlarla ses ve görüntü verisi işleme mümkündür. Bu sistemler, olay odaklı görüntü sensörleriyle birleştiğinde, daha hızlı ve etkili görüntü tanıma ve ses analizine olanak sağlar.

Grafik Algoritmaları ve Optimizasyon:

Grafik algoritmaları ve optimizasyon görevleri için, nöromorfik sistemler oldukça avantajlı olabilir. Nöromorfik bilgisayarların paralel ve olay odaklı işleme güçlerini kullanarak, bu algoritmalar daha hızlı çözümler üretebilir.

Biyomimetik Uygulamalar:

Nöromorfik hesaplama, biyolojik sistemlerin işleyişini taklit eden uygulamalarda kullanılabilir. Örneğin, sinaptik plastisite gibi biyolojik öğrenme mekanizmaları, nöromorfik sistemlerde uygulanarak yeni öğrenme algoritmalarının geliştirilmesine olanak tanıyabilir.

Sağlık ve Biyomedikal Uygulamalar:

Biyomedikal veri işleme ve analizi nöromorfik bilgisayarlarda yapılabilir. Özellikle, nörolojik hastalıkların tedavisinde ve beyin-bilgisayar arayüzlerinde potansiyel kullanım alanlarına sahiptirler. (Schuman et al., 2022)

Geleneksel bilgisayar mimarilerine kıyasla sunduğu avantajlar nedeniyle, nöromorfik hesaplama gelecekte birçok endüstriyi devrim niteliğinde değiştirme potansiyeline sahiptir.(Schuman et al., n.d.)

2.2.7.1.F. Nöromorfik bilgisayarların avantajları ve dezavantajları

Nöromorfik bilgisayarların avantajları ve dezavantajları, bu sistemlerin mimarisi ve işleyiş biçiminden kaynaklanmaktadır.

Avantajları:

- **Enerji Verimliliği:** Geleneksel bilgisayarlara göre nöromorfik bilgisayarlar daha düşük enerji tüketimi ile çalışmaktadırlar.
- **Gerçek Zamanlı İşleme:** Nöromorfik bilgisayarlar, verileri gerçek zamanlı olarak işleyebilme yeteneğine sahiptirler.

- **Paralel İşleme:** Nöromorfik bilgisayarlar büyük miktarda veriyi paralel olarak işleyebilme özeliği sayesinde daha hızlı ve verimli hesaplamalar yapabilmektedirler.
- **Öğrenme ve Adaptasyon:** Nöromorfik bilgisayarlar, öğrenme algoritmalarını uygulayarak çevrelerine uyum sağlama yeteneğine sahiptirler. (Schuman et al., n.d.)

Dezavantajları:

- Nöromorfik bilgisayarlar için mevcut programlama dilleri ve araçlar oldukça sınırlıdır. Bu durum, sistemlerin kullanımını daha zor hale getirebilir ve daha fazla uzmanlık gerektirebilir.
- Nöromorfik sistemler bazı uygulama alanlarında daha verimli olsalar da genel amaçlı hesaplama için uygun olmayabilirler. Bu, bazı durumlarda sınırlayıcı bir faktör olabilir
- Geleneksel sistemlere kıyasla, nöromorfik sistemlerin eğitim ve öğrenme süreçleri daha karmaşık olabilir. Bu durum, kullanıcıların daha fazla zorlukla karşılaşmasına neden olabilir.
- Nöromorfik mimari geliştirme ve uygulama önemli başlangıç maliyetleriyle birlikte gelebilir. Bu durum, özellikle küçük işletmeler için bir zorluk oluşturabilir.
- Nöromorfik bilgisayarlar henüz gelişimin erken aşamalarında olduğu için bu alanda çok fazla araştırma veya uygulama bulunmayabilir. Bu durum, potansiyel kullanıcıların bu teknolojiyi benimsemekte zorlanmasına neden olabilir. (Schuman et al., n.d.)

Nöromorfik bilgisayarların geleceği, belirli uygulamalardaki avantajları, değişen malzemeler ve donanımlar ile birlikte programlama paradigmasındaki değişikliklerle şekillenecektir. Bu alan, araştırma ve uygulama açısından büyük bir potansiyele sahiptir. (Schuman et al., 2022)

2.2.7.2. Kuantum bilgisayarlar

2.2.7.2.A. Kuantum bilgisayarlar nedir?

Kuantum bilgisayarlar, kuantum mekaniğinin prensiplerine dayanan ve klasik bilgisayarlardan farklı olarak bilgi işleme yeteneklerine sahip olan bilgisayarlardır. 1980'lerde Richard Feynman'ın kuantum sistemlerinin simülasyonu üzerine yaptığı çalışmalar, kuantum bilgisayarların geliştirilmesinin temellerini atmıştır. Feynman, kuantum bilgisayarların bu simülasyonları daha etkili bir şekilde gerçekleştirebileceğini

öne sürerek klasik bilgisayarların kuantum sistemlerini simüle etmedeki yetersizliklerini vurgulamıştır. 1990'larda Peter Shor'un Shor algoritmasını icat etmesi, kuantum bilgisayarların asal çarpanlarına ayırma gibi zor problemleri çözebileceğini göstererek bu alana olan ilginin artmasına neden olmuştur. (Abdullah et al., 2019)

Klasik bilgisayarlar, verileri 0 ve 1'ler şeklinde temsil eden bitler kullanarak bilgi işlerken, kuantum bilgisayarlar, aynı anda hem 0 hem de 1 olabilen kuantum bitleri (kübitler) kullanır. Bu özellik, kuantum bilgisayarların belirli hesaplama türlerini klasik bilgisayarlardan çok daha hızlı gerçekleştirmesine olanak tanır. (S et al., 2022) Kuantum süperpozisyonu olarak adlandırılan bu özellik sayesinde kuantum bilgisayarlar çok daha fazla bilgi işleyebilmektedirler. (Nouioua & Belbachir, 2023)

Kuantum bilgisayarlar ile ilgili bazı temel kavramlar;

Qubit (Kuantum Bit): Qubit, kuantum bilgisayarlarda bilginin temel yapı taşıdır. Klasik bitlerin (0 veya 1) aksine, bir qubit aynı anda hem 0 hem de 1 değerine sahip olabilir. Bu özellik, kuantum süperpozisyonu olarak adlandırılır ve kuantum bilgisayarların paralel hesaplama yapmasını sağlar.

Süperpozisyon: Qubit'lerin birden fazla durumu aynı anda temsil edebilme yeteneğidir. Bu, kuantum bilgisayarların çok sayıda hesaplamayı aynı anda gerçekleştirmesine imkân sağlar.

Dolanıklık (Entanglement): İki veya daha fazla qubit'in birbirine bağlı olduğu bir durumdur. Bir qubit'in durumu, diğer qubit'lerin durumunu etkileyebilir. Bu özellik, kuantum bilgisayarların bilgi aktarımını ve hesaplamayı daha verimli hale getirir.

Kuantum Kapıları: Kuantum bilgisayarlar, qubit'leri manipüle etmek için kuantum kapıları kullanır. Bu kapılar, klasik mantık kapılarının kuantum versiyonlarıdır ve kuantum hesaplamaları gerçekleştirmek için gereklidir.

Kuantum Algoritmaları: Kuantum bilgisayarlar, belirli problemleri çözmek için özel olarak tasarlanmış algoritmalar kullanır. Örneğin, Shor'un algoritması asal çarpanlara ayırma işlemini hızlandırırken, Grover'in algoritması arama işlemlerini daha verimli hale getirir.

Kuantum Hataları ve Hata Düzeltme: Kuantum hesaplamaları sırasında hata oluşma olasılığı yüksektir. Bu nedenle, kuantum hata düzeltme kodları geliştirilmiştir. Bu

kodlar, kuantum bilgisayarların güvenilirliğini artırmak için kullanılır. (Nouioua & Belbachir, 2023)

Süperpozisyonu, göletteki iki dalganın birleşip örtüşmesi gibi, entanglement'ı ise iki rengi, mavi ve sarıyı karıştırarak yeşil yapmak gibi düşünülebilir. (Closser & Bou-Harb, 2022)

2.2.7.2.B. Kuantum bilgisayarların temel özellikleri

- **Kuantum bilgisayarlar çeşitli hesaplama programlarının zorluklarını hafifletir.**

Kuantum bilgisayarlar, çeşitli hesaplama programlarının zorluk seviyesini azaltma yeteneğine sahiptirler. Bu bilgisayarlar, mevcut veya gelecekteki klasik bilgisayarlardan daha hızlı bir şekilde çeşitli görevleri çözebilirler. Kuantum bilgisayarlar için "basit" ve "zor" görevler arasındaki sınır, klasik bilgisayarlara göre farklıdır. "Basit" görevler, çözüm süresinin verinin boyutuyla polinomik olarak arttığı, "zor" görevler ise gereken sürenin üssel olarak arttığı durumları ifade eder. Bu nedenle, klasik bilgisayarlar için zor olan bir görev, kuantum bilgisayarlar için basit olarak kabul edilir.

- **Kuantum sistemleri, diğer kuantum sistemlerini etkili bir şekilde simüle edebilir.**

Kuantum sistemler, diğer kuantum sistemlerini etkili bir şekilde simüle edebilir. Doğada Bose-Einstein yoğunlaşması, manyetizma ve süperiletkenlik gibi ilginç kuantum olguları bulunmaktadır. Bu olgular teorik olarak kuantum sistemlerinin kurallarından açıklanabilir, ancak bilim insanları bu yasaları tam olarak anlamakta ve tahmin etmekte zorluk çekmektedir. Bunun nedeni, bir parçacık kuantum sistemini tanımlamak için gereken faktörlerin sayısının parçacık sayısı ile üssel olarak artmasıdır. Geleneksel bilgisayarlar, otuz parçacığın performansını deneysel olarak değerlendirmekte zorluk yaşarken, kuantum bilgisayarlar bu simülasyonları daha verimli bir şekilde gerçekleştirebilir. Richard Feynman, geleneksel simülasyonların üssel bir azalma yaşadığını belirtmiştir. Kuantum emülatörleri, teorik tasarımlar ile deneysel veriler arasında bir köprü işlevi görebilir ve Shor algoritması gibi sistemler, geleneksel bilgisayarlara göre önemli bir hız artışı sağlayabilir. Ancak, Shor algoritması binlerce qubit gerektirirken, kuantum bilgisayarların taklit edilmesi için birkaç on qubit yeterli olabilir.

- **Moore'un Yasasının Fiziksel Sınırlamaları**

Moore Yasası, fiziksel sınırlamalara sahiptir. Kuantum sistemlerinin işleme kapasitesinin yanı sıra, kuantum mekaniğinin bilgisayar sistemlerine dahil edilmesi için birçok basit argüman bulunmaktadır. 1960'larda Intel'in kurucu ortağı Gordon Moore, entegre devrelerdeki transistör sayısındaki önemli artışları gözlemlemiş ve bu eğilimin devam edeceğini öngörmüştür. O zamandan beri, yoğunluk neredeyse her 18 ayda iki katına çıkmıştır. Bu eğilim devam ederse, 2020 yılı itibarıyla bilgisayar sistemlerinin çeşitli parçaları atomik boyutlara ulaşacak ve bu durumda kuantum özellikleri etkili olacaktır.

- **Küçük Kuantum Devreleri de Avantajlı Olabilir.**

Kuantum sisteminin belirtilen özelliklerinin yanı sıra, kuantum veri bilimi çeşitli faydalı işlevler üretir. En önemli örneklerden biri, "doğanın yasalarının güvenliği" ile veri iletimine olanak tanıyan kuantum kriptografisidir. Ayrıca, kuantum sisteminin küçük parçaları, yani küçük kuantum devreleri de faydalı olabilir. Örneğin, bu devreler atomik saatlerdeki hassasiyet testlerinde kullanılabilir. Atomik saatler, GPS, uzaktaki teleskoplar ve senkronizasyon ağları için kritik öneme sahiptir. Ayrıca, küçük kuantum devreleri, büyük mesafelerde dolanık durumların dağıtımında da kullanılabilir; bu durumlar, kaçınılmaz olarak gürültülü kanallar üzerinden gönderildiğinde dolanıklık kaybı yaşar. Ancak, birçok zayıf dolanık durumdan birkaç tane son derece dolanık durumun damıtılması mümkündür. (Abdullah et al., 2019)

2.2.7.2.C. Kuantum bilgisayarlar ile geleneksel bilgisayarların karşılaştırılması

- Geleneksel bilgisayarlar bilgiyi bitler (0 ve 1) olarak saklar. Her bit, yalnızca bir değeri temsil edebilir. Kuantum bilgisayarlar ise bilgiyi qubitler ile temsil eder. Bir qubit, 0 ve 1 durumlarının süperpozisyonunda bulunabilir, yani aynı anda hem 0 hem de 1 değerini alabilir.
- Geleneksel bilgisayarlarda hesaplamalar, bitlerin belirli bir sırayla işlenmesiyle gerçekleştirilir. Bu, genellikle lineer bir artış gösterir. Ancak kuantum bilgisayarlar, süperpozisyon ve dolanıklık özelliklerini kullanarak, çok sayıda hesaplamayı aynı anda gerçekleştirebilir. Bu, bazı problemleri klasik bilgisayarlara göre çok daha hızlı çözmelerini sağlar.

- Geleneksel bilgisayarlarda hatalar genellikle yazılım düzeyinde yönetilir ve düzeltme yöntemleri mevcuttur. Ancak kuantum bilgisayarlarda hata oluşma olasılığının daha yüksek olmasının yanı sıra daha karmaşık bir süreç içerdiği bilinmektedir. Bu nedenle, kuantum hata düzeltme kodları geliştirilmiştir. Bu kodlar, kuantum bilgisayarların güvenilirliğini artırmak için kullanılır.
- Geleneksel bilgisayarlar genel amaçlıdır ve birçok farklı uygulama için kullanılabilir. Ancak, bazı karmaşık fiziksel sistemlerin simülasyonu gibi belirli alanlarda sınırlıdır.
- Kuantum bilgisayarlar ise özellikle kuantum sistemlerinin simülasyonu, kriptografi ve büyük veri analizi gibi alanlarda avantaj sağlamasının yanında her tür hesaplama için uygun değildir.
- Geleneksel bilgisayarlar daha yaygın ve erişilebilir, maliyetleri genellikle daha düşüktür. Kuantum Bilgisayarların ise geliştirilmesi ve bakımı yüksek maliyetler gerektirebilir, bu da geniş çapta benimsenmelerini zorlaştırabilir. (Abdullah et al., 2019; Nouioua & Belbachir, 2023)

2.2.7.2.D. Kuantum bilgisayarların kullanım alanları

- **Otonom Araçlar:** Google ve Volkswagen, batarya, ulaşım ve otonom sürüş teknolojilerini geliştirmek için kuantum bilgisayarları kullanmaktadırlar. Bu teknolojiler, kirliliğin ve trafik sıkışıklığının azaltılmasına yardımcı olurken önemli maliyet tasarrufları da sunuyor.
- **Desen Eşleştirme:** Verilerdeki desenleri tanımlamak ve bu desenleri yeni desenleri öngörmek için kullanmak oldukça faydalıdır.
- **Tıbbi Araştırma:** Günümüzde, yeni bir ilacın bulunması ve piyasaya sürülmesi ilaç şirketleri için on yıl kadar sürebilir ve milyarlarca dolara mal olabilir. Kuantum bilgisayarları ile sürecin ön yüzünü iyileştirmek, maliyetleri ve piyasaya sürme süresini önemli ölçüde azaltabilir.
- **Veri Analitiği:** Kuantum bilgisayarlar, dünya genelinde toplanan büyük veri miktarını analiz etmek için kullanılmaktadır.
- **Hava Durumu Tahmini:** Geleneksel simülasyonlar, dikkate alınan büyük faktör sayısı nedeniyle zaman alıcıdır ve birçok işi etkiler. Kuantum bilgisayarların kullanımı ile

hava durumunu daha doğru bir şekilde tahmin edebiliriz, bu da hava koşullarından etkilenen işleri koruyacak ve daha büyük finansal faydalar sağlayacaktır.

- **Havacılık:** Kuantum bilgisayarlar, aeronautik senaryolar gibi karmaşık bilgisayar modellemelerini hızlandırarak milyarlarca dolar hatta tasarruf sağlayabilirler.
- **Kriptografi:** Kuantum bilgisayarlar, şifreleme ve şifre çözme işlemlerini basitleştirerek bilgi sistemlerinin güvenliğini çok daha güçlü hale getirebilir. (Nouioua & Belbachir, 2023)

Son yıllarda bilgisayar sistemlerinde önemli gelişmeler yaşanmıştır. Dijital bilgisayarlardan farklı olarak, kuantum mekaniğine dayanan kuantum sistemleri görevleri süper bilgisayarlardan daha hızlı gerçekleştirebilir. Bu yeni teknolojinin gelecekte bilgisayar sistemlerini önemli düzeyde etkileyeceği düşünülmektedir. Geleneksel bilgisayarların çözemediği uygulamaların kuantum bilgisayarlar ile kolayca çözümleneceği ön görülmektedir. Kuantum bilgisayarlarının yaygınlaşmasının uzun sürmeyeceği ve bilgisayar sistemlerini devrim niteliğinde değiştirmesi beklenmektedir. (Abdullah et al., 2019)

3.GEREÇ VE YÖNTEM

Bu araştırma son yıllarda psikiyatrik bozukların sınıflandırılması ve tedavisinde yapay zekâ yöntemlerinin kullanıldığı çalışmaları ele alan bir literatür taraması şeklinde yapılmıştır. Bu çalışmada ScienceDirect, Google Scholar, Pubmed, YÖK Ulusal Tez Merkezi ve DergiPark tarama sitelerinden yayınlamış olan makale incelemeleri yer almaktadır.



4.SONUÇ VE ÖNERİLER

Günümüzde global düzeyde kamu sağlığı için yaşanan en büyük problemlerden bir tanesi psikiyatrik bozukluklardır. Çünkü bu hastalıkların sonucunda ortaya çıkan sorunlar sadece bireyi değil aynı zamanda aileyi ve toplumu olumsuz etkilemektedir. Psikiyatrik hastalıkların sınıflandırılması ve doğru teşhisinin yapılması başarılı bir tedavi süreci için kritik bir öneme sahiptir. Bu alanda kullanılan yöntemler ve teknikler kişisel değerlendirmelere dayanmaktadır. Dolayısıyla tanı sürecinde ciddi zorluklar ortaya çıkabilmektedir. Bu sürecin sağlıklı işleyebilmesi aynı zamanda doğru bir tedavi sürecini oluşturacaktır.

Doğru sınıflandırma ve teşhis için günümüzde sağlık, hukuk, mühendislik, ulaşım, finans gibi birçok alanda yaygın olarak kullanılan yapay zekâ teknolojisinin devrim niteliğinde bir etki yaratma potansiyeline sahiptir. Bu teknolojinin kullanılması doğru bir sınıflandırma, daha hızlı ve daha objektif şekilde tanı konulmasını kolaylaştıracaktır. Yapay zekâ sadece tanı koyma sürecinde değil aynı zamanda kişiye özel tedavinin yapılması sürecinde de etkin rol oynayabilmektedir.

Yapılan araştırmalarda yapay zekâ yöntemleri kullanılarak hastaların tıbbi geçmişleri, genetik bilgileri, elde edilen klinik verileri, yapılan nörogörüntülemeleri gibi verilerin analizini yaparak daha doğru sonuçların elde edilmesini mümkün kılmıştır. Yapay zekâ için bu verilerin yanı sıra psikiyatrik hastalıkların sınıflandırılması ve tanısı için kullanılan DSM (Diagnostic and Statistical Manual of Mental Disorders) ve ICD (International Classification of Diseases) gibi yöntemler ile elde edilen veriler temel kaynak oluşturmaktadır.

Bu çalışma psikiyatrik hastalıkların sınıflandırılması ve tedavisinde yapay zekâ tekniklerinin kullanılmasına yönelik bir literatür taramasını içermektedir. Burada yer alan çalışmalar gösteriyor ki yapay zekanın teşhis sürecinde kullanılması, yüksek doğruluk oranlarının ortaya çıkmasını sağlamıştır.

Psikiyatrik bozukluk içerisinde en yaygın hastalıklar arasında majör depresif bozukluk, sosyal anksiyete bozukluğu, psikoz, dikkat eksikliği ve hiperaktivite, bipolar, obsesif kompulsif bozukluk, şizofreni, travma sonrası stres bozukluğu ve opiyat

kullanım bozukluğu yer almaktadır. Bu bozukluklara sahip bireylerde görülen semptomlar birbirine benzemektedir ve hastalığın teşhisini zorlaştırarak tedavi sürecini olumsuz etkilemektedir. Tam da bu noktada yapay zekâ teknikleri kullanılarak toplanan tüm verilerin analizi yapılarak doğru tanıyı koymak mümkündür.

Belirsizliklerin ve karmaşıkların çözümlenmesinde kullanılan yapay zekâ tekniği olan bulanık mantığın majör depresif bozukluğunun teşhis edilmesinde kullanılarak yüksek doğruluk oranlarının elde edildiğine dair birçok çalışma yapılmıştır. Depresyon hastaları semptomlarını genel olarak sözel dile getirmektedir. Bulanık mantık bu sözel ifadeleri matematiksel ifadelere dönüştürerek analizini yapıp doğru tanı konulmasında etkili rol oynamaktadır. Önemli halk sağlığı sorunlarında biri olan sosyal anksiyete bozukluğunun teşhis edilmesi için de bulanık mantık kullanılabilir. Sosyal anksiyete bozukluğu kişileri depresyon, madde kullanımı gibi farklı sorunlara yönlendirmemesi için doğru teşhisin yapılması önem arz etmektedir. Sina Fathi ve ark. nın yaptığı araştırmada bulanık mantık teknolojisinin kullanılması ile %98,7 gibi yüksek bir doğruluk oranının tespit edilmesi yapay zekânın etkinliğini bir kez daha ortaya koymaktadır.

Yapay zekanın belki de en çok bilinen ve kullanılan tekniklerinden bir tanesi olan yapay sinir ağlarının psikiyatrik bozukların teşhisindeki önemi yapılan araştırmalarla ortaya konulmuştur. Jian Peng ve ark.nın yaptığı çalışmalar sonucunda özellikle okul çağındaki çocuklarda ortaya çıkan Dikkat Eksikliği Ve Hiperaktivite bozukluğunun teşhisinde yapay sinir ağlarını kullanarak %72,89 gibi bir doğruluk oranı elde ettiklerini açıklamışlardır. Bu metot diğer yöntemler ile karşılaştırıldığında oldukça iyi bir performans gösterdiği söylenebilir. Yaygın ruhsal bozukluklardan bir tanesi olan Bipolar hastalığına sahip bireylerin genellikle depresif oldukları dönemde kliniklere başvurdukları tespit edildiğinden dolayı yaygın olarak depresyon tanısı almaktadırlar. Dolayısıyla Bipolar bozukluğunun tespiti için de kullanılan yapay sinir ağları ile yüksek doğruluk oranları tespit edilmiştir. Sana Yasin ve ark nın çalışmasında %98,75, Yu Lei ve ark. nın araştırmasında ise %96,88 doğruluk oranı elde edilmiştir.

Yapay zekâ teknolojisi denildiğinde akla gelen ilk yöntemlerde biri olan derin öğrenme algoritmalarının büyük verilerin analizi konusundaki başarısı sayesinde şizofreni başta olmak üzere birçok ruhsal bozukluğun teşhisinde etkili bir şekilde kullanılmaktadır. WHO'ya göre dünyada 20 milyon civarında insanı etkileyen şizofreni

hastalığı farklı klinik tablolarla ortaya çıkan psikiyatrik bir bozukluktur. Abhishek Appaji ve ark.nın yaptığı arařtırmalarda derin öğrenme algoritmaları kullanılarak şizofreni tanısında %95 gibi bir doğruluk oranı elde etmişlerdir. Fatıma Hasan, Syed Fawad Hussain ve ark. nın yapay sinir ağı ve derin öğrenme yöntemini birleřtirerek yaptıkları çalışmalarda şizofreni teşhisinde %90 gibi yüksek bir doğruluk oranı elde etmişlerdir. Derin öğrenme algoritmaları travma sonrası stres bozukluğunun sınıflandırılması ve teşhisinde, karmaşık verileri işleyerek özellik çıkarması sayesinde etkili bir yöntem olarak kullanılmaktadır. Arjun Singh ve ark nın yaptığı çalışmada ses örnekleri üzerinden travma sonrası stres bozukluğunun tespitinde %97 gibi bir doğruluk oranı elde etmişlerdir.

Yapılan literatür taraması gösteriyor ki yapay zekâ uygulamaları ruhsal bozuklukların teşhis ve tedavisinde hem zamansal hem maliyet hem de doğruluk oranı açısından önemli avantajlar sağlamaktadır. Bu teknolojinin etkili bir şekilde kullanılması için daha fazla araştırma yapılması gerekmektedir.

KAYNAKLAR

- Amerikan Psikiyatri Birliđi. *Mental Bozuklukların Tanısal ve Sayımsal El Kitabı, Beşinci Baskı (DSM-5)*. (2014). Hekimler Yayın Birliđi.
- Abdullah, R. M., Basher, R., Alwan, A., & Abualkishik, A. Z. (2019). Quantum Computers for Optimization the Performance. *Procedia Computer Science*, 160, 54–60. <https://doi.org/10.1016/J.PROCS.2019.09.443>
- Acar, O. (2020). *Yapay Zekâ Fırsat mı, Yoksa Tehdit mi?* Kriter Yayınevi.
- Acharya, A., & Arnold, Z. (2019). Chinese Public AI R&D Spending: Provisional Findings CSET Issue Brief. *Center for Security and Emerging Technology*.
- Appaji, A., Harish, V., Korann, V., Devi, P., Jacob, A., Padmanabha, A., Kumar, V., Varambally, S., Venkatasubramanian, G., Rao, S. V., Suma, H. N., Webers, C. A. B., Berendschot, T. T. J. M., & Rao, N. P. (2022). Deep learning model using retinal vascular images for classifying schizophrenia. *Schizophrenia Research*, 241, 238–243. <https://doi.org/10.1016/J.SCHRES.2022.01.058>
- Bora, S. (2023). Psikozda Dijital Ruh Sađlığı Müdahalelerinin Kullanımı: Yararlar ve Riskler. *Akdeniz Hemşirelik Dergisi*, 55–64.
- Bostrom, N. (2018). *Süper Zekâ – Yapay Zekâ Uygulamaları, Tehlikeler ve Stratejiler (F. B. Aydar, Çev.)*. Koç Üniversitesi Yayınları.
- Bozüyük, T., Yađcı, C., Gökçe, İ., & Akar, G. (2005). *Yapay Zekâ Teknolojilerinin Endüstrideki Uygulamaları*.
- Chattopadhyay, S., Pratihar, D. K., & De Sarkar, S. C. (2008). Developing fuzzy classifiers to predict the chance of occurrence of adult psychoses. *Knowledge-Based Systems*, 21(6), 479–497. <https://doi.org/10.1016/J.KNOSYS.2008.03.006>
- Closser, D., & Bou-Harb, E. (2022). A live digital forensics approach for quantum mechanical computers. *Forensic Science International: Digital Investigation*, 40, 301341. <https://doi.org/10.1016/J.FSIDI.2022.301341>
- Çoban, M. C. (2021). Trikotillomani Tanı ve Tedavisine Güncel Bakış. *Sosyal, Beşerî ve İdari Bilimler Dergisi*, 4(12), 1193–1210.
- Coşkun, F., & Deniz Güllerođlu, H. (n.d.). *Yapay Zekanın Tarih İçindeki Gelişimi ve Eğitimde Kullanılması*. <https://doi.org/10.30964/auebfd.916220>
- Crane, N. A., Chang, F., Kinney, K. L., & Klumpp, H. (2021). Individual differences in striatal and amygdala response to emotional faces are related to symptom severity in social anxiety disorder. *NeuroImage: Clinical*, 30, 102615. <https://doi.org/10.1016/J.NICL.2021.102615>
- Daniel, Z., Saurabh, M., Erik, B., John, E., Deep, G., Barbara, G., Terah, L., James, M., Juan Carlos, N., Michael, S., Yoav, S., Jack, C., & Raymond, P. (2021). “The AI Index 2021 Annual Report,” *AI Index Steering Committee*.
- Deneubourg, J.-L., Aron, S., Goss, S., & Pasteels, J.-M. (1990). *The self-organizing exploratory pattern of the argentine ant* (Vol. 3). *Journal of Insect Behavior*.
- Dick, S. (2019). Artificial Intelligence. *Harvard Data Science Review*. <https://doi.org/10.1162/99608F92.92FE150C>
- Dođan, F., & Türkođlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 409–445.

- Eğrisöğüt Tiryaki, A., & Kazan, R. (n.d.). Bulaşık Makinesinin Bulanık Mantık ile Modellenmesi. *Mühendis ve Makina*, 48(565), 3–8.
- Elen, A., & Ekmekçi, D. (2020). Popülasyon Tabanlı Meta-sezgisel Optimizasyon Teknikleri. In *Geleceğin Dünyasında Bilimsel ve Mesleki Çalışmalar 2020 Bilgisayar Mühendisliği / I*. Karabük Üniversitesi.
- Erdal Vardar, M. (n.d.). *Türk Psikiyatri Dergisi* 2020;31(3):151-8. <https://doi.org/10.5080/u25070>
- Erguzel, T. T., Ozekes, S., Sayar, G. H., Tan, O., & Tarhan, N. (2015). A hybrid artificial intelligence method to classify trichotillomania and obsessive compulsive disorder. *Neurocomputing*, 161, 220–228. <https://doi.org/10.1016/J.NEUCOM.2015.02.039>
- Ersoy, E., & Karal, Ö. (2012). Yapay Sinir Ağları ve İnsan Beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2).
- Europe and AI: Leading, Lagging Behind, or Carving Its Own Way? - Carnegie Endowment for International Peace.* (n.d.). Retrieved May 1, 2024, from <https://carnegieendowment.org/2020/07/09/europe-and-ai-leading-lagging-behind-or-carving-its-own-way-pub-82236>
- Evren, C. (2010). Sosyal Anksiyete Bozukluğu ve Alkol Kullanım Bozuklukları. *Psikiyatride Güncel Yaklaşımlar*, 473–515.
- Fathi, S., Ahmadi, M., Birashk, B., & Dehnad, A. (2020). Development and use of a clinical decision support system for the diagnosis of social anxiety disorder. *Computer Methods and Programs in Biomedicine*, 190, 105354. <https://doi.org/10.1016/J.CMPB.2020.105354>
- Fazel Zarandi, M. H., Soltanzadeh, S., Mohammadi, A., & Castillo, O. (2019). Designing a general type-2 fuzzy expert system for diagnosis of depression. *Applied Soft Computing*, 80, 329–341. <https://doi.org/10.1016/J.ASOC.2019.03.027>
- Final Report- National Security Commission on Artificial Intelligence.* (2021). <https://www.nscai.gov/wp-content/uploads/2021/03/Full-Report-Digital-1.pdf>
- Fukushima, K. (1975). *Cognitron: A self-organizing multilayered neural network.*
- Furkan Keskenler, M., & Fahri Keskenler, E. (2017). *Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi*. 5, 8–18.
- Furkan Keskenler, M., & Keskenler, E. F. (2017). Bulanık Mantığın Tarihi Gelişimi. *Takvim-i Vekayi*, 5(1), 1–10.
- Ghorbani, A., Davoodi, F., & Zamanifar, K. (2023). Using type-2 fuzzy ontology to improve semantic interoperability for healthcare and diagnosis of depression. *Artificial Intelligence in Medicine*, 135, 102452. <https://doi.org/10.1016/J.ARTMED.2022.102452>
- Goldberg, D. E., & Holland, J. H. (1988). *Genetic Algorithms and Machine Learning* (2nd ed., Vol. 3).
- Gondal Khalid Masud. (2018). *View of Artificial Intelligence and Educational Leadership.* <https://annalskemu.org/journal/index.php/annals/article/view/2591/1860>
- Gündoğdu, Ö. E. (2007). *Veri Madenciliğinde Genetik Algoritmalar*. Kocaeli Üniversitesi.
- Hamet, P., & Tremblay, J. (2017). Artificial intelligence in medicine. *Metabolism*, 69, S36–S40. <https://doi.org/10.1016/J.METABOL.2017.01.011>
- Hassan, F., Hussain, S. F., & Qaisar, S. M. (2023). Fusion of multivariate EEG signals for schizophrenia detection using CNN and machine learning techniques. *Information Fusion*, 92, 466–478. <https://doi.org/10.1016/J.INFFUS.2022.12.019>
- <https://ennurcitir.wordpress.com/2020/02/19/yapay-sinir-aglari>. (n.d.).

<https://www.oecd.ai/dashboards>. (n.d.).

- Jie Sun, Qun-Xi Dong, San-Wang Wang, Yong-Bo Zheng, Xiao-Xing Liu, Tang-Sheng Lu, Kai Yuan, Jie Shi, Bin Hu, Lin Lu, & Ying Han. (2023). Artificial intelligence in psychiatry research, diagnosis, and therapy. *Asian Journal of Psychiatry*, 87.
- Karabağ, M. (2021). Ahlaki Değerlerin Kodlanabilmesi Bağlamında Yapay Zekâ Etiğine Kuramsal Bir Bakış. *TRTakademi*, 06(13).
- Karaođlan, Ö. G. (2007). *Kontrol Sistemleri İçin Bulanık PID Kontrolörlerin Genetik Algoritmalar Yardımıyla Ayarlanması*. İstanbul Teknik Üniversitesi.
- Karataş, İ. (2018). Bulanık Mantık ile Klasik ve Sembolik Mantık İlişkisi (Karşılaştırılması) 1. *European Journal of Educational & Social Sciences*, 3. www.ejess.eu
- Kashyap, A., Callison-Burch, C., & Boland, M. R. (2023). A deep learning method to detect opioid prescription and opioid use disorder from electronic health records. *International Journal of Medical Informatics*, 171, 104979. <https://doi.org/10.1016/J.IJMEDINF.2022.104979>
- Lei, Y., Belkacem, A. N., Wang, X., Sha, S., Wang, C., & Chen, C. (2022). A convolutional neural network-based diagnostic method using resting-state electroencephalograph signals for major depressive and bipolar disorders. *Biomedical Signal Processing and Control*, 72, 103370. <https://doi.org/10.1016/J.BSPC.2021.103370>
- Maltarollo, V. G., Honório, K. M., & Da Silva, A. B. F. (2013). *Applications of Artificial Neural Networks in Chemical Problems*. Intechopen.
- McCulloch, W. S., & Pitts, W. A. (1943). *A logical calculus of the ideas immanent in nervous activity*. *Buttetin of Mathematics and Biophysics* (Vol. 5).
- Mijwil, M. M., Sadikođlu, E., Cengiz, E., Candan, H., Koleji, B., Üniversitesi, E. B., Mühendisliđi, T., Üniversitesi, Y., Fakültesi, M., Mühendisliđi, B., & Üniversitesi, B. T. (2022). *Siber Güvenlikte Yapay Zekanın Rolü ve Önemi: Bir Derleme*. 5(2), 97–105. www.dergipark.gov.tr/veri
- Nabiyev, V. V. (2010). *Yapay Zekâ: İnsan-Bilgisayar Etkileşimi*. Seçkin Yayınları.
- Nilsson, J. N. (2018). *Yapay Zekâ: Geçmişi ve Geleceđi*, (M. Dođan, Çev.). Bođaziçi Üniversitesi Yayınları.
- Nouioua, T., & Belbachir, A. H. (2023). The quantum computer for accelerating image processing and strengthening the security of information systems. *Chinese Journal of Physics*, 81, 104–124. <https://doi.org/10.1016/J.CJPH.2022.11.006>
- Ölmez, Ç. (2010). *Uzaktan Eğitim Sistemlerindeki Soru Bankalarının Bulanık Mantık Yöntem ile Analizi*. Fen Bilimleri Enstitüsü.
- Öztemel, E. (2020). *Bilişim Teknolojileri ve İletişim: Birey ve Toplum Güvenliđi* (Prof. Dr. Muzaffer Şeker Doç. Dr. Yasin Bulduklu Dr. Öğr. Üyesi Cem Korkut Öğr. Gör. Mürsel Doğrul, Ed.; pp. 75–90). Türkiye Bilimler Akademisi.
- Öztürk, K., & Şahin, M. E. (2018'a). *A General View of Artificial Neural Networks and Artificial Intelligence*. 6(2), 25–36. <http://www.sloi.org/sloi-name-of-this-article>
- Öztürk, K., & Şahin, M. E. (2018b). *A General View of Artificial Neural Networks and Artificial Intelligence*. 6(2), 25–36. <http://www.sloi.org/sloi-name-of-this-article>
- Peng, J., Debnath, M., & Biswas, A. K. (2021). Efficacy of novel Summation-based Synergetic Artificial Neural Network in ADHD diagnosis. *Machine Learning with Applications*, 6, 100120. <https://doi.org/10.1016/J.MLWA.2021.100120>
- Pirim, H. (2006). Teknoloji Bađımlı Yaşamanın Matematiksel Desenleri-I. *Journal of Yasar University*, 1(1), 81–93.

- Rajawat, A. S., Bedi, P., Goyal, S. B., Bhaladhare, P., Aggarwal, A., & Singhal, R. S. (2023). Fusion Fuzzy Logic and Deep Learning for Depression Detection Using Facial Expressions. *Procedia Computer Science*, 218, 2795–2805. <https://doi.org/10.1016/J.PROCS.2023.01.251>
- Russell, S., & Norvig, P. (2010). *Artificial Intelligence A Modern Approach Third Edition*. Pearson. <https://doi.org/10.1017/S0269888900007724>
- S, N., Singh, H., & N, A. U. (2022). An extensive review on quantum computers. *Advances in Engineering Software*, 174, 103337. <https://doi.org/10.1016/J.ADVENGSOFT.2022.103337>
- Sanca, M., Artun, H., & Okur, M. (2022). Fen Eğitiminde Bulanık Mantık Uygulamaları Neden Kullanılmalıdır? *Ulusal Eğitim Akademisi Dergisi*, 6(1), 130–144. <https://doi.org/10.329607/uead.1052946>
- Schultz Duane P., & Schultz Sydney Ellen. (2007). *Modern Psikoloji Tarihi*. Kaknüs Yayınları.
- Schuman, C. D., Kulkarni, S. R., Parsa, M., Mitchell, J. P., Date, P., & Kay, B. (2022). Opportunities for neuromorphic computing algorithms and applications. *NatuRe COMPUTatiONal SCieNce*, 2. <https://doi.org/10.1038/s43588-021-00184-y>
- Schuman, C. D., Potok, T. E., Patton, R. M., Douglas Birdwell, J., Dean, M. E., Rose, G. S., & Plank, J. S. (n.d.). *A Survey of Neuromorphic Computing and Neural Networks in Hardware*. Retrieved July 29, 2024, from <http://energy.gov/downloads/doe-public->
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*, 47–64.
- Şen, Z. (2004). *Yapay Sinir Ağları İlkeleri*. Su Vakfı Yayınları.
- Şen, Z. (2009). *Bulanık Mantık İlkeleri ve Modelleme* (3rd ed.). Su Vakfı Yayınları.
- Singh, A., Gupta, S., Goel, L., Agarwal, A. K., & Dargar, S. K. (2024). Archimedes optimization-based Elman Recurrent Neural Network for detection of post-traumatic stress disorder. *Biomedical Signal Processing and Control*, 90, 105806. <https://doi.org/10.1016/J.BSPC.2023.105806>
- Sönmez. (2020). Ders Notu: Yapay Zekâ. In *İstanbul Teknik Üniversitesi*.
- Söyler, H., & Keskinürk, T. (2007). Karınca Kolonisi Algoritması ile Gezen Satıcı Probleminin Çözümü. *8. Türkiye Ekonometri ve İstatistik Kongresi*, 1–11.
- Summakoğlu, D., & Ertuğrul, B. (2018). Şizofreni ve Tedavisi. *Lectio Scientific Journal of Health and Natural Sciences Temmuz*, 2, 43.
- Turing, A. M. (1950). *Mind a Quarterly Review Of Psychology And Philosophy I.-Computing Machinery And Intelligence*. <https://academic.oup.com/mind/article/LIX/236/433/986238>
- University Stanford. (2021). *The One Hundred Year Study On Artificial Intelligence(AI100) Study Panel Report*.
- Wang, W., Zhou, H., Li, W., & Goi, E. (2024). Neuromorphic computing. *Neuromorphic Photonic Devices and Applications*, 27–45. <https://doi.org/10.1016/B978-0-323-98829-2.00006-2>
- Yasin, S., Hussain, S. A., Aslan, S., Raza, I., Muzammel, M., & Othmani, A. (2021). EEG based Major Depressive disorder and Bipolar disorder detection using Neural Networks:A review. *Computer Methods and Programs in Biomedicine*, 202, 106007. <https://doi.org/10.1016/J.CMPB.2021.106007>
- Yeloğlu, Ç. H., & Hocaoğlu, Ç. (2017). Önemli Bir Ruh Sağlığı Sorunu: Bipolar Bozukluk. *Mustafa Kemal Üniversitesi Tıp Dergisi*, 41–54.
- Yılmaz, A., & Kaya, U. (2021). *Derin Öğrenme* (3rd ed.). Kodlab.
- Yılmaz, B. (2018). Obsesif Kompulsif Bozukluk Tedavisinde Güncel Yaklaşımlar. *Lectio Scientific Journal of Health and Natural Sciences*, 2(1), 21–42.

Yılmaz, Ş. (2008). *Çok Depolu Araç Rotalama Probleminin Karınca Kolonisi Optimizasyonu ile Modellenmesi Ve Bir Çözüm Önerisi*. Yıldız Teknik Üniversitesi.

Zhang, C., & Lu, Y. (2021). *Study on artificial intelligence: The state of the art and future prospects*. <https://doi.org/10.1016/j.jii.2021.100224>

