

T.C.
İzmir Kâtip Çelebi Üniversitesi
Fen Bilimleri Enstitüsü

Sağlık Bilimlerinde Yapay Zeka

Yazılım Mühendisliği Ana Bilim Dalı
Yüksek Lisans

Emrah Akkoyun

Proje Danışmanı: Prof. Dr. Merih Palandöken

Aralık 2022



Sağlık Bilimlerinde Yapay Zeka

Yazılım Mühendisliği Ana Bilim Dalı

Yüksek Lisans

Emrah Akkoyun

Proje Danışmanı: Prof. Dr. Merih Palandöken

Aralık 2022

Yazarlık Beyanı

Ben, **Emrah Akkoyun**, başlığı **Sağlık Bilimlerinde Yapay Zeka** olan bu projemin ve proje içinde sunulan bilgilerin şahsıma ait olduğunu beyan ederim. Ayrıca:

- Bu çalışmanın bütünü veya esası bu üniversitede Yüksek Lisans derecesi elde etmek üzere çalıştığım süre içinde gerçekleştirilmiştir.
- Daha önce bu projenin herhangi bir kısmı başka bir derece veya yeterlik almak üzere bu üniversiteye veya başka bir kuruma sunulduysa bu açık biçimde ifade edilmiştir.
- Başkalarının yayımlanmış çalışmalarına başvurduğum durumlarda bu çalışmalara açık biçimde atıfta bulundum.
- Başkalarının çalışmalarından alıntıladığımda kaynağı her zaman belirttim. Projenin bu alıntılar dışında kalan kısmı tümüyle benim kendi çalışmamdır.
- Kayda değer yardım aldığım bütün kaynaklara teşekkür ettim.
- Projede başkalarıyla birlikte gerçekleştirilen çalışmalar varsa onların katkısını ve kendi yaptıklarımı tam olarak açıkladım.

Tarih: 30.12.2022

Sađlık Bilimlerinde Yapay Zeka

ÖZ

Yapay zeka teknolojileri son yılların en hızlı gelişen alanlarından biri olmuştur ve bu teknolojilerin sađlık alanında kullanımı da giderek artmıştır. Özellikle pandemi döneminde, sađlık sistemlerinin iş yükünü azaltmak ve hizmetlerin verimliliğini artırmak amacıyla yapay zeka uygulamalarının kullanımı daha da yaygınlaşmıştır.

Bu çalışmada; Geçmişten günümüze yapay zeka teknolojisinin gelişimi araştırılmış, yapay zeka teknolojisi sađlık bilimlerinde kullanım alanlarına göre incelenmiş, sađlık bilimlerinde kullanılan yapay zeka uygulamaları araştırılmıştır. Doktorlar ve hemşireler tarafından sıkça kullanılan hasta bakım robot tipleri ve çalışma prensipleri incelenmiştir.

Anahtar Kelimeler: Yapay zeka, Teknoloji, Sađlık, Doktor, Hemşire

Teşekkür

Proje çalışmam boyunca, ilgi, destek, bilgi-birikim ve sabrını benden esirgemeyen kıymetli danışman hocam sayın Prof. Dr. Merih Palandöken'e, manevi desteklerini üzerimden esirgemeyen aileme sonsuz teşekkürlerimi sunarım.

İçindekiler

Yazarlık Beyanı	ii
Öz	iii
Teşekkür	iv
Kısaltmalar Listesi	viii
1 Giriş	1
2 Yapay Zeka Kavramı	3
2.1. Yapay Zekanın Tanımı	3
2.2. Yapay Zekanın Tarihçesi	4
2.3. Yapay Zekânın Doğal Zekâdan Farkı	5
3. Sağlık Hizmetlerinde Büyük Veri ve Veri Madenciliği	6
4. Sağlıkta Makine Öğrenmesi Yöntemleri	8
4.1. Makine Öğrenmesi	8
4.2. Makine Öğrenmesi Yöntemleri	8
4.2.1. Denetimli Öğrenme	8
4.2.1.1. K-En Yakın Komşu Algoritması	9
4.2.1.2. Destek Vektör Makineleri	10
4.2.1.3. Yapay Sinir Ağları	11
4.2.1.4. Lojistik Regresyon	12
4.2.1.5. Naive Bayes	12
4.2.1.6. Karar Ağaçları	13
4.2.2. Denetimsiz Öğrenme	14
4.2.2.1. K-Ortalamlar	14
4.2.2.2. Hiyerarşik Kümeleme	15
4.2.3. Pekiştirmeli Öğrenme	16

5. Sağlıkta Derin Öğrenme Teknikleri ve Uygulamaları	17
5.1. Derin Öğrenme	17
5.1.1. Derin Sinir Ağları	18
5.1.2. Evrişimsel Sinir Ağları	19
5.1.3. Tekrarlayan Sinir Ağları	19
5.2. Medikal Görüntü İşlemede Derin Öğrenme Yöntemleri	20
6. Sağlık Bilimlerinde Yapay Zeka Tabanlı Klinik Karar Destek Sistemleri ...	23
6.1. Klinik Karar Destek Sistemleri	23
6.2. Klinik Karar Destek Sistemlerinin Avantajları ve Dezavantajları	25
7. Tıpta Yapay Zeka Uygulamaları	27
7.1. Klinik Araştırmalarda Yapay Zeka ve Makine Öğrenmesi	27
7.2. Nükleer Tıpta Yapay Zeka Uygulamaları	28
7.3. Dermatolojide Yapay Zeka Uygulamaları	29
7.4. Pulmoner Rehabilitasyonda Yapay Zeka; Giyilebilir Takip Cihazları	30
7.4.1. Yapay Zeka ve Teletıp	31
7.4.2. KOAH'LI Hastalarda Giyilebilir Takip Cihazlarının Kullanımı	33
7.5. Klinik Laboratuvarlarda Yapay Zeka	33
7.6. Nöroşirürjide Yapay Zeka ve Gelecek	38
7.7. Oftalmolojide Yapay Zeka	40
8. İlaç Keşfi ve Geliştirilmesinde Yapay Zeka	42
8.1. İlaç Keşfinde Yapay Zeka	42
8.2. İlaç Keşfinde Kullanılan Yapay Zeka Araçları	46
8.2.1. DeepChem	46
8.2.2. DeepTox	46
8.2.3. Deep Neural Net QSAR	47
8.2.4. Neural Graph Fingerprint	47
8.2.5. AlphaFold	47

8.2.6. Chemputer	48
9. Hemşirelik Mesleğinde Yapay Zeka ve Robot Teknolojileri	49
9.1. Hemşirelikte Teknoloji.....	49
9.2. Hemşirelik Uygulamalarında Yapay Zeka.....	51
9.3. Yapay Zeka ve Hemşirelik Yönetimi	54
10. Tıp Alanında Kullanılan Yapay Zeka Teknolojileri	57
10.1. Enlitic	57
10.2. Butterfly Network	58
10.3. Lunit	58
10.4. Arterys	58
10.5. Caption Health	59
10.6. Google DeepMind	60
10.7. Careskore	60
10.8. Oncora Medicine	61
10.9. Bay Labs	61
Sonuç	63
Kaynaklar	65

Kısaltmalar Listesi

DVM	Destek vektör makineleri
YSA	Yapay sinir aęları
ESA	Evrişimsel sinir aęları
RNN	Tekrarlayan sinir aęları
MR	Manyetik Rezonans Görüntüleme
PET	Pozitron emisyon tomografisi
BT	Bilgisayarlı Tomografi
HYS	Hastalık yönetim sistemi
NLP	Doęal dil işleme
KOAH	Kronik obstrüktif akcięer hastalıęı
ESK	Elektronik kayıt sistemi
SBD	Saęlık bilgi deęişimi
TBI	Travmatik beyin hasarı
EEG	Elektroensefalografi

1. Giriş

İnsanlar tarih boyunca farklı yöntemler ve teknolojiler geliştirip kullanarak yaşamlarını kolaylaştırmaya çalışmışlardır. İnsanlar yeni teknolojiler keşfetmiş, bu teknolojileri kullanarak üretim süreçlerini hızlandırmış ve hayat kalitelerini artırmışlardır. Ayrıca, bilim ve teknolojiadaki ilerlemeler sayesinde insanlar sağlık sorunlarını çözmüş ve yaşam sürelerini uzatmışlardır. Bu ilerlemeler, insanların elindekilerle yetinmeyi reddetmeleri ve sürekli öğrenmeyi arzulaması sayesinde mümkün olmuştur. Yaşanan gelişim ve değişimler zamanla yeni bilim dallarının ortaya çıkmasına neden olmuşlardır.

Bilgisayar bilimleri, bilgisayarların ve bilgi işleme sistemlerinin incelenmesi, tasarımı ve kullanımı ile ilgili bir bilim dalıdır. Bu alan, elektronik bilgisayarların ortaya çıkışından bu yana hızla gelişmiştir ve günümüzde çeşitli alanlarda yaygın olarak kullanılmaktadır. Bilgisayar bilimlerinin gelişimi, yapay zeka ve diğer teknolojik ilerlemelerin de gelişimine yardımcı olmuştur. Yapay zeka, 1950'lerde ortaya çıkan bir kavramdır. Bu kavram, bir makine veya bilgisayarın insan gibi düşünme ve öğrenme yeteneğine sahip olması anlamına gelir. Yapay zeka, insan düşüncesinin ve öğrenme sürecinin modelleme yoluyla bir makineye aktarılmasını amaçlar.

Bu çalışma kapsamında sağlık bilimlerinde yapay zeka uygulamaları araştırılmıştır. Çalışmanın ikinci bölümünde, yapay zeka konusu incelenmiştir. Yapay zekanın tarihsel gelişimi anlatılmıştır. Üçüncü bölümde büyük tıbbi veri kavramı, veri madenciliği ve tıpta uygulamalarına yer verilmiştir. Dördüncü bölümde ise makine öğrenmesi kavramı açıklanmıştır. Beşinci bölüm derin öğrenme kavramı ve tıpta uygulanmasından oluşmaktadır. Altıncı bölümde klinik karar destek sistemlerine yer verilmiş, klinik karar destek sistemlerinin avantajları ve dezavantajları açıklanmıştır. Yedinci bölümde klinik araştırmalar, nükleer tıp, dermatoloji, pulmoner rehabilitasyon, klinik laboratuvar, nöroşirürji, oftalmoloji alanlarında yapay zeka uygulamalarından bahsedilmiştir. Sekizinci bölümde ilaç keşfinde yapay zeka kullanımı araştırılmıştır. Dokuzuncu bölümde hemşirelik mesleğinde yapay zeka kullanımı araştırılmış ve hemşirelik bakım robotları incelenmiştir. Onuncu bölümde

günümüzde geliştirilen tıp alanında kullanılan yapay zeka teknolojileri incelenmiştir. Sonuç bölümünde konuyla ilgili değerlendirmelere yer verilmiştir.

2. Yapay Zeka Kavramı

2.1. Yapay Zekanın Tanımı

Bilgi çağında sıklıkla karşılaştığımız “yapay zeka” kavramı farklı şekillerde tanımlanmaktadır. Genel olarak insanlar için yapay zeka insan gibi düşünen ve hareket eden robotları çağrıştırmaktadır.

Yılmaz [1], yapay zeka kavramını şu şekilde açıklamaktadır:

‘Yapay zeka; makinelere akıl yürütme yeteneği kazandıran ve bunun yanı sıra makinelerin problem çözme, kelime ve nesnelere ayırt edebilme ve kendi kendine karar üretebilme gibi kognitif fonksiyonları yani kavramaya ilişkin bilişsel fonksiyonları yerine getirmek adına programlanmış makinelere insan zekasının bir simülasyonu olarak ifade edilebilir.’(s.22).

Yapay zeka çok fazla alanda kendine yer bulunmaktadır. Örneğin:

- Mühendislik: Yapay zeka, makine öğrenimi tekniklerini kullanarak, üretim süreçlerinde kalite kontrolü, hataların tespiti ve önlenmesi gibi görevleri yerine getirebilir.
- Sağlık: Yapay zeka, radyoloji görüntülerinin yorumlanması, tıbbi verilerin analiz edilmesi ve hastalık tanısı konusunda yardımcı olabilir.
- Finans: Yapay zeka, finansal piyasaları tahmin etmek, yatırım kararları vermek ve riskleri azaltmak gibi görevlerde kullanılabilir.
- Eğitim: Yapay zeka, öğrencilerin öğrenme stiline ve ihtiyaçlarına göre özel olarak tasarlanmış öğrenme ortamları oluşturulmasına yardımcı olabilir.
- Güvenlik: Yapay zeka, güvenlik kameralarının görüntülerinin taranması, anormal davranışların tespiti ve önleyici önlemlerin alınması gibi görevlerde kullanılabilir.

- Pazarlama ve satış: Yapay zeka, müşteri profillerini oluşturarak, ürün ve hizmetleri hedef kitlelere ulaştırmak ve satışları artırmak gibi görevlerde kullanılabilir.

2.2. Yapay Zekanın Tarihçesi

Yapay zekanın tarihçesi binlerce yıl öncesine dayanmaktadır. Yapay zekanın geçmişine baktığımızda eski Yunan mitolojisinde “Daedalus” yapay İnsan yaratma kavramı karşımıza çıkmaktadır. Charles Babbage adındaki bir bilim adamı 1884 yılında makinelerin zeki olması adına bu mekanik makineler üzerinde çalışmalar yapmıştır. Bu çalışmalar sonunda makinelerin insan zekası gibi zeki davranışlar sergileyemeyeceği sonucuna varmıştır. Claude Shannon adındaki bir bilim adamı 1950 yılında bilgisayarların satranç oynayabileceğini ileri sürmüştür ve “Bir Bilgisayarı Satranç Oynamak İçin Programlama”, adında satranç oynayan bir bilgisayar programını geliştirmeye yönelik ilk makaleyi yayınlamıştır.

Yapay zekâ, teorik biçimiyle de olsa, bir matematikçi olan Alan Turing’in Computing Machinery and Intelligence (1950) adlı makalesinde modern biçimini almıştır. Turing (1950:19) bu makalede, bilgisayarlara insan gibi düşünmenin öğretilebileceğini, bir çocuğun zihnine benzer bir biçimde tasarlanacak olan bir bilgisayarın öğretim ve tecrübe aktarımıyla eğitilebileceğini savunmuştur. Turing, aynı makalede bir bilgisayarın akıllı olarak kabul edilebilmesi için gerekli olduğunu savunduğu ve günümüze kadar geçerliliğini korumuş olan Turing testini geliştirmiştir. Bu teste göre, bir kişi perdenin gerisinde kiminle iletişim içinde olduğunun bilgisine sahip olmadan, iletişim içinde olduğu şeyin, insan ya da bilgisayar olduğunu ayırt edemezse, bu bilgisayar akıllı olarak nitelenebilir. Bir başka deyişle, Turing düşünebilen makinelerin insanları yanıltabilecek zeka seviyesine ulaşabileceğini öngörmüştür[2].

1956 yılında Dartmouth’da bir konferans düzenlemiş ve McCarthy, yapay zeka ismini, konferansa ad olarak önermiştir. Bu konferans yapay zeka konusunda yeni bir çağın başlangıcı olarak nitelendirilebilir. IBM’de çalışan Arthur Samuel 1960 yılında dama oyunu oynayan bir program geliştirmiş ve bu program dünya şampiyonlarına kafa tutmuştur.

1997 yılında IBM tarafından geliştirilen Deep Blue isimindeki satranç oynayabilen bilgisayar dünya satranç şampiyonu Garry Kasparov'u yenmeyi başarmıştır. 2000 yılında Asimo adında insansı robot Honda şirketi tarafından tasarlanarak üretilmiştir.2009 yılında Google şirketi sürücüsüz araç geliştirmeye başlamıştır.2012 yılında Apple şirketi Siri adını verdiği akıllı asistan programını tanıttı ve cihazlarında kullanmaya başladı. Yapay zeka tarihi çok eski yıllara dayansa da son yıllarda bu alanda yapılan çalışmalar yoğunlaşmıştır.

2.3. Yapay Zekanın Doğal Zekadan Farkı

İnsan beyni kompleks bir yapıya sahiptir ve milyarlarca nörondan oluşur. İnsan beyni yeni bir bilgi karşısında nöronlar arasında yeni bağlantılar kurarak bilgiyi anlamlandırır ve bu süreçte arka planda bir program çalışmaz. Yapay zeka sistemi yeni bilgi karşısında arka planda çalışan program aracılığı ile bilgiyi anlamlandırır.

Doğal zekâya sahip insanlar bilginin kalıcılığı için gerekli olan tekrarlamayı yapmadığında bilgiler kalıcılığını yitirir ve unutulur. Yapay zeka bilgisayar programı değişmediği sürece devamlılığını sürdürür.

Doğal zekada bilginin bir insandan diğerine aktarılması uzun sürerken program içerisindeki bilgi bir bilgisayardan diğerine rahat bir şekilde aktarılır ve kullanım alanı genişler. Yapay zeka kolaylıkla aktarılabilir ve geniş bir kullanıcıya yayılabilir.

Doğal zekaya sahip insan ani ve farklı bir durumla karşılaştığında hızlı tepki verebilir farklı çözümler üretebilir. Yapay zekanın üreteceği çözümler kendisine yüklenen verilerle sınırlı kalır.

İnsan eğitimi maliyetli bir faaliyettir. Yapay zekanın kullanımı birçok alanda insanın eğitilip kullanılmasından daha ucuzdur.

3. Sağlık Hizmetlerinde Büyük Veri ve Veri Madenciliği

Veri madenciliği, çok büyük miktardaki verinin bilgisayar programları tarafından analiz edilerek veriler arasındaki bağlantının keşfedilme süreci olarak tanımlanır. Tıp alanında, veri madenciliği yöntemleri, veriler arasındaki gizli bağlantıları bulma özelliğinden dolayı giderek daha fazla kullanılmaktadır.

Sağlık hizmetlerinde hasta kayıtlarının bilgisayar ortamında saklanması nedeniyle büyük miktarda veri üretilmektedir. Bu veriler büyük hacimli ve çok karmaşık bir yapıya sahiptir ve klasik yöntemlerle bu verileri analiz etmek zordur. Giderek artan verilerin, analiz edilmesindeki zorluğun ortadan kaldırılması için büyük veri kavramı ortaya çıkmış ve verilerin sağlıklı bir şekilde analiz edilmesi için gerekli teknolojik altyapı sağlanmıştır. Büyük sağlık verileri, hasta dokümanları, tıbbi görüntüleme cihazlarından gelen veriler, giyilebilir cihazlardan gelen veriler, laboratuvar sonuçları, genetik analizler, ilaç bilgileri vb. bilgileri içermektedir.

Bilgisayar sistemleri, bir programı çalıştıran programlanmış kuralları kullanarak klinik karar verme desteği sunabilirler. Örneğin, bireysel hasta unsuru, hasta kabul edildiğinde sisteme kaydedilir. Ayrıca hemşirelik ön değerlendirmeleri ve gözlemlerine dayalı veriler de hemşireler tarafından elektronik sağlık kayıtlarına kaydedilir. Her bir bireysel hasta unsuru, bilgisayarlı veri tabanına uyarlanabilir[3].

Büyük tıbbi veri sayesinde yanlış konulan tanıların önüne geçilmektedir. Hastalık tanısını doğru koymak ve etkili tedavi sürecini planlamak, hastaların hastanede kalış süresi azalmaktadır. Hastanede yatış süresinin azalması olası hastane enfeksiyonlarının önüne geçmekte ve tedavi maliyetlerini en aza indirmektedir.

Sağlık sisteminde yer alan tıbbi büyük veri ve veri madenciliği tekniklerini kullanarak hastaların risk durumunu belirleyebiliriz. Örneğin kanser ve kalp damar sistemi hastalıkları gibi ölüm oranı yüksek hastalıklarda veri analitiği teknikleri kullanılarak erken teşhis ile birçok hastanın hayatta kalma süresi ve yaşam konforları artırılabilir.

Hasta olduklarında insanlar genellikle internette araştırma yapmaktadır. Küresel salgın durumlarında karantina sürecinin getirdiği kısıtlamalar nedeniyle insanlar internette hastalık belirtilerini ve tedavi çözümlerini aramaktadır. Bu arama verilerinin, veri madenciliği yöntemleri kullanılarak analiz edilmesi ile küresel salgınlara daha hızlı müdahale etmek ve tıbbi kaynakları verimli kullanmak mümkün olmaktadır.

Büyük tıbbi veri kullanımı doktorların ve diğer sağlık personellerinin işini kolaylaştırmaktadır. Hastanın nabız, solunum hızı vb. hayati değerlerini anlık olarak bildiren sensörler sayesinde riskli durumlar sağlık personeline bildirilir.

Büyük tıbbi veri sayesinde hastanın ilaç dozları etkili şekilde ayarlanabiliyor ve olası yan etkiler en aza indirilerek riskli durumlar azaltılabiliyor. Büyük tıbbi verinin kullanıldığı alanlardan biride hastane yönetimidir. Sağlık yöneticileri hastane personel sayısı, ihtiyaç duyulan malzeme miktarı vb. kararları iyi analiz edip aylık ve yıllık planlar yapmaktadırlar. Büyük tıbbi verinin analiz edilip geleceğe yönelik doğru planlar yapılması sağlık yöneticilerin iş yükünü azaltmakta ve hastalara verilen hizmetin kalitesini arttırmaktadır.

4. Saęlıkta Makine Öğrenmesi Yöntemleri

4.1. Makine Öğrenmesi

Yapay zeka ve makine öğrenmesi kavramları günlük hayatta sıkça karşımıza çıkmaktadır. Bu kavramlar çoęu zaman bir arada kullanıldığı için genellikle karıştırılmaktadır. Makine öğrenimi, veriden öğrenebilen öğrendikleriyle tahminde bulunabilen algoritmalarıdır. Bilgisayarlara veriler yükleyip bu verilerden çıkarım yapan bu çıkarımla tahminde bulunabilen, programlanan bilgiler dışındaki bilgileri de ortaya çıkarabilen ve kendi kendini geliştirebilen sistemlerdir. Makine öğrenimi, yapay zekanın bir alt alanıdır[4].

4.2. Makine Öğrenmesi Yöntemleri

Makine öğrenmesi yöntemleri, bir probleme ait verinin işlenmesi ile anlamlı bağlantılar kurarak karar verebilen algoritma destekli yazılımlardır. Makine öğrenmesi ile mevcut veri setlerine dayanan bir işlemi en uygun hale getirmek için bilgisayarlar programlanabilir. Sınıflandırmalar bilgisayar sayesinde çok kısa sürede ve etkili bir şekilde yapılabilir, yapılan işlemler sonunda bir model oluşturulur ve bu modele dayanarak geleceęe yönelik tahminlerde bulunabilir.

Makine öğrenmesi yöntemleri çok fazla olmakla birlikte en yaygın kullanılan yöntemler; denetimli, denetimsiz ve pekiştirmeli olmak üzere üç grupta incelenmektedir.

4.2.1. Denetimli Öğrenme

Denetimli öğrenme yaygın olarak kullanılan makine öğrenmesi yöntemlerinden biridir. Denetimli öğrenme yöntemlerinin kullanılabilmesi için öncelikle girdi ve çıktıkların bulunduğu eğitim setinin olması gerekmektedir. Denetimli öğrenme yöntemindeki en önemli nokta etiketlenmiş eğitim setiyle modelin eğitilmesidir. Etiketli eğitim setinde hangi verinin hangi bilgiye karşılık geldięi bilinmektedir. Makine öğrenmesi yöntemleri kullanılarak veri setindeki giriş ve çıkış çiftlerine göre

bir model üretilir. Üretilmiş model kullanılarak daha önce hiç görülmemiş yeni ve etiketi bilinmeyen veriler için doğru tahminlerde bulunulur.

Denetimli öğrenme eğitim aşaması ve test aşaması olmak üzere iki aşamadan oluşur. Eğitim aşamasında verilerin bir kısmı kullanılarak öğrenme algoritması bilinen girdi ve sonuç ilişkilerine göre öğrenme sürecini gerçekleştirmiş olur. Test verisi, eğitim verisini öğrenme algoritmasından geçirdikten sonra yapılan tahminlerin doğruluğunu test etmek için kullanılmaktadır. Denetimli öğrenmede çıktının değerine göre sınıflandırma ve regresyon teknikleri kullanılır. Veri kümesindeki veriler, etiketlenebiliyorsa veya kategorik verilerden oluşuyorsa üretilen model sınıflandırıcı olur. Veri kümesindeki etiketler sürekli değerlerden oluşuyorsa üretilen model regresyon olur. Denetimli öğrenmede sıkça kullanılan algoritmalara örnek olarak şunlar verilebilir; K-en yakın komşu algoritması, destek vektör makineleri, yapay sinir ağları, karar ağaçları, lojistik regresyon analizi, basit (naive) bayes sınıflandırıcılarıdır.

4.2.1.1. K-En Yakın Komşu Algoritması

Makine öğrenmesi algoritmaları parametrik ve parametrik olmayan modeller olarak ayrılır. K-En yakın komşu algoritması hem regresyon hem de sınıflandırma problemlerini çözmek için kullanılan, uygulaması kolay parametrik olmayan bir yöntemdir. K-En yakın algoritmasının amacı, test veri setinde yer alan ve sınıfı bilinmeyen bir örneğin eğitim veri setindeki örneklere olan uzaklığını ölçerek sınıflandırmaktır[5]. K-En yakın komşuluk algoritmasında sabit k değeri kullanılır. Yeni verinin mevcut verilere göre uzaklığı hesaplanır, kendisine en yakın k tane komşunun hangi sınıfa ait olduğuna bakılarak sınıfı tahmin edilir. Örneklerin birbirlerine uzaklık değeri hesaplanırken genellikle; Euclidean, Manhattan, Minkowski, Hamming, Öklid gibi uzaklık fonksiyonları kullanılır. K-En yakın algoritması yöntemleri kullanılarak bazı kanser türleri, şeker hastalığı, kalp hastalıkları erken teşhis edilebilmektedir.

4.2.1.2. Destek Vektör Makineleri

Destek vektör makineleri (DVM), Vapnik-Chervonenkis teorisine dayanan, güçlü temelleri olan denetimli bir makine öğrenme algoritmasıdır. DVM; sinir ağları ve radyal tabanlı yapay sinir ağlarına benzerlik gösterse de genellikle bu algoritmalarından daha iyi performans gösterir[6]. Bu yöntem, verilerin bir sınıflandırma veya regresyon problemini çözmek için kullanılan bir modeldir. DVM, verileri çözümlen bir hiper düzleme dayalıdır ve veri noktalarını iki ya da daha fazla sınıfa ayırmak için en uygun düzlemi bulmaya çalışır. Bu sayede, verilerin sınıflandırılması için en uygun karar sınırını belirler.

DVM, diğer makine öğrenmesi yöntemlerine göre daha iyi bir performans gösterir. Özellikle, küçük veri kümeleri için oldukça etkilidir. Ayrıca, verilerin düzensiz veya karmaşık dağılımlarında da iyi sonuçlar verir. Bunun yanı sıra, DVM, çok sayıda öznelik içeren veri kümelerini de işleyebilir.

Destek vektör makineleri, sağlık alanında çeşitli problemleri çözmek için kullanılabilir. Bu makine öğrenme yöntemi, veri setlerindeki nesnelere sınıflandırmak için kullanılır ve bu nedenle sağlık alanında da çok yararlıdır. Örneğin, DVM kanser tespitinde kullanılabilir ve bu sayede doktorların hastalığı erken teşhis edebilmelerine yardımcı olabilir.

DVM'nin sağlık alanındaki avantajları şunlardır:

- DVM, veri setlerinde oldukça büyük bir örneklem sayısına sahip olan problemleri çözebilir. Bu sayede sağlık alanında da büyük veri setleriyle çalışılabilir ve bu veriler doğru bir şekilde sınıflandırılabilir.

- DVM, verilerin düzensiz veya karmaşık dağılımlarına sahip olması durumunda da çok iyi bir performans gösterir. Bu nedenle sağlık alanında da farklı tipteki verilerle çalışılabilir.

- DVM, doğrusal olmayan veri setlerini de sınıflandırabilir. Bu sayede sağlık alanında da farklı doğrusal olmayan veri setleriyle çalışılabilir ve bu veriler doğru bir şekilde sınıflandırılabilir.

- DVM, verilerin boyutlarının fazla olması durumunda da iyi bir performans gösterir. Bu nedenle sağlık alanında da çok boyutlu veri setleriyle çalışılabilir ve bu veriler doğru bir şekilde sınıflandırılabilir.

Bu avantajların yanı sıra, DVM sağlık alanında kullanıldığında doktorların hastalıkları daha doğru bir şekilde teşhis edebilmesine yardımcı olabilir. Bu sayede hastalıklar erken teşhis edilebilir ve bu sayede tedavi süreci daha kısa sürede tamamlanabilir.

4.2.1.3. Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beynindeki sinir hücrelerinin yapısını taklit eden ve yüksek işlem gücüne sahip bir yapay zeka teknolojisidir. Bu teknoloji, makine öğrenmesi, sözcük tanıma ve diğer zor problemleri çözme konusunda oldukça etkilidir.

YSA'lar, sinir hücreleri tarafından oluşturulan bir dizi katmanlardan oluşur. Bu katmanlar arasında veri aktarılır ve bu veri, ağı eğitildiği süre boyunca güncellenir. Bu sayede, YSA'lar öğrendikleri bilgileri hatırlar ve kullanarak karar verme sürecine katılırlar. Yapay sinir ağları, girişler, ağırlıklar, çıkışlar ve birimlerden oluşur. Girişler, verileri ağa sağlar ve bu veriler ağırlıklar tarafından değerlendirilir. Ağırlıklar, verilerin önemini belirler ve çıkışlar, ağı çözümünü sağlar. Birimler ise, girişleri ve ağırlıkları birleştirerek çıkışları üretir.

YSA'ların kullanım alanları oldukça geniştir. Örneğin, YSA'lar ses tanıma, görüntü tanıma, makine öğrenimi, tahminleme ve veri madenciliği gibi alanlarda kullanılabilirler. YSA'ların gelişimi, insanların bilgisayarları nasıl kullanabilecekleri konusunda yeni fırsatlar doğurmaktadır ve bu teknolojinin gelecekteki potansiyeli oldukça yüksektir.

Yapay sinir ağları, verilen girdilere göre öğrenme ve karar verme yeteneğine sahip oldukları için sağlık alanında da oldukça yararlıdır. Örneğin, bir hastanın muayene

sonuçları ve geçmişteki tedavi verilerine dayalı olarak bir tahmin yaparak, doktorların teşhisi konulmasında yardımcı olabilir. Ayrıca, yapay sinir ağları, radyolojik görüntüler gibi çok büyük veri kümelerini değerlendirmek için de kullanılabilir. Bu sayede, doktorların teşhislerini doğrulamada veya yanlış teşhis olasılığını azaltmada yardımcı olabilir. Bu yapının sağlık alanında kullanımının yanı sıra, yapay sinir ağları aynı zamanda tıbbi makine öğrenimi gibi alanlarda da kullanılmaktadır. Örneğin, bir yapay sinir ağı, verilen verilere dayanarak bir kanser tümörünün büyüklüğünü ve yayılma olasılığını tahmin edebilir. Bu sayede doktorlar, hastaların tedavi planlarını belirlerken daha doğru kararlar alabilirler.

4.2.1.4. Lojistik Regresyon

Lojistik regresyon istatistiksel sınıflandırma yöntemlerinden biridir. Lojistik regresyon, verilen bir giriş değişkeni kümesinden bir hedef değişkeni tahmin etmeye çalışır. Hedef değişken genellikle bir sınıflandırma probleminde olduğu gibi iki veya daha fazla sınıfa ayrılmış bir değişkendir.

Lojistik regresyon, doğrusal regresyondan farklı olarak, hedef değişkenin tahmin edilen değerini bir sınıflandırma probleminde olduğu gibi 0 veya 1 arasında bir değer olarak verir. Bu değer, verilen giriş değişkenlerinin bir kombinasyonunun olasılığını gösterir. Örneğin, lojistik regresyon bir kredi kartı başvurusu için giriş değişkenlerini kullanarak, başvurunun kredi kartı sahibi olma olasılığını tahmin edebilir.

Sağlık alanında lojistik regresyon, bir hastanın belirli bir hastalığa sahip olup olmayacağını tahmin etmek için kullanılabilir. Bu tahmin, hastanın bazı değişkenlerini (örneğin yaşı, cinsiyeti veya risk faktörlerini) girdi olarak kullanarak yapılabilir. Lojistik regresyon, sağlık alanında yalnızca hastalık tahmini yapmak için değil, aynı zamanda hastalığın seyrini tahmin etmek ve tedavi seçeneklerini değerlendirmek için de kullanılabilir. Örneğin, bir hastanın belirli bir tedavi seçeneğinin başarı olasılığını tahmin etmek için lojistik regresyon kullanılabilir.

4.2.1.5. Naive Bayes

Naive Bayes, bir kategorize edilme probleminde kategorilerin özelliklerini modelleyen bir algoritmadır. Bu algoritma genellikle sınıflandırma problemlerinde

kullanılır ve giriş verilerinin her bir özelliği için olasılık değerlerini hesaplar. Böylece bir verinin hangi kategoriye ait olduğu konusunda tahminler yapabilir.

Naive Bayes, "naive" (saf) olarak adlandırılmasının nedeni, bu algoritmanın özellikler arasındaki bağımlılıkları yok saymasıdır. Bu algoritma, verilerin özelliklerinin birbirlerinden bağımsız olduğu varsayımını yapar. Bu varsayım genellikle doğru olmayabilir, ancak Naive Bayes'in hızlı ve basit bir şekilde hesaplanmasını sağlar.

Naive Bayes'in en önemli avantajı, veri kümesinin büyüklüğüne göre performansının düşük değişim göstermesidir. Bu algoritma, veri kümesi çok büyük olduğunda bile güvenilir sonuçlar verebilir. Ayrıca Naive Bayes, kategoriler arasında özelliklerin dağılımının benzer olması durumunda daha iyi sonuçlar verir.

Naive Bayes'in en önemli dezavantajı ise, özellikler arasındaki bağımlılıkları yok saymasıdır. Bu, algoritmanın kategorize edilen verilerin gerçek dağılımını tam olarak yansıtmayabilir ve bu da tahminlerin doğruluğunu azaltabilir. Sonuç olarak, Naive Bayes algoritması, kategorize edilme problemlerinde hızlı ve güvenilir bir seçenektir. Özellikler arasındaki bağımlılıkları yok saymasına rağmen, bu algoritma genellikle iyi sonuçlar verebilir ve veri kümesinin büyüklüğüne göre performansı düşük değişim gösterir.

Naive Bayes, bir hastalığın belirtilerini ve bu belirtilerin hangi hastalıkla ilişkili olduğunu bildiğimiz verilerden yola çıkarak, bu verileri kullanarak bir kişinin belirtilerine göre hastalığın hangi olasılıkla ortaya çıktığını tahmin edebilir. Örneğin, bir kişinin ağrısı, ateş yükselmesi ve burun akıntısı gibi belirtileri varsa, Naive Bayes yöntemi bu kişinin grip olasılığını hesaplayabilir.

4.2.1.6. Karar Ağaçları

Karar ağaçları, bir karar verme yöntemidir. Bu yöntem, bir problemi parçalara ayırır ve bu parçaların her birine bir karar verme sürecini uygular. Sonuç olarak, karar ağacı bir karar verme sürecinin adım adım nasıl yapılacağını gösterir.

Bir karar ağacının en temel elemanı, dallardır. Her dal bir karar verme seçeneğini temsil eder ve her seçenek bir sonuç doğurur. Örneğin, bir karar ağacında hava

durumu hakkında bir karar vermek isteyebilirsiniz. Bu durumda, dallar güneşli, bulutlu ve yağmurlu gibi seçenekler olabilir ve her bir seçenek sonucu karar ağacının bir sonraki adımını belirler.

Karar ağaçları, veri madenciliği, makine öğrenimi ve benzeri alanlarda sıklıkla kullanılır. Örneğin, bir hastalığın teşhisini belirlemek için karar ağacı kullanılabilir. Bir hastanın belirtilerini girdiğinizde, ağaç size o hastalığın ne olduğunu söyleyebilir. Ayrıca, bir tedavinin hangisi en iyi olacağını da belirleyebilir. Karar ağaçları ayrıca, hastalık riskini değerlendirmeye yardımcı olabilir. Örneğin, bir kişinin yaşı, cinsiyeti, ailesel geçmişi gibi verilerini girdiğinizde, ağaç size o kişinin belirli bir hastalığa yakalanma riskini söyleyebilir. Bu sayede, kişinin daha iyi bir sağlık planı oluşturabilir.

4.2.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, makine öğrenme tekniklerinden biridir ve verilerden doğrudan öğrenme yapmayı amaçlar. Denetimsiz öğrenme, verilere yönelik bir etiketleme işlemi gerektirmez ve veriler içinde bulunan kalıpları ve düzenlemeleri keşfetmeye çalışır. Bu teknik, veri madenciliği, sınıflandırma, kümeleme gibi birçok alanda kullanılabilir.

Denetimsiz öğrenme, verilere yönelik bir etiketleme işlemi gerektirmez ve bu nedenle veri kümesinin büyüklüğünden bağımsız olarak çalışabilir. Bu teknikte, verilerin içinde bulunan kalıplar ve düzenlemeler otomatik olarak keşfedilir ve bu keşifler doğrultusunda verilere yönelik bir anlamlandırma yapılabilir. Denetimsiz öğrenme, verilerin içinde bulunan farklılıkları ve benzerlikleri keşfetmeyi amaçlar, bu sayede verilere yönelik bir anlamlandırma yapılabilir. Denetimsiz öğrenme türleri arasında K-ortalamlar, Hiyerarşik Kümeleme gibi yöntemler bulunur.

4.2.2.1. K-Ortalamlar

K-ortalamlar bir kümeleme yöntemidir. Kümeleme, verilerinizi benzer niteliklere sahip gruplara ayırmak için kullanılan bir veri madenciliği tekniğidir. K-ortalamlar ise bu tekniğin en popüler yöntemlerinden biridir. K-ortalamlar, veri kümesinde bulunan noktaları en iyi şekilde ayırmak için kullanılan bir algoritmadır. Algoritma,

veri kümesindeki noktaları belirli sayıda gruba (küme) ayırmak için kullanılır. Her bir küme, verilerin ortalama değerine en yakın olan nokta tarafından temsil edilir ve bu noktalara "ağırlık merkezi" denir.

K-ortalamlar algoritması, veri kümesindeki noktaları rastgele kümelere ayırarak başlar. Daha sonra, her bir kümedeki noktaların ortalama değerini hesaplar ve bu değerlere göre kümeleri yeniden ayarlar. Bu işlem birkaç kez tekrarlanır ve sonuç olarak kümeler, verilerin en iyi şekilde ayrılmış hali olacaktır. K-ortalamlar algoritmasının en büyük avantajı, basit ve anlaşılabilir bir yapısıdır. Bunun yanı sıra, bu algoritma veri kümesindeki büyüklük ve dağılımının etkisini azaltarak doğru sonuçlar verir.

Sağlık alanında, bu yöntem genellikle veri madenciliği ve veri analizi için kullanılır. Örneğin, bir hastanenin kayıtlarındaki veriler k-ortalamlar yöntemiyle gruplandırılarak, hastaların benzer özelliklere sahip olup olmadıkları ve tedavi seçenekleri gibi konularda incelenebilir.

4.2.2.2. Hiyerarşik Kümeleme

Hiyerarşik Kümeleme, veri kümeleme yöntemlerinden biridir ve verileri kümeler halinde gruplandırma işlemini gerçekleştirir. Bu yöntem, verileri benzer özelliklere sahip olan gruplar halinde ayırmak için kullanılır. Kümeleme işlemi sonucunda, veriler benzer özelliklere sahip olan gruplar halinde ayrılır ve bu gruplar birbirlerinden farklıdır[7].

Hiyerarşik Kümeleme, iki temel yöntem olan "birleştirme" ve "bölme" yöntemlerini kullanarak işlem yapar. Birleştirme yöntemi, benzer özelliklere sahip olan verileri bir araya getirip bir küme oluştururken, bölme yöntemi ise bir kümeyi daha küçük kümelere böler. Bu yöntemler, verileri hiyerarşik bir yapıda gruplandırmak için kullanılır.

Hiyerarşik Kümeleme, diğer kümeleme yöntemlerine göre daha kolay anlaşılır ve anlaşılması daha kolaydır. Ayrıca, bu yöntem diğer yöntemlerden daha hızlı sonuçlar verir ve daha doğru sonuçlar elde edilebilir. Sağlık alanında bu yöntem kullanılarak hastaların belirtileri ve test sonuçları gibi veriler kullanılarak benzerlik gösteren hastaların kümelerine ayrılabilir. Bu sayede hastaların benzer şikâyetleri veya

belirtileri olan grupların tedavi edilme yöntemleri veya araştırma konuları belirlenebilir.

4.2.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, makine öğrenmesi türü olarak bir öğrenme stratejisidir. Bu strateji, bir ağın performansını iyileştirmek için ödül ve ceza verilerek davranışlarının düzgün bir şekilde öğrenmesini sağlar. Pekiştirme, bir ağın öğrenmesini destekleyen bir yöntemdir ve çoğunlukla bir davranışı iyileştirmeye yönelik kullanılır. Örneğin, bir robotun bir yükü taşıyabilmesi için bir ödül verilebilir. Robot, yükü taşıyabilirse ödül alır ve bunu tekrarlayarak davranışını iyileştirir. Aynı şekilde, robot yükü taşıyamazsa bir ceza verilerek davranışının düzeltilmesi sağlanabilir.

5. Saęlıkta Derin Öğrenme Teknikleri ve Uygulamaları

5.1. Derin Öğrenme

Derin öğrenme; nesne tanıma, konuşma tanıma, doğal dil işleme gibi alanlarda çok katmanlı yapay sinir ağlarını kullanan bir yapay zeka yöntemi olup makine öğrenmesi yöntemlerinden biridir[8]. Bu yöntem, yapay sinir ağlarını kullanarak derin bir girdi verisinden çıktı verisi üretmeyi amaçlar. Bu yöntem, özellikle büyük veri kümelerinde işlev görür ve bu verileri analiz ederek öğrenme ve karar verme süreçlerini otomatikleştirmeye yardımcı olur.

Derin öğrenme, diğer makine öğrenimi tekniklerinden farklı olarak, katmanlar halinde yapılandırılmış yapay sinir ağlarını kullanır. Bu katmanlar, birbirlerine bağlı bir dizi nöron ve sinir hücresi gibi matematiksel fonksiyonları içerir. Girdi verisi, bu katmanların en altında bulunan ilk katmana girilerek işlenir ve her bir katman üzerinden geçtikçe daha da derinleştirilir. Bu süreç, çıktı verisine ulaşana kadar devam eder. Derin öğrenme, çok sayıda veri kümesinde işe yarar ve bu verileri analiz ederek öğrenme ve karar verme süreçlerini otomatikleştirmeye yardımcı olur. Örneğin, bu yöntem resim tanıma, sözcük anlamı tahmini ve ses tanıma gibi alanlarda kullanılabilir. Bu yöntem ayrıca insan beyninin öğrenme süreçlerini modelleyerek, beyindeki sinir ağlarını benzer bir şekilde işletmeyi amaçlar.

Derin öğrenme, saęlık verilerinin analiz edilmesinde de kullanılabilir. Derin öğrenme, çok büyük ve karmaşık veri kümelerini analiz etmek için tasarlanmış yapay sinir ağlarını kullanarak çok katmanlı modeller oluşturmaya izin verir. Bu modeller, verileri işleyip öğrenme sürecinde güçlü korelasyonlar keşfederek, verilerdeki gizli düzenlere veya kalıplara ulaşmaya çalışır. Bu sayede, saęlık verileri için anlamlı çıkarımlar yapılabilir ve hastalıkların teşhisi ve tedavisinde yardımcı olabilir. Örneğin, kanser hastalığı teşhisinde derin öğrenme, özellikle radyolojik görüntüleri inceleyerek tümörlerin varlığını tespit etme konusunda oldukça başarılıdır. Bir görüntü veri kümesi kullanılarak eğitilen bir derin öğrenme modeli, bu görüntüleri

tarayarak tümör belirtilerini tespit edebilir ve bu verileri kullanarak teşhis koyabilir. Derin sinir ağları, evrişimsel sinir ağları, tekrarlayan sinir ağları derin öğrenme tekniklerinden bazılarıdır.

5.1.1. Derin Sinir Ağları

Derin sinir ağları, yapay sinir ağlarının bir türüdür ve çok katmanlı bir yapıya sahiptir. Bunlar, insan beyninin işleyişine benzer bir şekilde çalışır ve girdi verilerini çeşitli ağırlıklar ve eşikler kullanarak işler ve bu sayede çıktılar üretir. Derin sinir ağları, çok fazla veriye sahip olan problemlerin çözümünde oldukça etkilidir ve genellikle çok boyutlu verilerle iş görürler. Örneğin, görüntü tanıma ve ses tanıma gibi alanlarda kullanılabilirler.

Derin sinir ağları, klasik yapay sinir ağlarına göre daha yüksek bir doğruluk oranına sahip olabilirler. Bu, ağın daha fazla katmana sahip olmasından kaynaklanır. Her bir katman, verileri daha fazla özelleştirir ve bu sayede ağ daha hassas bir şekilde çalışabilir. Ayrıca, derin sinir ağları genellikle daha hızlı öğrenme gösterirler ve bu da onların daha etkili olmasını sağlar.

Ancak, derin sinir ağlarının da birkaç dezavantajı vardır. Öncelikle, bu tür ağlar genellikle daha pahalıdır ve daha fazla işlem gücü gerektirirler. Ayrıca, derin sinir ağları bazen aşırı uyum sorununa maruz kalabilirler ve bu da doğruluk oranlarını düşürebilir. Bu nedenle, derin sinir ağlarının kullanımı, verilerin büyüklüğü ve doğruluk oranı gibi faktörlere göre değişebilir.

Derin sinir ağları, güçlü öğrenme yetenekleri sayesinde sağlık alanında birçok farklı uygulama alanı bulabilir. Örneğin, derin sinir ağları hastalık tanısında doktorların doğruluk oranlarını artırabilir, ilaç geliştirme sürecinde yardımcı olabilir ve hastalıkların seyri hakkında daha fazla bilgi edinmeye yardımcı olabilir. Bu gibi uygulamalarda, derin sinir ağları yüksek miktarda veriyi işleyerek, doğruluk oranlarını artırmak için kompleks korelasyonları keşfedebilir. Bu sayede, sağlık alanında derin sinir ağlarının kullanımı, hastalık tanısı ve tedavi seçeneklerini geliştirmeye yardımcı olabilir.

5.1.2. Evrişimsel Sinir Ağları

Evrişimsel sinir ağları, sinir ağlarının bir türüdür ve görüntüleri işlemeye yönelik olarak tasarlanmışlardır. Bu tip sinir ağları, görüntülerin içinde bulunan nesnelere tanıma ve sınıflandırma konusunda oldukça başarılıdır. Bu tip sinir ağları, görüntü işleme alanında kullanılan bir tekniktir ve görüntülerdeki nesnelere doğru bir şekilde tanımlamak için kullanılır. Evrişim işlemi, başlangıçta rastgele değerlere sahip görüntü filtresinin giriş görüntüsü ile evrişim edilmesi işlemidir. Evrişim katmanı geleneksel yapay sinir ağlarında bulunmayan ESA'nın temel yapı taşıdır. Tüm katmanlarda yer alan hücrelerin birbirleri ile bağlantılı olması ve bağlantı ağırlıklarının yenilenmesi yerine küçük bölgelerde evrişim işlemi kullanılmaktadır. ESA'nın en büyük avantajlarından biri evrişim katmanlarında paylaşılan ağırlıklardır. Bu da aynı özellik haritasında aynı filtreleri uygulamak demektir[9].

Evrişimsel sinir ağları sağlık alanında birçok farklı kullanım alanı bulunmaktadır. Örneğin, ESA'lar radyolojik görüntülerin analizinde kullanılabilir ve bu görüntülerde bulunan anormallikleri tespit edebilirler. Ayrıca, ESA'lar diyabetik retinopati gibi göz hastalıklarının tanısında da kullanılabilirler. Bunun yanı sıra, ESA'lar kanser tespitinde de kullanılabilir ve bu hastalığın erken teşhis edilmesine yardımcı olabilirler.

5.1.3. Tekrarlayan Sinir Ağları

Tekrarlayan sinir ağları (RNN) öğrenme algoritmaları olarak adlandırılan bir tür sinir ağıdır. Bu algoritmalar, verilerin birbirleriyle ilişkisi olan serilerini işleyebilir ve bu sayede zaman içinde değişen verileri anlayabilir. Örneğin, bir RNN metni işleyebilir ve anlamlı kelimeleri ayırt edebilir. RNN'ler, sinir ağlarının geleneksel yapısından farklı olarak, girdi verilerine bağlı olarak kendini tekrar eden bir yapıya sahiptir. Bu sayede, RNN'ler veriler arasındaki ilişkileri anlamaya ve geçmiş verilerden yola çıkarak gelecekteki verileri tahmin etmeye yatkındır. RNN'ler ayrıca birçok farklı türde veriyi işleyebilirler. Örneğin, ses, resim ve metin gibi farklı veri türlerini birlikte işleyebilirler ve bu veriler arasındaki ilişkileri keşfedebilirler. Bu özellikleri sayesinde RNN'ler birçok farklı alanda kullanılmaktadır, örneğin metin üzerinde dil

modelleme, resimler üzerinde nesne tanıma ve ses üzerinde konuşma tanıma gibi görevlerde kullanılabilirler.

Tekrarlayan sinir ağlarının sağlık alanında birçok farklı kullanım alanı bulunmaktadır. Örneğin, hipertansiyon kan basıncının yüksek olması durumudur. Bu durum, bir kişinin sağlığını olumsuz yönde etkileyebilir ve kalp krizleri, inme gibi ciddi sağlık sorunlarına yol açabilir. Tekrarlanan sinir ağları, hipertansiyon hastalığının tedavisinde kullanılan bir yöntemdir. Tekrarlanan sinir ağları, hipertansiyonun nedenlerini belirleyebilmek ve tedavisi için etkili bir plan oluşturmak için kullanılır. Bu ağlar, hastalık hakkında bilgi toplayarak, hastalığın seyrini tahmin etmeye ve tedavi seçeneklerini belirlemeye yardımcı olur.

5.2. Medikal Görüntü İşlemede Derin Öğrenme Yöntemleri

Uzun yıllardan beri, manyetik rezonans görüntüleme (MR), bilgisayarlı tomografi (BT), pozitron emisyon tomografisi (PET), mamografi, ultrason ve röntgen gibi tıbbi görüntüleme yöntemleri erken teşhis, tanı ve hastalıkların tedavisi için kullanılmıştır. Kliniklerde tıbbi görüntülerin yorumlaması ise genellikle radyologlar ve hekimler gibi uzman kişiler tarafından yapılmaktadır. Ancak, patolojideki geniş varyasyonlar ve gerçek uzmanların mesleki yorgunluğu, insan hatasına yatkın ve uzmandan uzmana farklılık gösterebilen durumlar göz önüne alındığında, bilgisayar destekli yöntemlerden yararlanmanın oldukça gerekli olduğu söylenebilir[10].

Medikal görüntüleme yöntemleri, vücudun içine girdikleri veya dışından kullandıkları teknolojik araçlar ve yöntemlerle vücudun iç yapısını veya dokularını göstermeyi amaçlayan yöntemlerdir. Bu yöntemler, hastalıkların tanısı, tedavisi ve takibi amacıyla kullanılırlar.

Görüntü işleme, genellikle bir görüntünün elektronik bir forma dönüştürülmesi ve bilgisayar tarafından işlenmesiyle başlar. Bu, bir görüntüyü bir dizi piksel olarak temsil eden bir matris olarak depolamak ve bu pikseller üzerinde işlemler yapmak anlamına gelebilir. Örneğin, bir görüntünün kontrastını artırmak için, piksellerin parlaklık değerleri arasındaki farkı artırmak gerekebilir. Görüntü işlemenin uygulanabilmesi için resimlerin sayısallaştırılması çok önemlidir.

Görüntülerin sayısallaştırılması, pixel değerlerinin bir dizi sayı değerine dönüştürülmesiyle gerçekleştirilir. Bu sayı değerleri, görüntünün her bir pixelinin açık veya karanlık olduğunu belirten bir grayscale değeri veya her bir pixelin renk kanallarının (kırmızı, yeşil ve mavi) değerlerini belirten bir RGB değerine göre belirlenir. Derin öğrenme yöntemlerinin, görüntü işlemede kullanılması bu alanda önemli gelişmelere neden olmuştur.

Derin öğrenme yöntemleri, görüntülerdeki bilgileri daha doğru bir şekilde tahmin etmeyi sağladığı için, bu yöntemler medikal görüntü işlemede oldukça yaygın olarak kullanılmaktadır. Örneğin, bu yöntemler kullanılarak, bir kişinin gözlerindeki görüntülerden diyabet tanısı konulabilmekte ve bu tanı doğruluğu çok yüksek oranlarda sağlanabilmektedir. Ayrıca, derin öğrenme yöntemleri kullanılarak, beyin görüntülerindeki anormalliklerin tespit edilmesi de mümkün olabilmektedir. Medikal görüntü işlemede derin öğrenme teknikleri, görüntülerdeki bilgileri daha doğru bir şekilde tahmin edebilmeyi sağlayarak, çeşitli sağlık durumlarının tanısı ve tedavisinde kullanılmaktadır. Bu tekniklerin kullanımı, tıbbi müdahalelerin daha etkili ve doğru bir şekilde yapılmasına yardımcı olmaktadır.

Medikal görüntüler, doktorlar tarafından hastalık tanısı ve tedavi planının belirlenmesinde önemli bir rol oynayan verilerdir. Ancak bu görüntülerin içeriğini doğru bir şekilde yorumlamak için çok sayıda veriye ve zamana ihtiyaç duyulmaktadır. Bu nedenle, medikal görüntülerdeki nesnelere ayırma ve etiketleme görevini otomatikleştirmek önemlidir.

Derin öğrenme, yapay sinir ağları kullanarak verileri analiz eden bir tekniktir. Bu tekniğin avantajı, veri sayısı ve çeşidinin artmasıyla birlikte modelin performansının da artmasıdır. Bu nedenle, derin öğrenme medikal görüntülerdeki nesnelere ayırmada ve etiketlemede etkili bir yöntemdir. Örneğin, bir derin öğrenme modeli, bir BT görüntüsünde bulunan akciğer tümörlerini ayırabilir ve etiketleyebilir. Bu sayede doktorlar, tümörleri daha kolay tespit edebilir ve hastalıkları daha erken dönemlerde tedavi edebilirler.

Derin öğrenme, medikal görüntülerdeki nesnelere ayırma ve etiketleme görevini otomatikleştirerek doktorların işini kolaylaştırabilir ve hastalıkların daha erken

dönemlerde tanınmasına yardımcı olabilir. Bu nedenle, derin öğrenme medikal alanda önemli bir rol oynayacaktır.

6. Sağlık Bilimlerinde Yapay Zeka

Tabanlı Klinik Karar Destek Sistemleri

6.1. Klinik Karar Destek Sistemleri

Karar verme, insanlar için doğal bir parçasıdır ve hayatın her alanında kararlar almak zorundayız. Ancak, karar verme süreci, kişinin bilgi eksikliği, tecrübe yetersizliği, ön yargıları ve mevcut psikolojik ve fizyolojik durumu gibi çeşitli faktörlerden etkilenir. Bu nedenle, doğru karar verme için, öncelikle bir kişinin kendi durumunu ve seçeneklerini anlamaya çalışması gerekir. En doğru karar verme konusu her alanda önemli bir konudur. Sağlık bilimlerinde özellikle önemlidir, çünkü sağlık konusunda alınan hatalı kararlar insanların hayatlarını ciddi şekilde etkileyebilir. Bu nedenle, sağlık alanında çalışan profesyonellerin en doğru kararları verme yeteneklerine sahip olmaları çok önemlidir. En doğru karar verme için, profesyonellerin ihtiyaç duydukları tüm bilgilere sahip olmaları ve bu bilgileri doğru bir şekilde yorumlamaları gerekir. Sağlık bilimleri birçok bilim dalının birleşiminden oluşur ve bu bilim dalları arasında biyoloji, tıp, epidemiyoloji, psikoloji, ekonomi, sosyoloji, bilgisayar bilimleri gibi birçok farklı alan bulunur. Bu bilim dallarının bir arada çalışması, sağlık hizmetlerinde en doğru kararların alınmasına yardımcı olur. Örneğin, epidemiyoloji ve biyoloji bir salgının yayılımını ve etkilerini anlamaya yardımcı olurken, psikoloji ve sosyoloji insanların sağlık davranışlarını anlamaya yardımcı olur. Ekonomi de sağlık hizmetlerinin maliyetlerini ve kaynaklarının nasıl en iyi şekilde kullanılabileceğini araştırır. Bu bilim dallarının bir arada çalışması, sağlık hizmetlerinde en etkili ve etkin sonuçların elde edilebilmesini sağlar. Teknolojinin gelişmesiyle birlikte sağlık bilimlerinde de yapay zekâ tabanlı teknolojiler kullanılmaya başlamıştır. Bu teknolojiler, özellikle veri madenciliği ve makine öğrenimi gibi yöntemleri kullanarak, çeşitli sağlık verilerini analiz etme ve bu verilere dayalı tahminler yapma gibi işlemleri gerçekleştirebilmektedir. Örneğin, yapay zekâ tabanlı teknolojiler, hastalık tanısı ve tedavisi konusunda doktorların karar verme sürecine yardımcı olabilir, ya da epidemiyolojik verileri analiz ederek bir salgının yayılımını tahmin etmeye yardımcı olabilir.

Klinik karar destek sistemleri, yapay zeka teknolojisi kullanarak sađlık hizmetleri alanında kullanılan bir tür sistemdir. Bu sistemler, sađlık personeli için klinik kararlar verme sürecinde yardımcı olmak için tasarlanmıştır ve genellikle bireylerin geçmiş sađlık verileri, laboratuvar testleri ve diđer bilgiler gibi verileri analiz ederek doktorların ve diđer sađlık çalışanlarının klinik kararlarını desteklemek için kullanılır. Yapay zeka teknolojisi, bu sistemlerin verileri analiz etme ve karar verme süreçlerini hızlandırmak ve doğruluđunu artırmak için kullanılır. Bu sayede sađlık personeli, klinik kararlarını daha hızlı ve doğru bir şekilde verebilir ve böylece hastalarının sađlık durumlarını daha etkili bir şekilde yönetebilir.

Klinik karar destek sistemleri ayrıca hatırlatıcı ve uyarıcı sistemler de içerebilir. Bu tür sistemler, doktorların ve diđer sađlık profesyonellerinin unutmayacakları önemli bilgileri hatırlatır ve gerekli olduđunda uyarılar verir. Örneđin, bir hastanın aşılarının zamanı geldiđinde bir uyarı gönderebilir veya bir hastanın takipte olması gereken bir sađlık durumunun olup olmadıđını hatırlatabilir. Bu tür sistemler, doktorların ve diđer sađlık profesyonellerinin hatalı kararlar vermesini önleyerek hastaların sađlığını koruma konusunda yardımcı olurlar.

Tanılama sistemleri, klinik karar destek sistemlerinin bir alt kategorisi olarak kabul edilebilir. Bu sistemler, hekimlerin hastalık tanılarını koymada yardımcı olmak amacıyla tasarlandı. Tanılama sistemleri, genellikle hastalık belirtileri ve risk faktörleri gibi verileri analiz ederek hekimlere öneriler sunar. Bu sistemler, hekimlerin tanı koyma sürecini hızlandırabilir ve doğruluđunu artırabilir. Ancak, tanılama sistemleri yalnızca hekimlerin kararlarını desteklemek için tasarlandıđından, son kararın sorumluluđu hekimlerin elindedir.

Hastalık yönetim sistemleri (HYS), klinik karar destek sistemlerinden bir türüdür. Bu sistemler, doktorlar ve diđer sađlık çalışanlarına hastalıkların belirtilerini, sebeplerini ve tedavilerini anlamalarına yardımcı olmak için geliştirilmiştir. Hastalık yönetim sistemleri, genellikle hastalıkların belirtilerini girerek bu belirtileri tanımlayan bir veri tabanına erişerek doktorların tanı koymalarına yardımcı olur. Bununla birlikte, hastalık yönetim sistemleri aynı zamanda hastalıkların tedavisi ve ilgili sađlık kuruluşları hakkında da bilgi sunabilir. Genel olarak, hastalık yönetim sistemleri doktorların hastaları daha iyi tanıyarak daha etkili tedaviler önerebilmelerine yardımcı olur.

Klinik destek karar sistemlerinin alt dallarından biri olan ilaç dozu hesaplama sistemleri, doktorlar ve diğer sağlık profesyonellerine yardımcı olmak için geliştirilen yazılımlardır. Bu sistemler, hastaların vücut ağırlıkları, yaşları ve diğer faktörler göz önüne alınarak doğru ilaç dozunu hesaplamak için kullanılır. Bu sayede doktorlar ve diğer sağlık profesyonelleri, hastalarına en uygun ilaç dozunu vermek için güvenilir bir kaynaktan yararlanabilirler[11].

Reçete oluşturma sistemleri, hekimlerin hastalarına ilaç reçetesi yazarken kullandıkları bir tür klinik karar destek sistemidir. Bu sistemler, hekimlerin reçete yazarken doğru ilaç seçimini yapmalarına yardımcı olmak için tasarlandı. Bu sistemler, ilaçların etkileşimlerini, yan etkilerini ve dozajlarını dikkate alarak hekimlere reçete yazarken yardımcı olurlar. Böylece, reçete oluşturma sistemleri, hekimlerin daha doğru ve güvenilir reçeteler yazmasına yardımcı olur.

6.2. Klinik Karar Destek Sistemlerinin Avantajları ve Dezavantajları

Klinik karar destek sistemleri günümüzde pek çok ülkede sağlık işletmelerinde aktif olarak kullanılmaktadır. Klinik karar destek sistemleri, hastaların değerlendirilmesi tedavi seçeneklerinin belirlenmesi ve tedavi sürecinin izlenmesi gibi birçok klinik karar verme sürecinde yardımcı olarak kullanılmaktadır.

Klinik karar destek sistemlerinin bazı avantajları şunlardır:

1. Önerilen tedavi seçenekleri, hastalıkların çeşitli verilerine dayanarak belirlenir, bu da doğru karar verme ihtimalini arttırabilir.
2. Sistemler, hastalıkların belirtilerine ve tedavi seçeneklerine ilişkin geniş bir veri tabanına sahiptir, bu da hekimlerin daha hızlı ve doğru kararlar vermesine yardımcı olabilir.
3. Klinik karar destek sistemleri, hekimlerin dikkatini önemli noktalara odaklayarak onlara zaman kazandırabilir.
4. Bu sistemler, hekimlerin hatalı kararlar verme olasılığını azaltarak hatalı tedavileri önleyebilir.

5. Klinik karar destek sistemleri, hastaların durumlarının deęişimini izleyerek hekimlerin daha iyi bir takip saęlamasına yardımcı olabilir.

Klinik karar destek sistemlerinin bazı dezavantajları da vardır. Bu sistemlerin kullanımı sırasında doktorların kendi klinik deneyimlerini ve anlamalarını kullanmalarını azaltabilir. Bu, doktorların tecrübelerini kullanarak yapacakları kararların doęruluęu ve etkinlięi üzerinde olumsuz bir etki yaratabilir. Klinik karar destek sistemleri genellikle pahalıdır ve bu yüzden tüm saęlık kuruluşları tarafından kolaylıkla kullanılamayabilir.

7. Tıpta Yapay Zeka Uygulamaları

7.1. Klinik Araştırmalarda Yapay Zeka ve Makine Öğrenmesi

Klinik araştırmalar, insanlar üzerinde yapılan çalışmalardır ve genellikle yeni ilaçların etkinliğini ve güvenilirliğini test etmek amacıyla yapılır. Klinik araştırmalar, çeşitli sağlık sorunlarının tanısı, tedavisi ve önlenmesi konusunda önemli bilgiler sağlar. Klinik araştırmaların süreci etik onaydan başlar ve araştırma sonuçlarının yayınlanıp kamuya duyurulmasına kadar devam eder. Bu süreçte araştırmacılar araştırma planını oluşturur ve bu planı uygularlar. Plan, araştırma sorularını, hipotezlerini, çalışma grubunu, örnekleme yöntemlerini, veri toplama yöntemlerini ve sonuçları değerlendirme yöntemlerini içerir[12]. Makine öğrenmesi, verileri analiz etme ve bu verilerden öğrenme yapma yeteneğine sahip bir yöntemdir. Bu sayede, klinik araştırmalarda kullanılabilecek birçok potansiyel fayda ortaya çıkmaktadır. Bir klinik araştırmanın tasarımından analizine kadar birçok aşamalarında yapay zeka ve makine öğrenmesi kullanılmaktadır.

Günümüzde ilaç Ar-Ge'sine yardımcı olmak için yapay zeka destekli dijital ilaç geliştirme platformları kullanılmaktadır. Dijital ilaç keşfi ve geliştirme, bilgisayar destekli yöntemler kullanarak ilaçların tasarımı, üretimi ve test edilmesidir. Bu teknikler, ilaçların etkinliğini ve güvenliğini artırmak için kullanılır ve genellikle klasik ilaç geliştirme yöntemlerine kıyasla daha hızlı ve daha etkilidir.

Dijital ilaç keşfi ve geliştirme, makine öğrenimi teknikleri kullanarak ilaç keşfi ve geliştirme süreçlerini hızlandırmayı amaçlar. Bu teknikler, ilaçların potansiyel etkilerini tahmin etmek için kullanılabilir ve ilaç geliştirme süreçlerini daha verimli hale getirebilir. Makine öğrenimi, veri madenciliği ve diğer algoritmalar kullanılarak, ilaçların potansiyel etkilerini belirleme sürecini hızlandırabilir. Bu, ilaç geliştirme süreçlerini daha hızlı ve daha doğru hale getirebilir ve insanların daha hızlı bir şekilde iyileşmesine yardımcı olabilir.

Yapay zeka teknolojileri, pre-klinik araştırma evrelerinde, çeşitli biyolojik ve tıbbi modeller kullanılarak çalışılır. Bu modeller, insan vücudunun veya insan hastalıklarının in vitro veya in vivo koşullarda nasıl etkileneceğini anlamak için kullanılır. Örneğin, yapay zeka teknolojileri kullanılarak, bir ilaç molekülünün insan hücrelerine nasıl etki edeceği veya bir hastalığın nasıl tedavi edilebileceği araştırılabilir. Ayrıca, yapay zeka teknolojileri kullanılarak, insan vücudunun nasıl tepki vereceği veya nasıl etkileneceği hakkında daha fazla bilgi edinilebilir. Bu araştırmalar, ilaç geliştirme sürecinde önemli bir rol oynar ve insan sağlığı için büyük önem taşır.

Klinik araştırma randomizasyonu, bir araştırmanın katılımcılarını rastgele gruplara dağıtmak için kullanılan bir yöntemdir. Bu sayede, araştırmacılar denekler arasında doğal olarak ortaya çıkabilecek farklılıkları ortadan kaldırarak daha doğru sonuçlar elde edebilirler. Yapay zeka, bu işlemlerde kullanılarak katılımcı seçimi ve randomizasyon işlemlerini hızlandırabilir ve daha doğru sonuçlar elde etmeyi mümkün kılabilir. Bu sayede, araştırmalar daha hızlı tamamlanabilir ve daha fazla insana yardımcı olabilir.

7.2. Nükleer Tıpta Yapay Zeka Uygulamaları

Nükleer tıp, tıp alanında radyolojik yöntemler kullanarak hastalıkların tanı, tedavi ve izleme sürecini gerçekleştiren bir alandır. Nükleer tıp uzmanları, radyoaktif işaretçiler kullanarak vücudun içinde olan organları ve dokuları inceleyerek hastalıkların yerini ve seviyesini belirlerler. Radyolojik görüntüleme teknikleri ise bu işaretleyicilerin birikimini görüntüleyebilmektedir.

Nükleer tıp, çeşitli hastalıkların tanısında ve tedavisinde kullanılabilir. Örneğin, nükleer tıp yöntemleri kalp hastalıklarının tanısında kullanılabilir. Bu yöntemler, kalbin işlevini ve kan akışını izleyebilir ve bu sayede kalp yetmezliği gibi durumların erken teşhis edilmesine yardımcı olabilir. Ayrıca, nükleer tıp yöntemleri, tümörlerin yeri ve büyüklüğünü belirlemede de kullanılabilir. Bu sayede tümörlerin tedavisine yönelik daha etkili bir planlama yapılabilir. Derin öğrenme tıpta özellikle görüntü analizinde ve biyomedikal alanlardaki uygulamalar ile ön plana çıkmaktadır. Görüntü analizinde tıpta en yaygın kullanılan yapay zeka alanı eğitimli derin

öğrenmenin özel bir yapılandırılması olan evrimsel sinir ağlarıdır. Dolayısıyla yapay zekanın yaygın kullanımı da özellikle BT ve MR gibi görüntüleme teknikleri üzerine olmuştur[13]. Tümörlerin teşhisi için kullanılan radyolojik görüntüleme yöntemleri, tümörlerin büyüklüğü, şekli, yapısı ve yerleşimi hakkında bilgi toplamaya yardımcı olur. Ancak bu görüntüler tek başlarına yeterli olmayabilir ve tümörlerin teşhisi için daha fazla bilgiye ihtiyaç duyulabilir. Bu noktada radyomik devreye girer ve görüntülerdeki özelliklerin değişimlerini inceleyerek, tümörlerin teşhisi ve tedavisi hakkında daha fazla bilgi toplamaya yardımcı olur.

Radyomik, radyolojik veri madenciliği olarak da adlandırılabilir, radyolojik görüntüler üzerinde çok sayıda matematiksel ve istatistiksel özelliği belirleyen bir yöntemdir. Bu özellikler, doktorların hastalık belirtilerini belirleme ve tedavi seçeneklerini değerlendirme gibi amaçlar için kullanılır. Radyomik, tümörlerin heterojenliğini belirlemeye yardımcı olmaktadır.

Yapay zekanın tıptaki önemli uygulamalarından biri MR görüntülerinden BT görüntülerinin tahmin edilmesidir. MR görüntülerinden BT görüntülerinin tahmin edilmesi, MR görüntülerini kullanarak BT görüntülerini tahmin etmeye çalışan bir makine öğrenme modelidir. Bu model, MR görüntülerinde bulunan bilgiyi kullanarak BT görüntülerini tahmin etmeye çalışır. Bu teknik, radyolojik görüntüleme tekniklerinde daha hızlı ve doğru teşhis koyabilmeyi sağlayabilir. Ancak, bu teknik henüz tam olarak geliştirilmemiştir ve daha fazla araştırma ve geliştirme gerekmektedir.

7.3. Dermatolojide Yapay Zeka Uygulamaları

Dermatoloji, cilt ve cilt hastalıklarının tanı ve tedavisini konu alan bir tıbbi dalıdır. Bu dal, dermatolojik hastalıkların tedavisinde çeşitli yöntemler kullanır, bunlar arasında ilaç tedavisi, cerrahi müdahale ve diğer tedavi yöntemleri sayılabilir.

Dijital dermatoskopi, ciltteki küçük lezyonları ve anormal dokuları taramak için kullanılan bir yöntemdir. Bu yöntem, bir dermatoskop adı verilen bir cihaz kullanılarak yapılır ve ciltteki lezyonların daha iyi görüntülenmesini sağlar. Yapay zeka, dijital dermatoskopi sürecinde kullanılabilir ve ciltteki lezyonların tespiti ve değerlendirilmesinde yardımcı olabilir. Bu sistemler, çeşitli cilt lezyonlarının

görüntülerini görsel olarak tanıyarak, doktorların tanı koymalarına yardımcı olabilir. Ayrıca, yapay zeka teknolojisi, ciltteki melanom (kötü huylu deri kanseri) tespitinde de kullanılmaktadır. Bu teknolojiler, ciltteki lezyonların derinliklerini ve boyutlarını tespit ederek, doktorların melanom teşhisi koymalarına yardımcı olabilir.

Dermatologlar evrimsel sinir ağları kullanarak oluşturdukları yapay zeka uygulamasını melanom ve melanom dışı kanserlerin tanısında kullanmışlardır. Yapılan çalışma sonucunda yapay zeka ile dermatologların koyduğu tanıları karşılaştırılmış ve tanıların benzer olduğu görülmüştür.

Yapay zeka teknolojisi, cilt bakımı alanında da kullanılmaktadır. Örneğin, cilt bakımı ürünlerinin seçiminde yapay zeka kullanılabilir. Bu, kullanıcının cilt tipine ve problemlerine uygun ürünleri tavsiye etmek için yapay zeka algoritmaları kullanılabilir.

7.4. Pulmoner Rehabilitasyonda Yapay Zeka; Giyilebilir Takip Cihazları

Kronik solunum yolu hastalıkları, solunum sisteminde sürekli veya sık tekrarlayan enflamasyon veya hasar nedeniyle ortaya çıkan hastalıklardır. Bu hastalıklar solunum yolu tıkanıklığı, solunum yetmezliği ve solunum sıkıntısı gibi belirtilere yol açabilir. Kronik solunum yolu hastalıkları, çeşitli nedenlerden dolayı ortaya çıkabilir ve çok farklı şekillerde seyredebilir. Örneğin, astım ve kronik obstrüktif akciğer hastalığı (KOAH) gibi çeşitli solunum yolu hastalıkları kronik solunum yolu hastalıklarına örnek olarak verilebilir.

Kronik solunum yolu hastalıkları genellikle tamamen iyileşmez, ancak hastalığın seyri yavaşlatılabilir ve belirtileri azaltılabilir. Bu hastalıklarının tedavisi genellikle ilaçlarla ve yaşam tarzı değişiklikleriyle desteklenir. Bu değişiklikler, sigara içmekten kaçınılması, egzersiz yapılması, zayıflamak ve stresten uzak durmak gibi konularda düzenlemelere yönelik olabilir. Hastaların akciğer işlevselliğinin devamlılığını sağlamak için uzun süreli takip ve pulmoner rehabilitasyon gereklidir.

Pulmoner rehabilitasyon, kronik solunum yolu hastalıklarının tedavisinde etkili bir yöntemdir. Bu tedavi, solunum yetmezliği ve solunum sıkıntısı gibi belirtileri

azaltmaya ve hastalığın seyrini yavaşlatmaya yardımcı olur. Pulmoner rehabilitasyon, birçok farklı tedavi yöntemini bir araya getirerek hastanın fiziksel, duygusal ve sosyal ihtiyaçlarına yönelik bir yaklaşım sunar. Bu tedavi programı, egzersizler, nefes egzersizleri, beslenme tavsiyeleri, psikolojik destek ve solunum cihazları gibi farklı yöntemleri içerebilir. Kronik solunum yolu hastalıklarının tedavisi sırasında pulmoner rehabilitasyon, hastanın iyileşme sürecine yardımcı olabilir ve onun yaşam kalitesini artırabilir.

Pulmoner rehabilitasyonun temel hedefleri arasında aşağıdakiler sayılabilir:

- Solunum yeteneğini artırmak ve solunum kapasitesini maksimum düzeye çıkarmak
- Akciğer hastalığının etkilerini azaltmak ve hastalığın seyriyle baş etme becerilerini geliştirmek
- Öksürük ve balgam söktürme yeteneğini artırmak
- Nefes darlığını azaltmak ve nefes alma ve verme tekniklerini iyileştirmek
- Fiziksel aktivite düzeyini artırmak ve günlük yaşam aktivitelerinde daha fazla bağımsızlık sağlamak
- Psiko-sosyal desteği sağlamak ve hastalıkla baş etmeyi kolaylaştırmak

Pulmoner rehabilitasyon hastanede yatarak, evde ve ayakta takipli olarak yapılabilir.

7.4.1. Yapay Zeka ve Teletıp

Sağlıkta sanallaşma süreçlerinde önemli alanlardan biri TeleSağlık uygulamalarıdır. Hastanelerle fiziksel iletişimin olmaması gereken bir dönemde sanal hemşirelik, uzaktan tedavi, NLP tabanlı tanı ve yönlendirme sistemleri kullanılmakta ve geliştirilmektedir[14]. Yaşlı nüfusun artışı, evde hasta bakımı gibi hizmetlere olan ihtiyacı artırmaktadır. Yaşlı nüfusun artışı, sağlık hizmetlerinde daha fazla personel ve kaynak gerektirir. Bu nedenle, evde hasta bakımı gibi hizmetler önem kazanmaktadır. Evde hasta bakımı, yaşlı veya engelli bireylerin evlerinde sağlık

hizmetlerine erişimini kolaylaştırır ve onların yaşam kalitesini artırmaya yardımcı olur.

Tele tıp, uzaktan tıbbi değerlendirme ve tedavi sağlamak amacıyla kullanılan bir teknolojidir. Bu teknoloji sayesinde doktorlar ve diğer sağlık çalışanları, hastalarının sağlık durumunu uzaktan izleyebilir ve onlara tıbbi yardım sağlayabilirler. Evde hasta bakımına yönelik teknolojik gelişmeler, bu hizmetlerin verimliliğini ve etkinliğini artırmaktadır. Örneğin, evde hasta bakımı hizmetleri artık cep telefonları ve tabletler gibi cihazlarla da yapılabilmektedir. Bu cihazlar sayesinde, doktorlar ve diğer sağlık profesyonelleri hastalarının durumlarını uzaktan izleyebilir ve gerektiğinde müdahale edebilirler. Ayrıca, bu cihazlar sayesinde hastalar da kendilerini daha rahat hissedebilir ve sağlık profesyonellerine daha kolay ulaşabilirler. Bu teknolojik gelişmeler, evde hasta bakımı hizmetlerini daha verimli ve etkili hale getirmektedir. Teletıp uygulamalarının hızla gelişmesi ile pulmoner rehabilitasyon programları giyilebilir takip cihazları aracılığı ile gerçekleştirilmektedir. Yapay zeka, sağlığımızla ilgili daha iyi kararlar alması için bizi bireyleri güçlendirme potansiyeline sahiptir. Günümüzde çok sayıda insan, uyku düzenlerinden kalp atış hızlarına kadar günlük bilgi toplamak için giyilebilir teknoloji cihazlarını kullanmaktadır. Bu giyilebilir teknolojik cihazlar yardımıyla toplanan verilerle, makine öğrenimi ile mantıklı ve rasyonel sonuçlar türeterek bazı hastalık riskleri altında olan insanları bilgilendirebilmektedir[15].

Giyilebilir takip cihazlarının ilk örnekleri, 1960'larda ortaya çıkmıştır. Bu dönemde, NASA tarafından uzay görevleri sırasında kullanılan "ölçeklendirilebilir biyolojik sinyal izleyicisi" adlı cihazlar, giyilebilir takip cihazlarının ilk örnekleri olarak kabul edilmektedir. Ancak, giyilebilir takip cihazlarının yaygın olarak kullanımı ancak 21. yüzyılın başlarında gerçekleşmiştir. Özellikle, 2000'li yılların ortalarından itibaren bu cihazların teknolojik gelişmeler ve düşük fiyatlar sayesinde daha da yaygınlaşmasına neden olmuştur.

7.4.2. KOAH'LI Hastalarda Giyilebilir Takip Cihazlarının Kullanımı

Kronik obstrüktif akciğer hastalığı (KOAH), hava yolu tıkanıklığına neden olan bir hastalıktır. Bu tıkanıklık, hava yollarının genişlemesini engellediğinden, solunum yapmak zorlaşır ve solunum sıkıntısı ortaya çıkar. Bu hastalık, sigara içimi ve diğer hava kirliliği kaynaklarından kaynaklanan zararlı maddelerin zamanla hava yollarını tıkamasına neden olur. Günümüzde Kronik obstrüktif akciğer hastalığı(KOAH) önemli bir halk sağlığı sorunu haline gelmiştir.

Giyilebilir pulmoner rehabilitasyon, obstrüktif akciğer hastalığı (KOAH) olan kişilerin solunum fonksiyonlarını iyileştirmelerine yardımcı olmak için giyilebilir cihazlar kullanan bir rehabilitasyon türüdür. Bu cihazlar tipik olarak yelek veya kemer gibi vücuda giyilebilen küçük, taşınabilir cihazlardan oluşur ve akciğer fonksiyonunu iyileştirmeye ve KOAH semptomlarını hafifletmeye yardımcı olmak için hedefe yönelik solunum egzersizleri ve diğer tedavileri sağlamak üzere tasarlanmıştır. KOAH hasta sayısı her geçen gün hızla artmaktadır ancak bu hastaların sağlık durumunu izlemek için gerekli gelişmeler kısıtlıdır. Doktorlar, hastaların KOAH tedavisinde nasıl ilerlediğini daha iyi anlayarak daha etkili bir tedavi planı oluşturabilmeleri için çok fazla veriye ihtiyaç duymaktadır. Bu nedenle hastalardan ev ortamında giyilebilir teknoloji ile toplanan kalp hızı, solunum hızı gibi fizyolojik veriler hastanın klinik durumunu değerlendirmede doktorlara yardımcı olmuştur.

Pulmoner rehabilitasyonun evde uygulanması, hastane yükünü ve bakım maliyetlerini azaltmaktadır. Giyilebilir cihaz teknolojisinin gelişmeye devam etmesi ile pulmoner rehabilitasyonun takibi de paralel olarak gelişecektir.

7.5. Klinik Laboratuvarlarda Yapay Zeka

Enfeksiyon hastalıklarında erken ve doğru mikrobiyolojik tanı, hastalığın sebebini belirleyerek tedavinin doğru bir şekilde yönlendirilmesine yardımcı olur. Mikrobiyolojik tanı, genellikle bir mikroorganizmanın neden olduğu bir enfeksiyonu belirlemek için kullanılan bir yöntemdir. Bu yöntem, örneğin hastalık belirtilerini

gösteren bir örnekten alınan bir mikroorganizmayı inceleyerek veya vücuttaki bir enfeksiyonu tespit eden bir test uygulayarak gerçekleştirilebilir. Bu yöntem sayesinde, doktorlar enfeksiyonun sebebini belirleyerek doğru tedavi yöntemini seçebilir ve hastanın iyileşme sürecini hızlandırabilir.

Mikrobiyoloji laboratuvarlarında kullanılan hızlı tanı yöntemleri, mikroorganizmaların çeşitli özelliklerini inceleyerek onları tanımlamak için kullanılan yöntemlerdir. Bu yöntemler arasında bakteri kültürü, mikroskopik inceleme, antijen-antikor reaksiyonları ve moleküler biyoloji teknikleri bulunur.

Klinik mikrobiyoloji laboratuvarında, tanı için görüntü yorumlama yöntemi bir mikrobiyolojik inceleme yöntemidir. Bu yöntem, laboratuvarında toplanan örneklerin mikroskop altında incelenmesi ve görüntülerinin yorumlanmasıyla gerçekleştirilir. Örneklerin mikroskop altında incelenmesi sayesinde, laboratuvarındaki çalışanlar mikroorganizmaların büyüklüğünü, şeklini ve özelliklerini gözlemleyebilirler. Bu bilgiler, laboratuvarındaki çalışanların hastalık tanısını yapabilmesine yardımcı olur. Örneğin, bir örnekteki mikroorganizmaların büyüklüğü, şekli ve özellikleri kullanılarak, laboratuvarındaki çalışanlar bir bakteri veya virüsün neden olduğu bir enfeksiyonu tespit edebilirler. Görüntü yorumlama yöntemi, klinik mikrobiyoloji laboratuvarında tanı için önemli bir araçtır. Klinik mikrobiyoloji laboratuvarında örneklerin değerlendirilmesi konusunda geliştirilen otomasyon sistemleri, laboratuvar çalışanlarının daha hızlı ve doğru sonuçlar elde etmelerine yardımcı olur. Bu sistemler, örneklerin işleme ve değerlendirme süreçlerini otomatikleştirerek laboratuvar çalışanlarının zamanını daha verimli kullanmalarına yardımcı olur. Ayrıca, bu sistemlerin görsel bilgileri değerlendirme özelliği sayesinde laboratuvar çalışanları, örneklerdeki mikroorganizmaların boyutlarını, şekillerini ve diğer özelliklerini daha kolay görüntüleyebilir ve değerlendirebilir.

Hastalıklara hızlı tanı koymada fazla sayıda örneğin aynı anda hızlı ve doğru incelenmesi hastalıkların teşhisinde çok önemlidir. Bu amaçları karşılamak içinde üretilen kütle spektrometre sistemleri mikrobiyoloji laboratuvarında mikroorganizmaların tanımlanmasında kullanılan vazgeçilmez teknolojik cihazlardır.

Bir kütle spektrometresi, bir mikrobiyoloji laboratuvarında çeşitli mikroorganizmaların kimyasal bileşimini ve kütlelerini ölçmek için kullanılan bir cihazdır. Bu cihaz,

mikroorganizmaların moleküler ağırlıklarını ve diğer özelliklerini belirlemek için kullanılan bir analiz tekniğidir. Kütle spektrometresi, mikroorganizmaların protein profillerini ölçmek için kullanılabilir. Bu cihaz, mikroorganizmaların proteinlerini ayrıştırır ve bu proteinlerin moleküler ağırlıklarını ölçer. Bu sayede, mikroorganizmaların protein profillerini belirleyebilir ve farklı türler arasındaki farklılıkları gösterebilir. Bu şekilde elde edilen görüntüler kullanılarak veri tabanında bulunan mikroorganizmalar ile karşılaştırılır ve cins bazında etkenler tanımlanır. Hasta sayısının giderek artması mikrobiyoloji laboratuvarlarında otomasyon sistemlerinin kullanımının kaçınılmaz olduğunu ortaya koymuştur. Uzman sistemler alt ünitelerin iç ve dış dolaşım bağlantıları ile sorunsuz çalışmasını sağlar. Sağlık kayıtları (ESK) ve sağlık bilgi değişimi (SBD) ağları bu bağlantılardan bazılarıdır.

Elektronik sağlık kayıtları (ESK), sağlık hizmetlerinin verilmesi sırasında toplanan tüm sağlık bilgilerinin elektronik ortamda saklanmasını ve paylaşılmasını sağlar. Bu bilgiler genellikle hasta geçmişleri, fizik muayene sonuçları, tahliller, tıbbi görüntüler ve ilaç listeleri gibi bilgileri içerir. ESK'ler, sağlık hizmetlerinin verimliliğini ve doğruluğunu artırmaya yardımcı olur. Bunlar, sağlık personelinin hızlı bir şekilde erişebileceği bir veri deposu olarak hizmet verir ve hastaların sağlık durumları hakkında daha iyi bir fikir edinmelerine yardımcı olur. Ayrıca, ESK'ler, sağlık personelinin iş yükünü azaltır ve hata oranını azaltır, böylece sağlık hizmetlerinin verimliliği artar. Yenilikler, ESK teknolojisinin gelişmesine yardımcı olur. Örneğin, artık mobil cihazlar ve tabletler aracılığıyla ESK'ler erişilebilir hale gelmiştir. Bu, sağlık personelinin daha esnek bir şekilde çalışmasına ve daha fazla hastaya ulaşmasına yardımcı olur. Ayrıca, ESK'ler, hastaların kendi sağlık bilgilerine erişimine ve bu bilgileri takip etmeye yardımcı olur. Bu, hastaların kendi sağlıklarını takip etmelerine ve daha aktif bir rol oynayarak sağlıklarını koruma ve iyileştirme fırsatı verir. Genel olarak, elektronik sağlık kayıtları, sağlık hizmetlerinin verimliliğini, doğruluğunu ve erişilebilirliğini artırmaya yardımcı olur. Bu nedenle, ESK'lerin yaygın olarak kullanılması önemlidir.

Sağlık Bilgi Değişimi (SBD), bir sağlık hizmeti sisteminde farklı sağlık kurumları arasında hasta bilgilerinin paylaşılmasını amaçlayan bir çözümdür. Bu sistem, hastaların tedavi süreci boyunca farklı kurumlarda çeşitli sağlık hizmetleri almaları durumunda, bu kurumlar arasında hasta bilgilerinin doğru ve güvenli bir şekilde paylaşılmasını sağlar. Böylece, hastaların tüm sağlık bilgileri bir yerde

toplandığından, hastaların tedavisi sırasında tüm sağlık profesyonellerine erişilebilir ve doğru bir şekilde yönetilebilir.

SBD sistemleri, genellikle bir sağlık veri ağı üzerinden işletilir ve sağlık kurumlarının sistemleri arasında entegre edilir. Bu sayede, hasta bilgileri bir sağlık kurumundan diğerine doğru ve güvenli bir şekilde aktarılabilir. SBD sistemleri aynı zamanda hastaların kendi sağlık bilgilerine erişimine de olanak sağlar, böylece hastalar kendi sağlık durumları hakkında daha fazla bilgi edinebilir ve sağlık profesyonellerine daha iyi bir şekilde iletebilirler. SBD, hasta bilgilerinin doğru ve güvenli bir şekilde paylaşılmasını sağladığından, hasta tedavisinde etkinlik ve verimliliği artırır. Ayrıca, hasta memnuniyetini de artırır çünkü hastaların tüm sağlık bilgilerine erişimlerine olanak sağlar ve tedavi sürecinde daha bilgilendirilirler.

Mikroorganizmalar, çok küçük canlılar olan bakteriler, mantarlar, virüsler ve diğer parazitler gibi mikroskopik canlılardır. Onları tespit etmek için birçok yöntem kullanılabilir, ancak yapay zeka (AI) teknikleri de bu amaçla kullanılabilir. Örneğin, yapay zeka ile mikroorganizma tespiti için birçok çalışma yapılmıştır. Bu çalışmalar genellikle mikroorganizmaların resimlerini içeren veri kümelerini kullanır ve yapay zeka algoritmaları kullanılarak mikroorganizmaların tespiti ve sınıflandırılması yapılır. Bu tespit ve sınıflandırma işlemleri, mikroorganizmaların özelliklerine ve görüntülerine dayanarak yapılır ve yapay zeka algoritmaları bu özellikleri öğrenir ve tespit etmeyi öğrenir. Bu tür yapay zeka sistemleri, mikroorganizmaları tespit etme işlemi için hızlı ve doğru sonuçlar verebilir ve aynı zamanda mikroorganizmaların özelliklerini değerlendirme ve sınıflandırma işlemini de otomatikleştirebilir. Bu sayede, mikroorganizmaların tespiti ve sınıflandırılması işlemleri çok daha hızlı ve doğru bir şekilde yapılabilir ve bu da sağlık sektöründe önemli bir rol oynayabilir. Antimikrobiyal ilaçlar, bakteri, mantar ve virüsler gibi mikroorganizmaları yok etmek veya öldürmek için kullanılan ilaçlardır. İlaç direnci, bir mikroorganizmanın bir ilaça karşı dirençli hale gelmesi anlamına gelir ve bu, ilaçların etkinliğini azaltır veya tamamen ortadan kaldırır. Yapay zeka, antimikrobiyal ilaçlara karşı ilaç direncini sınıflandırmak için çeşitli yöntemler kullanılabilir. Örneğin, yapay zeka, ilaçların kimyasal yapısını ve mikroorganizmaların genetik yapısını inceleyerek, ilaçların ne kadar etkili olacağını tahmin edebilir. Ayrıca, yapay zeka, veri madenciliği yöntemlerini kullanarak, antimikrobiyal ilaçların kullanımı ile ilişkili

verileri toplayarak ve bu verileri analiz ederek, ilaç direnci sınıflandırmaları yapabilir.

Yapay zeka, bulaşıcı hastalıklara neden olan mikroorganizmaları tespit etmek için birçok yöntem kullanılabilir. Bunlardan bazıları şunlardır:

- Örneklerin genetik analizi: Örneklerin genetik yapısı incelenebilir ve bu sayede mikroorganizmaların ne tür olduğu tespit edilebilir. Bu işlem yapay zeka algoritmaları kullanılarak otomatikleştirilebilir.
- Görüntü tanıma: Örneklerin görüntüleri alınabilir ve bu görüntüler yapay zeka algoritmaları kullanılarak otomatik olarak tanımlanabilir. Bu sayede mikroorganizmaların ne tür olduğu anlaşılabilir.
- Semptomların tespiti: Bulaşıcı hastalıklardan etkilenen kişilerin semptomları taranabilir ve bu semptomlar yapay zeka algoritmaları kullanılarak otomatik olarak tanımlanabilir. Bu sayede mikroorganizmaların ne tür olduğu tespit edilebilir.

Bu yöntemlerden hangisinin kullanılacağı, tespit edilmek istenen mikroorganizmanın türüne ve mevcut durumlara göre değişebilir. Yapay zeka, bu yöntemleri kullanarak bulaşıcı hastalıklara neden olan mikroorganizmaları tespit etme işlemini hızlandırabilir ve doğruluğunu arttırabilir.

Bir grup bilim insanı kandaki hemoglobin seviyesini tespit etmek için mikroakışkan çiplerin ve yapay zekâ destekli otomatik mikroskopların kullanıldığı bir teknik geliştirdi.

Yapay zeka destekli otomatik mikroskoplar, geleneksel mikroskopların özelliklerine ek olarak yapay zeka algoritmalarını kullanarak görüntüleri analiz etme ve sınıflandırma yeteneğine sahiptir. Bu, laboratuvarlarda ve sağlık sektöründe mikroskopik incelemeler yaparken zaman ve emek tasarrufu sağlar. Örneğin, yapay zeka destekli otomatik mikroskoplar, belirli hücrelerin sayısını ve tipini tespit etmek için kullanılabilir veya tümör hücrelerini saptamak için kullanılabilir. Yapay zeka destekli otomatik mikroskoplar genellikle geleneksel mikroskopların özelliklerine benzerdir ve aynı şekilde görüntüleri büyütme ve inceleme yeteneğine sahiptir.

Ancak, yapay zeka destekli otomatik mikroskoplar, görüntüleri tarama ve analiz etme yeteneğine sahiptir ve bu, laboratuvarlarda ve sağlık sektöründe mikroskobik incelemeler yaparken büyük bir kolaylık sağlar. Mikroakışkan çip teknolojisi, hemoglobinin moleküllerinin özel bir bileşik ile reaksiyona girmesiyle çalışır. Bu reaksiyon, hemoglobinin moleküllerinin elektrik yüklerini değiştirerek, mikroakışkan çip üzerinde ölçülebilir bir sinyal oluşturur. Bu sinyal, hemoglobinin moleküllerinin sayısını veya konsantrasyonunu ölçmek için kullanılır. Hastalardan alınan kan örneklerinin içinde yer alan hemoglobinler, mikroakışkan çip içerisinde yer alan biyokimyasalla tepkimeye girerek yeşil ışığı soğuran molekül oluşturur. Böylece hemoglobinler yapay zeka destekli otomatik mikroskoplarla görüntülenebiliyor.

7.6. Nöroşirürjide Yapay Zeka ve Gelecek

Sinir biliminin üzerinde çalıştığı önemli konulardan biri öğrenmedir. İnsan beyni anne karnından başlayan ve ömür boyu devam eden bir öğrenme süreci içerisinde. Deneyimler ve duyular ile elde edilen bilgiler beyne bilgi aktaran önemli veri kaynaklarıdır. Beyin bu veri kaynaklarından elde edilen bilgileri süzgecinden geçirip ilgili beyin bölgelerinde kaydetmektedir. İşitme, görme, duyma, tatma, ağrı, ısı gibi pek çok bilgi ilgili beyin bölgelerinde kaydedilmekte ve ihtiyaç duyulduğunda bu bilgilere başvurularak olaylar ve gelişmeler karşısında verilmesi gereken uygun çıktılara dönüştürülmektedir. Yapay zeka alanındaki gelişmeler de beynin bu öğrenme modeline göre gelişmektedir. Bu alanda, yapay zeka modelleri ve algoritmaları kullanılarak beyin gibi düşünen ve öğrenen sistemler tasarlamaya çalışılır[16]. Nöroşirürjide yapay zeka, beyin ve sinir sistemlerinin çalışma şekillerini anlamaya yardımcı olur ve bu bilgileri kullanarak daha iyi bir şekilde öğrenme, hafıza ve düşünme gibi işlevleri yerine getirebilen sistemler tasarlamaya yardımcı olur. Örneğin, nöroşirürjide yapay zeka kullanılarak yüksek performanslı bir sinir ağı tasarlamak mümkündür ve bu ağ, beyin gibi öğrenme ve düşünme işlevlerini yerine getirebilir. Nöroşirürjide yapay zeka ayrıca, beyin ve sinir sistemi ile ilgili sağlık sorunlarının anlaşılmasına ve çözümüne yardımcı olabilir.

Veri birikiminin ve veri işleme gücünün artması ile yapay zeka cerrahi araştırmalarda daha önemli hale gelmiştir. Günümüzde bilim inşaları, “zihin kontrolü” kavramını aydınlatmaya çalışmaktadır. Beyin-bilgisayar arayüzü (BCI), bir sistemdir ve bu

sistem beyin sinyallerini algılar ve bunları bilgisayarın anlayabileceği bir formata dönüştürür. BCI, bir kişinin düşüncelerini direkt olarak bir bilgisayar veya diğer cihazla iletişim kurmasına izin verir. BCI, nörolojik bozuklukları olan kişiler için yardımcı olmak amacıyla kullanılabilir, ancak aynı zamanda sağlıklı bireyler için de birçok farklı amaç için kullanılabilir. Örneğin, bir BCI sistemi kullanılarak bir kişinin düşüncelerini kontrol ederek bir el robotu hareket ettirilebilir veya bir bilgisayar ekranında bir imleç hareket ettirilebilir. BCI teknolojisi hala gelişme aşamasında olmasına rağmen, gelecekte daha fazla uygulama alanı bulunabilecektir.

Yapay zeka (AI) teknolojisi, inme ve serebral vasküler patolojilerin tanısı ve tedavisinde kullanılabilir. Örneğin, yapay zeka sistemleri kullanılarak, inme belirtileri gösteren hastaların MR görüntüleri incelenebilir ve bu görüntüler yardımıyla inme türü ve büyüklüğü tahmin edilebilir. Bunun yanı sıra, yapay zeka sistemleri, serebral vasküler patolojilerin tanısında da kullanılabilir. Örneğin, yapay zeka sistemleri, beyin anjiyogramlarını inceleyerek, anjiyografik olarak tespit edilemeyen serebral vasküler patolojilerin varlığını tespit edebilir.

Travmatik beyin hasarı (TBI) sonucu ortaya çıkan epileptik aktivite otomatik olarak tespit edilebilir. Bu amaçla, yapay zeka ve makine öğrenimi teknikleri kullanılabilir. Örneğin, elektroensefalografi (EEG) verileri kullanılarak yapılan bir çalışmada, yapay sinir ağları kullanılarak TBI sonucu ortaya çıkan epileptik aktivitenin otomatik olarak tespit edilmesi mümkün olmuştur. Bu tür bir sistem, hastaların düzenli olarak EEG verilerinin toplandığı bir ortamda kullanılabilir ve tespit edilen epileptik aktivite hakkında doktorlara bilgi verilebilir. Bu tür yapay zeka sistemlerinin kullanımı, TBI sonucu ortaya çıkan epileptik aktivitenin daha erken tespit edilmesine yardımcı olabilir. Bu, hastaların daha iyi tedavi edilebilmesine ve prognozlarının iyileştirilebilmesine yardımcı olabilir.

Spinal cerrahide de yapay zekâyı kullanmak mümkündür. Spinal cerrahide, yapay zeka sistemleri, cerrahi sırasında kullanılan bilgisayarlı tomografi (BT) görüntülerini ve diğer verileri analiz ederek, cerrahın cerrahi sırasında daha iyi bir görüş sağlamasına yardımcı olabilir. Bu sayede, cerrahın daha doğru ve daha az invaziv cerrahi yöntemleri seçebilmesine yardımcı olabilir. Ayrıca, yapay zeka sistemleri, cerrahi sonrası dönemde hastaların iyileşme sürecini izleyerek, cerrahın hastanın iyileşme durumunu takip etmesine yardımcı olabilir.

Makine öğrenimi ve yapay zekâ, nörolojik yoğun bakım hastalarının bakımında potansiyel olarak yararlı araçlar olabilir. Örneğin, bu teknolojiler kullanılarak hastaların durumlarının izlenmesi ve değerlendirilmesi için sistemler geliştirilebilir. Bu sistemler, hastaların vücut sıcaklığı, kan basıncı, nefes sayısı gibi ölçümleri toplayarak, bu verileri kullanarak hastaların durumunu tahmin etmeye çalışabilir. Ayrıca, makine öğrenimi ve yapay zekâ, nörolojik yoğun bakım hastalarının rehabilitasyon sürecinde de kullanılabilir. Örneğin, yapay zekâ ile geliştirilen sistemler, hastaların terapisi sırasında yaptıkları hareketleri takip ederek, terapötik sürecin etkinliğini değerlendirmeye yardımcı olabilir.

7.7. Oftalmolojide Yapay Zeka

Oftalmoloji, göz sağlığı ve hastalıklarının tanı ve tedavisine yönelik bir tıbbi branştır. Oftalmologlar, gözlerdeki yapı ve fonksiyonları inceleyerek, göz sağlığı ile ilgili birçok farklı sorunu tespit edebilir ve bu sorunları tedavi edebilirler. Örneğin, oftalmologlar gözün yapısını inceleyerek, göz içi tansiyonu ölçebilirler ve glokom (göz içi tansiyonu yüksek olan bir hastalık) gibi durumları tespit edebilirler. Ayrıca, oftalmologlar gözün yapısını inceleyerek, göz kapağı problemlerini, göz bebeğinin şeklini ve göz içindeki damarların durumunu değerlendirebilirler. Oftalmologlar ayrıca, gözün içine bakmak için özel araçlar kullanırlar. Bu araçlar arasında göz içi lambaları, göz içi mikroskopları ve göz içi kamera sistemleri sayılabilir. Bu araçlar sayesinde, oftalmologlar göz içindeki damarları, retinayı (göz içindeki ışık algılayıcı tabaka) ve göz merceğini inceleyebilirler. Oftalmologlar ayrıca, gözlerdeki hastalıkları ve problemleri tedavi etmek için çeşitli yöntemler kullanırlar. Bu yöntemler arasında göz damlaları, göz içine enjekte edilen ilaçlar, göz içine yerleştirilen implantlar ve cerrahi müdahaleler sayılabilir. Oftalmologlar, ayrıca gözlerdeki yapı ve fonksiyonları inceleyerek, gözlük veya lensler gibi görme düzeltici araçları önerebilirler. Bu araçlar, gözlerdeki problemlerin neden olduğu görme bozukluklarını düzeltmek için kullanılır.

Oftalmoloji, sağlık alanında teknolojinin en çok kullanıldığı bölümlerden biridir. Yapay zeka teknolojisi, günümüzde birçok alanda kullanılmaktadır ve oftalmolojide de kullanımı giderek yaygınlaşmaktadır. Özellikle, görme bozukluklarının tanısı, tedavi edilmesi ve prognoz belirlenmesinde yapay zeka sistemleri kullanılabilir.

Örneğin, yapay zeka algoritmaları görme kaybı riskini tahmin etmek için kullanılabilir veya görme kaybını önlemeye yönelik tedavi seçeneklerini belirlemek için kullanılabilir. Ayrıca, yapay zeka algoritmaları göz hastalıklarının erken teşhisinde veya tedavisinde de kullanılabilir. Örneğin, göz hastalıklarının önceden belirlenmiş karakteristiklerine göre sınıflandırılması veya tahmin edilmesi için kullanılabilirler.

Oftalmolojik görüntüleme, gözün yapısını ve işlevlerini inceleyen bir tıbbi uygulamadır. Bu uygulamalar, göz doktorları tarafından kullanılır ve gözlerin sağlığını değerlendirmeye yardımcı olurlar. Yapay zeka, bu tür görüntüleme uygulamalarında kullanılabilir. Örneğin, yapay zeka algoritmaları kullanılarak görüntüler taranabilir ve bu görüntülerdeki anormallikler tespit edilebilir. Bu, göz doktorlarının daha hızlı ve daha doğru sonuçlar elde etmelerine yardımcı olabilir. Ayrıca, yapay zeka algoritmaları kullanılarak görüntüler arasında karşılaştırmalar yapılabilir ve bu sayede gözlerin zaman içindeki değişimlerinin takip edilebilmesi de mümkün hale gelir. Fundus fotoğrafı, göz içi tabakalarının görüntüsünün alındığı bir tür fotoğraftır. Bu fotoğraf, gözün arka bölümünde yer alan retina ve göz bebeği gibi bölümlerin durumunu değerlendirmeye yardımcı olur. Fundus fotoğrafı, göz sağlığı ile ilgili birçok konuda kullanılabilir, ancak en sık kullanım alanı glokom (göz içi basıncı yüksek olan bir hastalık) ve diyabetik retinopati (diyabet ile ilgili göz problemleri) gibi göz hastalıklarının tespiti ve izlenmesindedir. Derin öğrenme, fundus fotoğraflarının analizinde kullanılabilir. Örneğin, bir yapay sinir ağı modeli, fundus fotoğraflarını tarayarak göz sağlığı ile ilgili birçok farklı bilgi toplayabilir. Bu bilgiler, göz sağlığı ile ilgili klinik çalışmalar için kullanılabilir veya göz sağlığı ile ilgili birçok farklı problemi tespit etmek için kullanılabilir. Yapay zeka sistemleri, oftalmolojide kadriyovasküler durumun belirlenmesinde kullanılabilir. Bu durum, göz içindeki kılcal damarların sağlığı ile ilgilidir ve gözün bebeğin beslenmesi, oksijenlenmesi ve atılımının sağlanmasında önemlidir. Özellikle, kadriyovasküler durumun bozulması, göz hastalıklarının gelişimine neden olabilir ve görme kaybına yol açabilir.

8. İlaç Keşfi ve Geliştirilmesinde

Yapay Zeka

8.1. İlaç Keşfinde Yapay Zeka

İlaç keşfi, ilaç geliştirme sürecinin ilk aşamasıdır ve ilaç keşif yolu, bir ilaç molekülünün keşfedilmesinden, üretilmesine, test edilmesine ve sonuçta klinik olarak kullanılabilir hale getirilmesine kadar olan süreçleri kapsar. Bu süreç genellikle uzun zaman alır ve çok sayıda aşama içerir.

İlaç keşif yolu genellikle şöyle işler:

1. İlaç hedefi belirlenir: İlaç keşif yolu, ilaç hedefini belirleyerek başlar. İlaç hedefi, bir hastalık veya sağlık sorunu ile ilişkili olarak çalışılacak bir molekül veya protein olabilir.
2. İlaç adaylarının keşfi: İlaç hedefini belirledikten sonra, ilaç adaylarının keşfi için birçok yöntem kullanılır. Bu yöntemler arasında, doğal kaynaklardan ilaç molekülleri keşfetmek, sentetik yöntemlerle ilaç molekülleri üretmek veya var olan molekülleri değiştirmek gibi seçenekler yer alır.
3. İlaç molekülünün seçimi: Keşfedilen ilaç moleküllerinden en uygun olanı seçilir. Bu seçim, molekülün etkinliği, güvenilirliği ve üretilebilirliği gibi faktörleri dikkate alınarak yapılır.
4. Preklinik testler: Seçilen ilaç molekülü, preklinik testlerde laboratuvar ortamında test edilir. Bu testler, molekülün etkinliğini, güvenilirliğini ve toksik etkilerini değerlendirir.
5. Klinik çalışmalar: Eğer preklinik testlerde başarılı sonuçlar elde edilirse, ilaç molekülü klinik çalışmalara gönderilir. Klinik çalışmalar, ilaç molekülünün insanlarda etkinliğini, güvenilirliğini ve toksik etkilerini test etmek için yapılır.
6. İlaç onayı: Eğer klinik çalışmalarda da başarılı sonuçlar alınırsa yetkili kuruluşlardan onay alınır. Bu onay, bir ilacın pazara sunulması için

gereklidir ve ilaç firmaları tarafından ülkelerin ilaç denetim kuruluşlarına (örneğin, ABD'de FDA) sunulan bir dizi doküman ve veri tarafından desteklenir.

Hayvan modelleri, ilaç araştırması ve geliştirme sürecinde önemli bir araçtır. Bu modeller, ilaçların etkinliğini, güvenliğini ve yan etkilerini değerlendirmeyi mümkün kılar. Özellikle, hayvan modelleri, insanlarda gözlenmeyen etkileri ortaya çıkarma ve ilaçların mekanizmalarını anlama konusunda yardımcı olurlar.

Potansiyel ilaç hedefleri, hayvan modellerinde test edilirken, ilaçların etkinliği ve güvenliği açısından önemli olan birçok faktör değerlendirilir. Bu faktörler arasında, ilaçların hayvanlarda nasıl metabolize edildiği, ilaçların hayvanlardaki farmakokinetik ve farmakodinamik özellikleri, ilaçların hayvanlarda hangi dozlarda etkili olduğu ve ilaçların hayvanlardaki yan etkileri sayılabilir. Hayvan modelleriyle test aşamasında yapay zekânın kullanılması, denemelerin sorunsuz çalışmasına yardımcı olabilir. Yapay zeka teknolojisi, ilaçların hayvan modelinde nasıl etkileşime girdiğini tahmin etmek için kullanılabilir. Örneğin, bir yapay sinir ağı modeli, verilen bir ilacın belirli bir hayvan türünde nasıl etkileşime gireceğini tahmin edebilir. Bu tahminler, ilacın hayvanlarda nasıl etkileşime girdiğini anlamaya yardımcı olabilir ve ilaçların etkinliğini ve güvenliğini değerlendirmeye yardımcı olabilir. Araştırmacılar, prelinik geliştirme aşamasından başarıyla geçtikten ve Amerikan Gıda ve İlaç Dairesi gibi yetkili kuruluşlardan onay aldıktan sonra, ilacı insan katılımcılarla test etmeye başlar. Bu süreç, genel olarak dört aşamalıdır ve üretim yolculuğunun en uzun ve en maliyetli aşaması olarak kabul edilir.

Yapay zeka, ilaç keşfi ve geliştirmede maliyetleri düşürme potansiyeline sahiptir. Örneğin, yapay zeka sistemleri veri taraması ve analizi gibi zaman ve insan gücü gerektiren işlemleri otomatikleştirerek, bu süreçlerin hızını ve doğruluğunu artırabilir. Bu, ilaç keşif ve geliştirme sürecinin hızını artırarak, ilaçların piyasaya sürülmesine yardımcı olabilir.

İlaç geliştirme sürecinde birçok fırsat sunan yapay zeka teknolojilerin kullanıldığı alanlardan biride küçük molekül taşıyan ilaç tasarımıdır. Yapay zekanın altında kalan derin öğrenme modelleri, yüksek derecede otomatikleştirilmiş bir veri öğrenme yöntemidir ve günümüzde birçok alanda kullanılmaktadır. Özellikle, küçük molekül

taşıyan ilaç tasarımında derin öğrenme yöntemleri, moleküler veri setleri üzerinde çalışarak ilaç adayı moleküllerinin özelliklerini tahmin etmeye yardımcı olabilir. Bu, ilaç tasarım sürecinde molekül seçimi ve optimizasyonu aşamasında yararlı olabilir.

Yapay zeka, ilaç keşfinde önemli bir fırsat olarak görülmektedir çünkü ilaçların yeniden konumlandırılarak kullanımının potansiyeli vardır. Bu, ilaçların önceden bilinen bir amaca yönelik olarak kullanıldığı yerde, farklı bir amaç için de kullanılması anlamına gelebilir. Bu süreçte, bileşikler arasında daha önce bildirilmemiş fonksiyonel ilişkileri ortaya çıkarılabilir. Örneğin, bir ilaç önceden bir kalp hastalığı için kullanılmış olsa da, yeniden konumlandırılarak bir farklı hastalık için kullanılabilir. Araştırmacılar, birçok ilaç etkisi gibi çeşitli hücreyel sinyallerin değişimini ölçen transkriptom verilerini kullanarak, bir derin öğrenme yöntemini kullanarak ilaç-hedef etkileşimlerini öngörmek için bir çalışma gerçekleştirmişlerdir. Transkriptom, bir hücrenin RNA üretimini yöneten genlerin aktivitesini ölçen bir moleküler profildir ve ilaçların hücreler üzerindeki etkilerini anlamaya yardımcı olabilir. LINCS (Library of Integrated Network-based Cellular Signatures) veritabanı, bu tür transkriptom verileri için bir kaynaktır ve L1000 veritabanı, LINCS veritabanındaki verilerin bir alt kümesidir. Araştırmacılar, L1000 veritabanındaki transkriptom verilerini kullanarak bir DL modeli oluşturmuş ve bu modeli ilaç-hedef etkileşimlerini öngörmek için kullanmışlardır. Bu çalışma, ilaç araştırmalarında kullanılabilecek bir yöntem olabilir ve ilaçların etkilerinin daha iyi anlaşılmasına yardımcı olabilir. Max Planck Enstitüsü bilim insanları tarafından, bir milimetreden daha küçük boyutlu, hastanın vücut sıvısında yüzecek ve ilaç veya diğer tıbbi yardım sağlamak için kullanılabilecek robotlar üzerinde çalışmalar yapılmaktadır. Tıp tarihinde bir devrim yaratacağı düşünülen bu mikro robotların, insanların kan dolaşımında veya göz kürelerinin yüzeyinde yüzecek şekilde tasarlanacağı belirtilmektedir[17].

AtomNet, bir ilaç keşif yazılımıdır. Bu yazılım, ilaç keşif sürecinde kullanılan moleküler veri kümelerini inceleyerek, potansiyel ilaçların tasarımına yardımcı olur. AtomNet, bir çoklu girdili (multi-input) çoklu çıktılı (multi-output) regresyon modelidir. Bu model, bir molekülün fizikokimyasal özelliklerini tahmin etmek için kullanılır. Örneğin, bir molekülün toksisitesi veya biyolojik aktivitesi gibi özellikleri tahmin etmek için AtomNet kullanılabilir. AtomNet, öncelikle bir molekülün atomları ve bu atomlar arasındaki bağları tanımlayan bir veri seti kullanılarak eğitilir.

Daha sonra, AtomNet modeli bu veri setini kullanarak bir molekülün fizikokimyasal özelliklerini tahmin etmeye çalışır. AtomNet, moleküler veri setlerinde yüksek doğruluk oranlarına sahip olmuştur ve moleküler tasarım gibi uygulamalarda kullanılmıştır. Örneğin, bir molekülün biyolojik aktivitesini tahmin etmek için AtomNet kullanılabilir ve bu bilgi, ilaç geliştirme sürecinde önemli rol oynayabilir. AtomNet, ilaç keşif sürecini hızlandırarak, aynı zamanda ilaç keşif maliyetlerini de azaltabilir. Bu nedenle, AtomNet, ilaç keşif sürecinde önemli bir araç olarak kullanılmaktadır.

Klinik araştırmalar sırasında, birçok ilaç başarısız olur ve üretime alınmaz, bu da genellikle ilaç yanıtını yöneten mekanizmaların tam olarak anlaşılmasından kaynaklanır. Makine öğrenimi teknikleri, ilaç yanıt tahminleri gibi birçok alanda önemli bir rol oynayabilir, ancak çoğu yorumlanabilirlik eksikliği nedeniyle klinik uygulamaya ulaşamamıştır.. Araştırmacılar bu zorlukları aşmak için derin öğrenme modeli olan DrugCell'i geliştirmişlerdir. DrugCell, bir derin öğrenme modelidir. Bu model, bir molekülün belirli bir hedef proteinine etkisini tahmin etmeyi amaçlar. Özellikle, bu model, bir molekülün bir protein üzerindeki etkilerini tahmin etmek için yapısal ve kimyasal özelliklerini kullanır. DrugCell, veri tabanında bulunan binlerce ilaç ve protein verisini kullanarak eğitilir. Bu veriler, bir ilacın bir protein üzerindeki etkisini ölçen çeşitli yöntemlerle toplanır. Örneğin, bir ilacın bir protein üzerindeki etkisini ölçmek için, ilacın proteinin üzerindeki etki mekanizmasını ve proteinin üzerindeki değişiklikleri inceleyebilirsiniz. DrugCell, bu verileri kullanarak bir ilacın bir protein üzerindeki etkisini tahmin etmeye çalışır. DrugCell, kimyasal verilere dayalı bir model olduğu için, moleküllerin yapısal özelliklerini ve birbirleriyle etkileşimlerini anlamaya yardımcı olur. Bu, ilaç tasarımı ve geliştirme süreçlerinde önemli bir rol oynar, çünkü ilaç tasarımı sırasında, moleküllerin belirli hedef proteinlere etkisi önemlidir.

PASS Online (Predictive Activity Spectra for Substances) bir veritabanıdır ve biyolojik aktivite tahmini yapmak için Bayes yaklaşımını kullanır. PASS Online, farmakolojik etkiler, etki mekanizmaları, toksik ve yan etkiler gibi çeşitli biyolojik aktivite türlerini tahmin etmeye yöneliktir. Bu tahminler, maddelerin bilinen farmakolojik özelliklerine dayalıdır ve çeşitli veritabanlarından toplanan verilere dayanır. Bu veritabanları, maddelerin farmakolojik özellikleriyle ilgili bilgileri içeren yayınlar, patentler ve klinik çalışmalar gibi kaynaklardan derlenir.

8.2. İlaç Keşfinde Kullanılan Yapay Zeka Araçları

8.2.1. DeepChem

DeepChem, OpenAI tarafından geliştirilen ve kimyasal verileri işlemeye yönelik bir açık kaynaklı Python kütüphanesidir. Bu kütüphane, kimya alanında çalışan araştırmacılar, bilim adamları ve tasarımcılar için faydalı olabilir. DeepChem, kimyasal verileri işleme, modelleme ve analiz etme gibi görevler için çeşitli yöntemler sunar. Örneğin, DeepChem, moleküler verileri özelleştirilmiş sinir ağları ve diğer derin öğrenme algoritmaları kullanarak işleyebilir. Ayrıca, DeepChem, kimyasal verilerin görselleştirilmesi, önceden eğitilmiş modellerin kullanılması ve veri işleme görevlerini kolaylaştıran diğer özellikler de sunar.

DeepChem, kimya alanında çalışanlar için önemli bir araç olmasına rağmen, bunun dışında da kullanılabilir. Örneğin, farmasötik şirketler, DeepChem kütüphanesini kullanarak ilaç keşif ve tasarımı görevlerinde yardımcı olabilir. Ayrıca, DeepChem, biyomedikal araştırmalarda da kullanılabilir ve biyomedikal verilerin işleme, modelleme ve analizi görevlerinde yardımcı olabilir.

8.2.2. DeepTox

DeepTox, bir veri seti ve öğrenme modelleri topluluğu olarak bilinen bir projedir. Bu projenin amacı, zararlı maddelerin keşfedilmesine yardımcı olmak ve bunların önlenmesine katkıda bulunmaktır. DeepTox projesi, veri setleri ve öğrenme modelleriyle birlikte verilen bir araç olarak tasarlanmıştır. Bu araçlar, kimyasal maddelerin özelliklerini inceleyerek, bu maddelerin zararlı mı yoksa zararsız mı olduğunu tahmin etme yeteneğine sahip olacak şekilde eğitilir.

DeepTox projesi, özellikle toksikolojik araştırmalar ve kimyasal güvenlik çalışmalarında kullanılmak üzere tasarlandı. Bu proje sayesinde, zararlı maddelerin keşfedilmesi ve önlenmesi konusunda etkili bir araç sunulmuş olur. DeepTox projesi, kimyasal maddelerin özelliklerini inceleyen ve bu maddelerin zararlı mı yoksa zararsız mı olduğunu tahmin eden öğrenme modelleriyle birlikte verilir. Bu öğrenme

modelleri, veri setleriyle birlikte eğitilerek, zararlı maddelerin keşfedilmesine ve önlenmesine yardımcı olur.

8.2.3. Deep Neural Net QSAR

Deep neural net qsar, ağırlıklı olarak kimyasal maddelerin etkinliklerini tahmin etmek için kullanılan bir yöntemdir. Bu yöntem, kimyasal maddelerin yapılarını ve etkinliklerini belirleyen faktörleri öğrenmek için derin öğrenme yöntemlerini kullanır.

Deep neural net qsar yöntemi, kimyasal maddelerin yapılarını girdi olarak alır ve bu girdileri işleyen bir derin öğrenme ağı kullanılarak, bu maddelerin etkinliklerini tahmin eder. Örneğin, bir ilaç aşısının etkinliği, aşının içerdiği kimyasal maddelerin yapılarına ve bu maddelerin vücutta etkileşimlerine göre tahmin edilebilir.

8.2.4. Neural Graph Fingerprint

Neural graph fingerprint, bir molekülün özelliklerini tahmin etmek için kullanılan bir yöntemdir. Bu yöntem, molekülün yapısını bir graf olarak gösterir ve bu graf üzerinde bir sinir ağı (neural network) kullanılarak tahminler yapılır. Bu sinir ağı, önceden eğitilmiş bir veri kümesiyle eğitilerek, molekül yapısı girdisi alınarak çıktı olarak molekülün özelliklerini tahmin eder. Bu yöntem, moleküllerin özelliklerini tahmin etmek için kullanılan klasik yöntemlerden daha hızlı ve doğru sonuçlar verebilir.

8.2.5. AlphaFold

AlphaFold, OpenAI tarafından geliştirilen bir yapay zeka modelidir. Bu model, proteinlerin yapısını tahmin etmeye yöneliktir ve bu tahminleri doğrulamak için kullanılan birçok yöntemden daha doğru sonuçlar vermektedir. Proteinler, vücudumuzda çeşitli işlevleri yerine getiren biyomoleküllerdir ve bu işlevlerin çoğu proteinlerin yapısına bağlıdır. Örneğin, bir enzim proteininin bir molekülü parçalaması için belirli bir yapıya sahip olması gerekir. AlphaFold, bu yapıları tahmin etme konusunda çok başarılıdır ve bu sayede bilim adamlarının proteinlerin daha iyi anlaşılmasına yardımcı olur.

AlphaFold'un çalışma prensibi, proteinlerin yapısını tahmin etmek için çok sayıda veri kullanır. Bu veriler, proteinlerin daha önce çözülmüş yapıları ve bunların özellikleri gibi bilgileri içerir. Model, bu verileri kullanarak proteinlerin yapısını tahmin etmeye çalışır. Bu tahminler, proteinlerin yapılarının nasıl oluştuğunu, hangi amino asitlerin birbirlerine nasıl bağlandığını ve bu bağların nasıl dağılım gösterdiğini gösterir.

AlphaFold, proteinlerin yapısını tahmin etmek konusunda çok başarılı olmasının yanı sıra, bu yapıları doğrulamak için kullanılan yöntemlerden daha hızlı ve daha doğru sonuçlar vermektedir. Bu sayede, bilim adamları proteinlerin yapısını daha hızlı çözebilir ve bu sayede proteinlerin nasıl çalıştığını daha iyi anlayabilirler. Bu da, proteinlerin çeşitli işlevlerini yerine getiren moleküllerin nasıl tasarlandığını ve bu moleküllerin nasıl kullanılabileceğini anlamaya yardımcı olur.

8.2.6. Chemputer

Chemputer, bir kimyasal bilgisayar olarak adlandırılan bir cihazdır. Bu cihaz, kimyasal reaksiyonları gerçekleştirmek için tasarlandı ve kontrol etmek için yazılım ve donanım kullanır. Kimyasal bilgisayar, kimyasal maddelerin özelliklerini inceleyen ve kimyasal reaksiyonların tahmini yapılan bir cihazdır. İlaç keşfinde, yeni ilaç moleküllerinin tasarımı ve optimize edilmesi için kullanılabilir. Örneğin, Chemputer, ilaç moleküllerinin özelliklerini inceleyebilir ve ilaç moleküllerinin etkinliğini tahmin edebilir. Bu sayede, ilaç keşfinde yüksek etkinlikte ilaç moleküllerinin tasarımına yardımcı olabilir.

9. Hemşirelik Mesleğinde Yapay Zeka ve Robot Teknolojileri

Hemşirelik, insanların fiziksel, psikolojik ve sosyal ihtiyaçlarını karşılamaya yönelik bir meslektir. Hemşireler, hastaların sağlık durumlarını değerlendirir, ilaç uygulamaları ve müdahalede bulunur. Ayrıca, hemşireler hastaların aileleriyle iletişim kurarak, onlara sağlık bakımı hakkında bilgi verir ve destek sağlar. Hemşirelik, sağlık hizmetleri sektöründe önemli bir rol oynar ve insanların sağlıklı bir yaşam sürdürebilmelerine yardımcı olur.

Yirmi birinci yüzyılda robot teknolojisi ve yapay zeka, hemşirelik uygulamalarını etkileyen önemli gelişmelerdir. Bu teknolojik gelişmelerin hemşirelik uygulamalarına nasıl etki ettiği konusunda farklı görüşler vardır. Bazıları, robotlar ve yapay zeka sistemlerinin hemşirelerin yerine geçebileceğini ve hemşirelerin çalışmalarını azaltabileceğini düşünmektedir[18]. Diğerleri ise bu teknolojik gelişmelerin hemşirelerin verimliliğini artırarak hemşirelerin daha fazla zamanını hastalarla ilgilenmek için kullanabileceklerini savunmaktadır. Yapay zeka teknolojisi ve robotların klinik ortamlarda kullanımı hızla yaygınlaşmaktadır. Özellikle pandemi sürecinde, robotlar ve yapay zeka teknolojisi kliniklerde çeşitli görevleri yerine getirmek için daha fazla kullanılmaya başlandı. Örneğin, yapay zeka ve robotlar ile yüz tanıma sistemleri kullanılarak hastaların izlenmesi ve takibi yapılabilmektedir. Ayrıca, yapay zeka teknolojisi kullanılarak hastaların tedavi süreci ile ilgili tavsiyelerde bulunulabilir ve robotlar ile hastaların yatakta bakımı yapılabilmektedir. Bu teknolojilerin kullanılması, hastaların daha hızlı ve etkili bir şekilde tedavi edilmesine yardımcı olurken, aynı zamanda sağlık çalışanları için de zaman ve emek tasarrufu sağlamaktadır.

9.1. Hemşirelikte Teknoloji

Bilim dünyasındaki hızlı gelişmeler, yeni bilgi ve keşifleri aynı zamanda teknolojik ilerlemeleri de beraberinde getirir ve bu insanların yaşamlarını kolaylaştıran ve geliştiren ürünler ve hizmetlerin ortaya çıkmasına yol açar. Tıbbi teknoloji sektörü, tıbbi cihazlar, ekipmanlar ve sistemlerin üretimi, satışı ve hizmetlerinin yapıldığı bir

sektördür. Bu sektör, tıbbi cihazların ölçüm, görüntüleme, tedavi, araştırma ve diğer tıbbi amaçlar için kullanılmasını sağlar. Sağlık hizmetleri üretiminde son yıllarda görülen teknolojik gelişmeler, hem hasta bireylerin hem de sağlık profesyonellerinin davranışlarını değiştirmeye yardımcı olmaktadır.

Sağlık hizmetleri genellikle ekip çalışması şeklinde yürütülür ve bu ekip çalışması içinde hemşireler ve hekimler gibi farklı sağlık profesyonelleri önemli roller üstlenir. Hemşireler sağlık teknolojisini yoğun biçimde kullanırlar. Sağlık hizmetlerinde teknolojik ilerlemeler, yeni tedavi yöntemlerinin ortaya çıkışı ve sağlık sistemlerinin modernizasyonu gibi faktörler, hemşirelerin rolünü de değiştirir. Çağdaş anlayışa göre, hemşirelerin görevleri çok yönlüdür ve onlar sağlık hizmeti sunmak için çeşitli rolleri üstlenirler. Hemşireler temel bakım vericilerdir ve bu bakımın içeriği, hastanın ihtiyaçlarına göre değişebilir. Hemşireler ayrıca eğitici, araştırmacı, yönetici, karar verici ve savunucu rolleri üstlenebilirler.

Hemşirelik profesyonelleri teknolojinin benimsenmesine katkıda bulunarak sağlık hizmetlerinde değişimin ön saflarında yer almaktadır. Hemşirelik mesleği, teknolojik gelişmelerle birlikte hızla değişmektedir ve hemşirelik profesyonelleri bu değişimleri takip etmek ve uygulamak zorundadır. Hemşirelerin gelişen teknolojinin hemşirelik üzerindeki etkisini değerlendirmesi önemlidir. Hemşireler, sağlık alanında hızlı bir şekilde değişen teknolojinin tüm yeniliklerini takip etmeli ve bu yenilikleri uygulamaya geçirmeyi öğrenmelidirler. Teknolojinin sağlık bakım hizmetlerinde kullanılması, bir takım etik kaygıları da beraberinde getirir. Bu kaygılar arasında, robotların yapacağı hatalardan sorumlu olanın hemşireler olup olmadığı, robotların köleleştirilip köleleştirilmeyeceği, robotların emeğinin karşılığında ücret verilecek olup olmayacağı ve robotlara duygu yüklenebilip yüklenemeyeceği gibi sorular yer alır. Teknolojik gelişmeler hemşirelerin bakım verme sürecini hızlandırmakta ve hastaların daha verimli ve güvenli bir şekilde bakım almalarına yardımcı olmaktadır. Örneğin, elektronik sağlık kayıt sistemleri hemşirelerin hastalarının tıbbi geçmişlerine, ilaç kullanımına ve diğer sağlık bilgilerine daha kolay erişmelerini sağlar. Bu sayede hemşireler daha hızlı ve doğru bir şekilde hastalarına bakım verirler. Tüm mesleklerin, yapay zeka ve diğer teknolojik gelişmelerle birlikte değişeceği ve bu değişimlerle birlikte mesleki uyum sağlamaya çalışacakları doğaldır. Hemşirelik mesleği de bu değişimlerden etkilenecektir ve hemşirelerin yapay zeka ve diğer teknolojik gelişmelerle uyum sağlama zorunluluğu olacaktır.

9.2. Hemşirelik Uygulamalarında Yapay Zeka

Yapay zekâ teknolojisi sağlık endüstrisinde derin bir etki bırakacaktır. Özellikle, yapay zekâ ve makine öğrenimi gibi teknolojiler sağlık hizmetlerinin verimliliğini ve etkinliğini artırmaya yardımcı olacaktır. Yapay zekâ teknolojisinin gelişimi, insanların yerini alabileceği ile ilgili tartışmaların oluşmasına neden olmaktadır. Bu tartışmalar, yapay zekâ teknolojisinin insanlardan daha hızlı ve daha doğru sonuçlar üretebileceği, bazı işlerde insanların yerine kullanılabilmesi ve bazı işlerde bile insanların yerini tamamen alabileceği endişesiyle ilgilidir. Sağlık profesyonelleri, teknolojik gelişmelerin sağlık sektöründe nasıl kullanılabilmesini anlamaya çalışmalıdır. Özellikle yapay zeka ve diğer makine öğrenimi teknolojilerinin sağlık alanında kullanımı, sağlık profesyonellerinin günlük işlerini etkileyebilir. Bu nedenle, sağlık profesyonelleri, bu teknolojilerin nasıl çalıştığını ve hangi durumlarda kullanılabilmesini anlamaya çalışmalıdır. Ayrıca sağlık profesyonelleri bireylerin ihtiyaçlarına, acılarına ve isteklerine odaklanmalıdır. Aksi takdirde yapay zeka ile çalışan makinelerin sağlık personellerinin işlerini daha verimli bir şekilde yapabildikleri kanıtlanırsa, sağlık uzmanları işlerini robotlara devretmek zorunda kalabilir. Yapay zeka (AI) hemşirelik alanında birçok farklı şekilde kullanılabilir. Örneğin, AI sistemleri klinikteki rutin uygulamaları ve tedavi planlarını organize etmek için kullanılabilir. Bunun yanı sıra, AI sistemleri hemşirelerin veri toplamasını ve analiz etmesini kolaylaştırabilir ve hemşirelerin zamandan tasarruf etmelerine yardımcı olabilir. Yapay zekâ sistemleri, veri tabanı oluşturarak, daha hızlı ve daha doğru tıbbi tanı ve tedavi önerileri yapabilirler. Bu, insanların yaptıkları gibi hatalar yapma olasılığını azaltır ve tedavi sürecini daha verimli hale getirir. Robotlar hemşirelikte birçok farklı görevde kullanılabilirler ve verimliliği ve güvenliği artırmak için tasarlanabilirler. Örneğin, robotlar hasta bakımında yardımcı olarak kullanılabilirler. Örneğin, bir robot hemşire hasta odasına giderek vücut sıcaklığını ölçebilir, kan basıncı ölçebilir ve nefes sayısını ölçebilir. Bu veriler toplanıp doktorların ve hemşirelerin anında incelemesine sunulabilir, bu da hasta bakımının daha verimli hale getirilmesine yardımcı olabilir.

Yapay zeka yazılımı ile donatılmış robotlar cerrahların ameliyat sırasında yardımcı olabilir ve hemşirelerin fiziksel olarak iş yükünü azaltabilirler. Örneğin, 'Da Vinci' cerrah kontrollü robot, cerrahın verimliliğini artırmak için kullanılabilir. Bu robot,

insan ellerinin anatomik sınırlamalarını ortadan kaldırarak, cerrahın ameliyat sırasında daha hassas ve doğru hareketler yapmasına yardımcı olur. Böylece, cerrah ve hemşireler ameliyat sırasında daha az zaman harcayabilirler ve daha fazla ameliyat yapabilirler. Xenex robotları ultraviyole (UV) ışık kullanarak mikroorganizmaları öldürür ve böylece sağlık bakım ortamlarında hastane kaynaklı enfeksiyonların yayılmasını azaltmayı amaçlar. Bu tür enfeksiyonlar, hastalık yayılmasını ve hasta bakım maliyetlerini artıran ciddi bir sağlık sorunudur ve Xenex gibi UV ışık kullanan robotlar, bu enfeksiyonların önlenmesine yardımcı olabilir. Robear adlı bir kutup ayısına benzeyen bakım robotu, insanların yatağa veya tekerlekli sandalyeye taşınmasına ve mobilizasyona yardımcı olmak için üretilmiştir. Bu tip robotlar, hareketlerini kısıtlanmış olan yaşlı veya engelli bireyler için özel olarak tasarlanmıştır ve bu kişilerin günlük yaşam aktivitelerini daha kolay hale getirmeyi amaçlamaktadır. Bakım robotları genellikle sensörler ve diğer teknolojik özellikler kullanarak hastaların davranışlarını izleyebilir ve anormallikleri fark edebilir. Bu tip robotlar, hemşireler ve diğer sağlık çalışanlarına veya acil servislere durum hakkında bildirimde bulunur. Bu sayede, hemşireler ve diğer sağlık çalışanları hastaların durumunu daha sık izleyebilir ve gerekiyorsa müdahale edebilir. TUG robotları, sağlık hizmetleri içinde kullanılan otomatik gezinti ve navigasyon sistemlerine sahip robotlardır. Bu robotlar, sağlık tesislerinde ilaçları, laboratuvar numunelerini, hasta örtülerini ve yiyecekleri gibi öğeleri belirlenen varış yerlerine taşımak için kullanılır. TUG robotları genellikle otonom olarak çalışırlar ve bu sayede bir operatöre ihtiyaç duymadan öğeleri taşıyabilirler. Bu robotlar, sağlık hizmetlerinde lojistik işlemleri daha etkin hale getirmeye yardımcı olabilir ve insanların zamanını daha verimli kullanmalarına yardımcı olabilir. SAM adında robotlar, hastanelerde yer alan hasta odalarında belirli aralıklarla girerek hastaların durumlarını takip eden ve sorgulayan robotlardır. Bu robotlar, hastaların vücut sıcaklıklarını, nabız sayılarını, nefes sayılarını ve diğer vücut fonksiyonlarını ölçebilir ve bu verileri bir veri tabanına kaydedebilir. Ayrıca, bu robotlar aynı zamanda hastaların sorunlarını ve ihtiyaçlarını sorgulayabilir ve bu bilgileri doktorlar ve diğer sağlık çalışanlarına iletebilir. Bu sayede, doktorlar ve sağlık çalışanları hastaların durumlarını daha iyi anlayarak daha etkili tedavi planları oluşturabilirler. Cody, Georgia Tech Üniversitesi tarafından geliştirilen bir robot olup, yatağa bağımlı hastaların yatak banyosunun sağlanması ve kıyafetlerinin giydirilmesinde yardımcı olması gibi çeşitli görevler yapmaktadır. Ayrıca, inme yaşayan hastaların

rehabilitasyonunda da etkin bir şekilde kullanılabilir. Bu tip robotlar, hastaların yardımı ihtiyaç duydukları bazı işlemleri yerine getirirken, aynı zamanda hastaların daha rahat ve konforlu bir yaşam sürdürmesine de yardımcı olabilir. RIBA (Robot for Interactive Body Assistance) adı verilen bir hasta robotu, Japonya'da RIKEN tarafından geliştirilen bir robotik sistemdir. Bu robot, yatakta yatan hastaların bakımını ve günlük ihtiyaçlarını karşılamak için tasarlandı. RIBA, kol ve el hareketleriyle hareket ederek hastaların yatakta pozisyonunu değiştirir, yüzlerini yıkar ve yiyeceklerini yedirir. Aynı zamanda, RIBA, hastaların nefes alışverişlerini ve nabzını izleyerek bilgi toplar ve bu bilgiyi hemşirelerle paylaşarak hastaların durumunu izleyebilir. RIBA, yatakta yatan hastaların bakımını kolaylaştırmak ve onların daha iyi bir şekilde iyileşmelerine yardımcı olmak amacıyla tasarlanmıştır. PARO robotları, demans hastalarının ağrı düzeyi ve ruh halini olumlu yönde değiştirmek amacıyla tasarlanmıştır. Bu robotlar, demans hastalarıyla iletişim kurmak için, ses, dokunuş ve görüntüler gibi farklı algıları kullanır. Ayrıca, PARO robotları, hastaların davranışlarını takip eder ve bu bilgilere göre kendi davranışlarını değiştirir. Ayrıca, bu robotlar aynı zamanda demans hastalarının hafızalarını tazelemeye yardımcı olur ve onların öğrenme becerilerini geliştirir. Nao, Aldebaran Robotics tarafından geliştirilen bir humanoid robotdur. Bu robot, dil algılama, ses üretebilme ve hareket etme gibi çeşitli özelliklere sahiptir ve çeşitli görevleri yerine getirme kabiliyetine sahiptir. Nao, insanlarla etkileşim kurmak için tasarlanmıştır, hastalarla sohbet edebilen ve esprileri algılayan bir robottur. RoboCourier, bir teslimat robotu olarak tasarlanmıştır, laboratuvar numuneleri, ilaçlar ve diğer malzemelerin planlı ve isteğe bağlı teslimatlarını otomatik hale getirmek için kullanılabilir. Bu robot, belirli bir teslimat rotası üzerinde hareket ederek, teslimat gereksinimlerini otomatik olarak gerçekleştirir. Bu sayede, laboratuvar numuneleri, ilaçlar ve diğer malzemelerin teslimatlarında zaman ve enerji tasarrufu sağlar ve hata riskini azaltır. Pepper, SoftBank Robotics tarafından geliştirilen bir insansı robottur. Bu robot, çeşitli ortamlarda çevre ve diğer insanlarla etkileşime girebilir ve bir koç, arkadaş veya eğitimci olarak kullanılabilir. Pepper, insanlarla sohbet edebilir, dans edebilir ve oyunlar oynayabilir. Ayrıca, çeşitli işlemleri gerçekleştirebilir ve çeşitli bilgi ve hizmetleri sağlayabilir. İnsansı robotlar, birçok farklı alanda kullanılabilirler, ancak hasta bakımında kullanımı özel olarak düşünülmektedir. Bu robotlar, hastaların ihtiyaçlarını belirlemek ve etkin bir şekilde bakım sunmak için

kullanılabilirler. Bu sayede, hemşirelerin zamanını daha etkin bir şekilde kullanmalarına yardımcı olurlar ve hastaların konforunu ve güvenliğini artırır.

9.3.Yapay Zeka ve Hemşirelik Yönetimi

Sağlık hizmetlerinin etkili ve verimli bir şekilde yönetilmesi, sağlık sistemlerinin etkin bir şekilde işlenmesini ve insanların sağlık ihtiyaçlarının karşılanmasını sağlar. Bunun için, sağlık hizmetlerinin ihtiyaçlarına göre planlanması, yönetiminde etkin bir strateji geliştirilmesi, kaynakların doğru bir şekilde kullanılması ve ölçümleme sistemlerinin kurulması gerekmektedir. Küreselleşme, tüm dünyadaki ülkeler arasında ekonomik, ticari, teknolojik ve kültürel etkileşimin artmasına neden olmuştur. Bu, sağlık hizmetlerinde de etkisini göstermiştir. Özellikle işgücü ve maliyetlerin düşük olması nedeniyle, sağlık hizmetleri sunan ülkeler, düşük maliyetli hemşirelik hizmetleri sunarak rekabet edebilirler. Yapay zekâ teknolojisinin hemşirelik bakım sunumunda kullanımı, hemşirelerin yeni rollerini yalnızca destekleyici değil, aynı zamanda değiştirici de olabilir. Örneğin, yapay zekâ sistemleri hemşirelerin vakalarını takip etmesine yardımcı olabilir, ancak aynı zamanda hemşirelerin vakalarını takip etme görevini tamamen üstlenebilir. Bu durumda, hemşirelerin rolü değişebilir ve daha fazla planlama, yönetim ve koordinasyon gibi görevler üstlenebilirler.

Yapay zeka destekli teknolojiler, hastane yönetiminde önemli bir rol oynayabilirler. Örneğin, yönetici hemşirelere hasta akışını kolaylaştıran sistemler, hemşirelerin zamanını daha etkin kullanmalarına yardımcı olabilirler. Ayrıca, hastanede ne zaman yüksek yatak doluluğu olacağını tahmin eden sistemler, hastane yöneticilerine insan gücü planlama stratejileri oluşturmada yardımcı olabilirler. Bu sayede, hastanenin yüksek yatak doluluğu dönemlerinde yeterli hemşire ve diğer sağlık çalışanlarının bulunmasını sağlayabilirler. Yapay zeka destekli teknolojiler, ayrıca hastane yöneticilerine veri tabanlı karar verme yeteneği sunarak, hastane işletmelerinin verimliliğini artırmaya yardımcı olabilirler. Acil servislerde ve diğer hastane birimlerinde zamana bağlı hasta başvuru sayılarının tahmin edilmesi önemlidir. Bu tahminler, gelecekte beklenen iş yoğunluğunu öngörerek, hastane yönetimi ve çalışanlar için planlama yapılmasına yardımcı olur. Örneğin, hafta sonları ve tatillerde beklenen hasta sayısının yüksek olması durumunda, daha fazla doktor ve

hemşire gerekebilir. Ayrıca, zamana bağlı hasta başvuru sayılarının tahmin edilmesi, acil servislerde ve diğer birimlerde işleyişi optimize etmek için kullanılabilir.

Yapay zeka (AI) teknolojisi, hemşire seçiminde kullanılması mümkün olan bir araçtır. Örneğin, bir hastane veya sağlık kuruluşu, hemşire adaylarının daha önceki performans değerlendirme puanları, eğitim geçmişi ve diğer özelliklerini girdi olarak kullanarak bir hemşire seçim modeli oluşturabilir. Bu model, hemşire adaylarının hangilerinin daha uygun olduğunu tahmin ederek, hemşire seçim sürecini daha verimli hale getirmeyi amaçlayabilir.

Yönetici hemşireler, hemşirelik alanında yapay zeka teknolojisinin kullanımını destekleyebilir ve bu teknolojinin hemşireler tarafından benimsenmesini teşvik edebilirler. Yönetici hemşireler, yapay zekâ teknolojisinin hemşirelik bakımında kullanımını desteklemek ve bu teknolojinin hemşireler tarafından benimsenmesine yardımcı olmak için çeşitli önlemler alabilirler. Bunlar arasında şunlar yer alabilir:

- Yapay zeka teknolojisinin hemşirelik bakımında kullanımının faydalarını anlatmak: Yönetici hemşireler, hemşireleri yapay zekâ teknolojisinin hemşirelik bakımında kullanımının faydaları hakkında bilgilendirerek, bu teknolojinin hemşireler tarafından benimsenmesini sağlayabilirler
- Eğitim programları düzenlemek: Yönetici hemşireler, hemşireler için yapay zekâ teknolojisinin hemşirelik bakımında kullanımı hakkında eğitim programları düzenleyerek, hemşirelerin bu teknolojiyi kullanmayı öğrenmelerine yardımcı olabilirler.
- Örnekler vermek: Yönetici hemşireler, hemşirelerin yapay zekâ teknolojisinin hemşirelik bakımında kullanımına ilişkin örnekler vermek suretiyle, bu teknolojinin nasıl kullanılabileceğini gösterip, hemşirelerin benimsenmesine yardımcı olabilirler.
- Destek olmak: Yönetici hemşireler, hemşirelerin yapay zekâ teknolojisinin hemşirelik bakımında kullanımına ilişkin sorunlarını çözmek için destek olabilirler. Bu sayede, hemşirelerin bu teknolojiyi kullanmaya devam etmelerine yardımcı olabilirler.

Bu gibi önlemler, yapay zeka teknolojisinin hemşirelik bakımında kullanımının hemşireler tarafından benimsenmesine yardımcı olabilir.

10. Tıp Alanında Kullanılan Yapay Zeka Teknolojileri

10.1. Enlitic

Enlitic, bir sađlık teknolojisii Őirketidir ve 6zel olarak radyolojik g6r6nt6leme verileri i7in yapay zeka (AI) tabanlı sistemler geliŐtirir. Bu sistemler, radyoloji g6r6nt6lerindeki anormal bulguları tespit etmeyi ve bu bulguları deđerlendirmeyi hedefleyen AI modellerini kullanır. Bu modeller, radyoloji g6r6nt6lerini tarayan ve anormallikleri tespit eden 6zel yapay sinir ađlarından oluŐur.

Enlitic'in geliŐtirdiđi sistemler, sađlık 7alıŐanlarına radyoloji g6r6nt6lerini deđerlendirme s6recini hızlandırmayı ve dođruluk oranını artırmayı ama7lar. 6zellikle, bu sistemlerin kanser ve diđer ciddi sađlık sorunlarının erken teŐhis edilmesine yardımcı olması beklenmektedir.

Enlitic'in yapay zeka tabanlı sistemleri, radyoloji alanında bir7ok araŐtırma ve makalede ele alınmıŐtır. 6rneđin, bir 7alıŐmada Enlitic'in geliŐtirdiđi bir yapay sinir ađı modelinin, bilgisayar tabanlı radyoloji deđerlendirme sistemlerine g6re daha iyi bir performans g6sterdiđi g6sterilmiŐtir. Bu 7alıŐma, Enlitic'in yapay zeka tabanlı sistemlerinin radyoloji g6r6nt6lerini deđerlendirirken etkin bir Őekilde kullanılabileceđini g6stermiŐtir.

Diđer bir 7alıŐmada ise, Enlitic'in yapay zeka tabanlı sistemlerinin, kalp g6r6nt6lerinde anormallikleri tespit etme konusunda y6ksek bir dođruluk oranı g6sterdiđi bulunmuŐtur. Bu 7alıŐma, Enlitic'in yapay zeka tabanlı sistemlerinin kalp g6r6nt6lerini deđerlendirirken etkin bir Őekilde kullanılabileceđini g6stermiŐtir.

10.2. Butterfly Network

Butterfly Network, bir teknolojik şirket tarafından geliştirilen bir cihazdır. Bu cihaz, insan vücudunda yer alan organları taramak için kullanılır ve bu taramaların sonuçlarını bir bilgisayar ekranında görüntüler. Butterfly Network'ün cihazı, bir ince iğne yardımıyla vücut içine yerleştirilir ve bu iğne üzerinde bir küçük ultra hızlı radyo frekansı (UHF) anteni bulunur. Anten, vücuttaki organları taramak için elektromanyetik dalgalar yayar ve bu dalgalar, organların yapısına göre yansıtılır. Yansımalar, cihaz tarafından alınır ve bilgisayara aktarılır, bu sayede organların görüntüsü oluşturulur. Butterfly Network'ün cihazı, konvansiyonel röntgen ve manyetik rezonans görüntüleme (MRI) gibi yöntemlerden daha hafif, ucuz ve kolay taşınabilir. Ayrıca, konvansiyonel yöntemler gibi radyasyon yaymaz, bu da cihazın güvenliğini artırır. Ancak, Butterfly Network'ün cihazının doğru sonuçlar vermesi için düşük dozlu röntgen yöntemiyle birlikte kullanılması tavsiye edilir. Butterfly Network'ün cihazı, özellikle değişik vücut bölgelerini taramak ve doktorların vücudun iç yapısını anlamaya yardımcı olmak için kullanılır. Örneğin, cihaz kalp, böbrekler, dalak gibi organları taramak ve bu organların işlevlerini değerlendirmek için kullanılabilir. Ayrıca, cihaz, kanser gibi hastalıkların erken teşhisinde de yardımcı olabilir.

10.3. Lunit

Lunit, bir bilgi teknolojisi şirkettir. Şirket, sağlık sektöründe yazılım çözümleri sunmaktadır. Özellikle, radyolojik görüntülerin değerlendirilmesinde kullanılan yazılım araçları geliştirir ve satar. Bu araçlar, doktorların radyolojik görüntüleri daha hızlı ve daha doğru bir şekilde değerlendirmeyi ve bu görüntüleri kullanarak hastalarının durumunu daha iyi anlama ve takip etmeyi kolaylaştırır. Lunit, ayrıca sağlık veri analizi ve machine learning alanlarında da çalışmalar yapmaktadır.

10.4. Arterys

Arterys, sağlık teknolojisi şirketi olarak kardiyovasküler ve onkolojik hastalıkların tanısı ve tedavisinde kullanılan yüksek çözünürlüklü görüntüleme yöntemleri

sunmaktadır. Bu yöntemler, bilgisayar destekli tıbbi görüntüleme (CAD) ve kalp görüntüleme gibi alanlarda kullanılmaktadır.

Arterys, kalp ve damar hastalıklarının tanısı ve tedavisinde kullanılan yüksek çözünürlüklü görüntüleme yöntemlerini geliştirmeye odaklanmıştır. Örneğin, kardiyak MR (magnetik rezonans) görüntüleme yöntemleri kullanarak, kalbin fonksiyonlarını ve yapısını inceleyebilir ve bu bilgileri doktorların kalp hastalıklarının tanısı ve tedavisinde kullanmalarına yardımcı olabilir. Ayrıca, Arterys, onkolojik hastalıkların tanısı ve tedavisinde de kullanılan yüksek çözünürlüklü görüntüleme yöntemlerini de geliştirmektedir. Bu yöntemler, doktorların vücuttaki anormal hücrelerin yerini tespit etmelerine ve bu hücrelerin yayılımını izlemelerine yardımcı olabilir.

Arterys, yüksek çözünürlüklü görüntüleme yöntemlerini klinikler ve hastaneler tarafından kullanılmak üzere sağlık teknolojisi platformları olarak sunmaktadır. Bu platformlar, doktorların bu yöntemleri kolayca erişebilecekleri ve kullanabilecekleri bir ortam sağlar. Bu sayede, doktorlar hastalıkları daha erken tanıyabilir ve daha etkili tedavi yöntemleri geliştirebilirler.

10.5. Caption Health

Caption Health, bir sağlık teknolojisi şirkettir ve konuşma tanıma teknolojisi kullanarak doktorların ve hastaların konuşmalarını anlamaya yardımcı olan bir yazılım geliştirmiştir. Bu yazılım, doktorların ve diğer sağlık çalışanlarının hastaları ile iletişim kurmalarını kolaylaştırmak amacıyla tasarlandı ve kullanımı, hasta raporlarının doğru bir şekilde oluşturulmasını ve hastaların daha iyi anlaşılmasını sağlar.

Caption Health'in ürünleri, FDA tarafından onaylanmıştır ve şirket, hastane ve sağlık merkezleri gibi sağlık kuruluşları tarafından geniş çapta kullanılmaktadır. Özellikle, COVID-19 pandemisi sırasında, Caption Health'in yazılımı, doktorların ve diğer sağlık çalışanlarının maskelerini takarken hastaları anlamalarına yardımcı olmuştur.

10.6. Google DeepMind

Google DeepMind'in sađlık projesi, Google tarafından yuruteden bir alıřma olup, kuresel sađlık sektoruinde teknolojik ilerlemeler yapmayı amalamaktadır. Bu projenin amacı, veri yonetimi, veri guvenliđi ve veri koruma gibi konuları da iine alan birok konuda ilerlemeler yapmak ve sađlık sektoruine yardımcı olmaktır.

Google DeepMind'in sađlık projesi, öncelikle sađlık verilerinin toplanması, depolanması ve kullanılması gibi konulara odaklanmıştır. Bu proje kapsamında, sađlık verileri toplandıktan sonra, bu verilerin anlamlı ve anlaşılır bir şekilde sunulması için çeřitli yöntemler geliştirilmiştir. Google DeepMind'in sađlık projesi aynı zamanda, sađlık verilerinin korunması ve guvenliđi gibi konulara da odaklanmıştır. Bu proje kapsamında, sađlık verilerinin guvenliđi için çeřitli önlemler alınmış ve verilerin korunması için güçlü guvenlik önlemleri geliştirilmiştir.

10.7. Careskore

Careskore, bir kiřinin sađlık durumunu ve sađlık risklerini ölçmek için kullanılan bir skorlama sistemidir. Bu skorlama sistemi genellikle sađlık sigortaları veya bireylerin sađlık durumlarının tahmin edilmesi için kullanılır. Careskore, bir kiřinin sađlık geçmiři, yaşı, cinsiyeti, kilosunu ve benzeri verileri kullanarak bir skor oluşturur. Bu skor, bir kiřinin sađlık risklerinin yüksek veya düşük olduğunu gösterir.

Careskore sistemi, sađlık sigortaları için özellikle yararlı olabilir, çünkü bu sistem, sigortalının gelecekteki sađlık maliyetlerini tahmin etmeye yardımcı olabilir. Bu, sigorta řirketlerine sigortalıların primlerini belirlemeyi kolaylaştırabilir. Aynı zamanda, Careskore sistemi, bir kiřinin sađlık durumunun tahmin edilmesine yardımcı olarak, sađlık hizmetlerine erişimini iyileştirmeye yardımcı olabilir.

10.8. Oncora Medicine

Oncora Medicine, bir sađlık teknolojisi Őirketidir ve tıbbi verileri analiz ederek kanser tedavisinde kullanılmak üzere tavsiyeler ve öneriler sunar. Őirket, tıbbi verilerin yanı sıra makine öğrenimi ve veri bilimi tekniklerini kullanarak hastaların tedavi seçeneklerini deđerlendirir ve tavsiyelerde bulunur.

Oncora Medicine, kanser tedavisinde doktorların ve hastaların karar verme sürecine yardımcı olmak amacıyla tasarlanmıştır. Őirket, tıbbi verilerin analizi sonucunda oluşan tavsiyeler sayesinde doktorların daha dođru ve etkili tedavi seçeneklerini belirlemesine yardımcı olur. Bu sayede, hastalar daha iyi bir tedavi deneyimi yaşayabilir ve tedavi süreçlerinin daha verimli hale getirilmesine yardımcı olunur.

Oncora Medicine ayrıca, kanser tedavisinde kullanılan ilaçların etkinliğini deđerlendirir ve hastaların bu ilaçları kullanırken yaşayabilecekleri yan etkileri tahmin eder. Bu sayede, doktorlar hastaların ilaç kullanımına ilişkin daha dođru tavsiyelerde bulunabilir ve hastaların tedavi süreçleri sırasında daha iyi bir sađlık durumuna sahip olmalarına yardımcı olunur.

10.9. Bay Labs

Bay Labs, bir Sađlık Teknolojisi Őirketidir. Őirket, akıllı telefonlar ve tabletler gibi mobil cihazlar aracılıđıyla kalp atıŐ hızı, nefes alıŐ veriŐ hızı ve göđüs hareketleri gibi vücut sinyallerini ölçen bir mobil uygulama geliŐtirmiŐtir. Bu uygulama, hastaların evlerinde veya doktor muayenehanelerinde kullanılabilir ve doktorların hastaların sađlık durumlarını izlemesine yardımcı olur.

Bay Labs, ayrıca kalp ekokardiyografisi (EKO) gibi kalp çalıŐımını ölçen testleri de geliŐtirmiŐtir. Bu testler, doktorların kalp yetmezliđi, anjina (koroner arter hastalıđı) ve diđer kalp rahatsızlıkları gibi sađlık sorunlarını tanılamasına yardımcı olur.

Bay Labs, sađlık hizmetlerini geliŐtirmeyi amaçlayan bir Őirket olarak, hastaların sađlık durumlarını izlemek için kullanılacak yenilikçi çözümler geliŐtirmeye devam etmektedir. Bu çözümler, hastaların sađlık durumlarını izlemeyi

kolaylařtırarak, doktorların daha etkili bir řekilde tedavi planları oluřturmasına yardımcı olur.

Sonuç

İnsanoğlunun kendine benzeyen varlıklar oluşturmaya ve zekasını taklit etmeye çalışması, yapay zeka teknolojilerinin ortaya çıkışının temel nedenlerinden biridir. Yapay zeka teknolojileri gerçek hayat problemlerinin karmaşıklığını çözmede geleneksel çözüm yöntemlerinin yetersiz kalması nedeniyle önem kazanmıştır. Yapay zeka, sağlık bilimlerinde birçok farklı şekilde kullanılmaktadır.

Bu çalışmada sağlık bilimlerinde yapay zeka kullanımları incelenmiştir. Araştırma ile ortaya çıkan sonuçları aşağıdaki şekilde özetlemek mümkündür:

- Yapay zeka sağlık profesyonellerinin daha hızlı ve doğru kararlar vermelerine yardımcı olabilir ve hastaların takibi ve izleme süreçlerini otomatikleştirerek zaman tasarrufu sağlayabilir. Bu tür sistemlerin kullanımı, sağlık profesyonellerinin daha az yorulmalarına ve hastalara daha fazla zaman ayırmalarına olanak sağlar, böylece daha fazla hastaya hizmet edebilirler.
- Derin öğrenme yöntemleri kullanılarak eğitilmiş yapay zeka modelleri, radyolojik görüntüler, tomografik görüntüler ve benzeri görüntüler üzerinde çok yüksek doğruluk oranları ile tespitler yapabilmektedir. Bu tespitler, doktorların hastalıkları erken teşhis etmelerine ve doğru tedavi yöntemlerini belirlemelerine yardımcı olabilir.
- Yapay zeka ve giyilebilir cihazlar kullanılarak hastaların sağlık durumlarının uzaktan takip edilebilmesi mümkündür. Bu sayede hastaların sağlık durumları daha iyi izlenebilir ve gerektiğinde müdahale edilebilir.
- Yapay zeka teknolojisi, bulaşıcı hastalıklara neden olan mikroorganizmaları tespit etmek için kullanılabilir. Bir hastalığın yayılım hızını ve yayılma yollarını tahmin etmek için doğru veri toplama ve anlama tekniklerinin kullanılması önemlidir. Bu bilgiler, sağlık sistemlerini ve halkı bilgilendirme kampanyalarını düzenlemeye yardımcı olabilir ve pandemilerin etkisini azaltmaya yardımcı olabilir.

- Yapay zeka yöntemleri, ilaç moleküllerinin tasarımı ve özelliklerinin optimize edilmesi için kullanılabilir. Yapay zeka ayrıca, mevcut ilaçların etkinliklerini ve yan etkilerini daha iyi anlamaya yardımcı olabilir.
- Yapa zeka sistemleri hemşirelerin hastalarını takip etmelerine ve sağlık durumlarını izlemelerine yardımcı olabilir. Bunun yanı sıra, yapay zeka sistemleri hemşirelerin sağlık kayıtlarını güncelleştirirken, doktorların ve diğer sağlık çalışanlarının verimliliğini artırır ve yanlış dozaj ve ilaç yönetimi gibi hataları azaltabilir.

Baş döndüren devrim niteliğindeki gelişmelerle gelecekte yapay zeka teknolojisinin hastalık tanı ve tedavisinde çok daha fazla kullanılacağı aşikardır.

Kaynaklar

[1] Yılmaz A, Ölçer İ. Yapay zekanın cerrahi uygulamalar entegrasyonu. Beykent Üniversitesi Fen ve Mühendislik Bilimleri Dergisi 2021; 13(2): 21-27.

[2] Adaş E, Erbay B. Yapay zekâ sosyolojisi üzerine bir değerlendirme. Gaziantep University Journal of Social Sciences 2022; 21(1): 326-337.

[3] Altındış S, Kıran Mİ. Sağlık Hizmetlerinde Büyük Veri. Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 2018;11(2): 257-271.

[4] Akbulut S. Makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak BİST100 endeksi ile emtia, döviz fiyatları ve gelişmekte olan ülkelerin borsa endeksleri arasındaki ilişkinin incelenmesi (yüksek lisans tezi). Aksaray: Aksaray Üniversitesi; 2022. <https://tez.yok.gov.tr>

[5] Akmaz D. Güç kalitesi olaylarının dalgacık dönüşümü, K-En yakın komşu algoritması ve kazanç oranı özellik seçme yöntemi kullanılarak tanınması. International Journal of Innovative Engineering Applications 2022; 6(1): 42-47.

[6] Kuzu BS, Yakut SG. Destek vektör makineleri yardımıyla imalat sanayisinde mali başarısızlık tahminlerinin teknoloji yoğunluğuna göre İncelenmesi. Osmaniye Korkut Ata Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi. 2020; 4(2): 36-54.

[7] Tekin B. (2020). Covid-19 Pandemisi döneminde ülkelerin Covid-19, Sağlık ve finansal göstergeler bağlamında sınıflandırılması: Hiyerarşik kümeleme analizi . Finans Ekonomi ve Sosyal Araştırmalar Dergisi 2020; 5 (2): 336-349.

[8] Yılmaz A. Derin öğrenme, 4. baskı. Kodlab yayın dağıtım yazılım;2022

[9] Arı A, Hanbay D. Bölgesel evrimsel sinir ağları tabanlı MR görüntülerinde tümör tespiti. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi 2019; 34(3): 1395-1408.

[10] Eker AG, Duru N. Medikal görüntü işlemede derin öğrenme uygulamaları. Acta Infologica 2021; 5(2): 459-474.

- [11] Özata M, Aslan Ş. Klinik karar destek sistemleri ve örnek uygulamalar. Kocatepe Tıp Dergisi. 2004; 5(1): 12-17
- [12] Tekindal MA, Tekindal M. Klinik arařtırmalarda yapay zekâ kullanımına aracılık eden SPIRIT-AI protokolünün Türkçeye uyarlaması. Biliřim Teknolojileri Dergisi 2021; 14(4): 445-455.
- [13] Salan A. Nükleer tıpta yapay zeka uygulamaları. Ed.: řahin, A. R. , Doęan, K. Ve Sivri, S. Saęlık bilimlerinde yapay zeka. Akademisyen Kitabevi A.ř;2020.197-204
- [14] Akalın B, Veranyurt Ü. Saęlıkta Dijitalleşme ve yapay zeka. SDÜ Saęlık Yönetimi Dergisi 2020; 2(2): 128-137.
- [15] Uzun T. Yapay zeka ve saęlık uygulamaları. İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 2020; 3(1): 80-92.
- [16] Türk Nöroloji Derneęi. Nörobilim ve Yapay Zeka [internet].Ankara; 2022 [eriřim tarihi 08.12.2022]. <https://www.noroloji.org.tr /menu/189/norobilim-ve-yapay-zeka>
- [17] Hořgör H, Güngördü H. Saęlıkta Yapay Zekanın Kullanım Alanları Üzerine Nitel Bir Arařtırma. Avrupa Bilim ve Teknoloji Dergisi 2022; (35): 395-407.
- [18] řendir M, řimřekoęlu N, Kaya A, Sümer K. Geleceęin Teknolojisinde Hemřirelik. Saęlık Bilimleri Üniversitesi Hemřirelik Dergisi 2019; 1(3): 209-214.