



T.C.

MARMARA ÜNİVERSİTESİ TIP FAKÜLTESİ

BEYİN VE SİNİR CERRAHİSİ ANABİLİM DALI

**YAPAY ZEKÂ ALGORİTMALARI İLE AMELİYAT SIRASINDAKİ
MİKROSKOP GÖRÜNTÜLERİ ÜZERİNDEN DERİN ÖĞRENME TEKNİĞİ
İLE PEDİYATRİK POSTERİOR FOSSA (ARKA ÇUKUR) TÜMÖR
TANIMLAMA YAPILMASI**

Dr. AHMET KARAGÖZ

UZMANLIK TEZİ

İSTANBUL 2024



T.C.

MARMARA ÜNİVERSİTESİ TIP FAKÜLTESİ

BEYİN VE SİNİR CERRAHİSİ ANABİLİM DALI

**YAPAY ZEKÂ ALGORİTMALARI İLE AMELİYAT SIRASINDAKİ
MİKROSKOP GÖRÜNTÜLERİ ÜZERİNDEN DERİN ÖĞRENME TEKNİĞİ
İLE PEDİYATRİK POSTERİOR FOSSA (ARKA ÇUKUR) TÜMÖR
TANIMLAMA YAPILMASI**

Dr. AHMET KARAGÖZ

UZMANLIK TEZİ

Tez Danışmanı: Doç. Dr. MUSTAFA SAKAR

İSTANBUL 2024

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilemeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynak listesine aldığımı, yine bu tezin çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Dr. Ahmet KARAGÖZ

ÖNSÖZ

Sevgili aileme,

Uzmanlık eğitimimi en iyi şekilde almama olanak sağlayan Anabilim Dalı başkanımız Prof. Dr. Mustafa İbrahim Ziyal hocama, Prof. Dr. Adnan Dağçınar, Prof. Dr. Fatih Bayraklı, Prof. Dr. Ferhat Harman, Doç. Dr. Yaşar Bayri, Doç. Dr. Mustafa Sakar, Doç. Dr. Yahya Güvenç hocalarıma ve Uzm. Dr. Fatih Akbulut, Uzm. Dr. Yener Şahin, Uzm. Dr. Onur Erdoğan abilerime, ayrıca asistan arkadaş ve kardeşlerime; servis ve ameliyathane hemşirelerimiz, teknisyenlerimiz ve personellerimize şükranlarımı sunarım.

Tez danışmanlığımı yapan Doç. Dr. Mustafa Sakar'a, ayrıca çalışmayı beraber yürüttüğüm Uzm. Dr. Ertuğrul Pınar, Uzm. Dr. Efekan Çekiç ve Arş. Gör. Merve Pınar'a çok teşekkür ederim.

12.01.2024

Dr. Ahmet KARAGÖZ

İÇİNDEKİLER

TABLO LİSTESİ

Tablo 1: Modelin Mask R-CNN ile Posterior fossa tümör tespitinin hassasiyet, duyarlılık, DICE ve JAK değerleri tablosu.

v

ŞEKİL LİSTESİ

Şekil 1: Makine öğrenmesi ve Derin öğrenmenin ayrımı	4
Şekil 2: Yapay zekâ, Makine öğrenmesi ve Derin öğrenmenin kümesel gösterimi ...	4
Şekil 3: Londra Bilim Müzesi'nde sergilenen Charles Babbage'ın Analitik Makine'si.....	7
Şekil 4: Cezeri'nin otomatik çalışan Su Makinesi.....	8
Şekil 5: Cezeri'nin ünlü Filli Su Saati	8
Şekil 6: Alan Turing'in Bilgisayar Makineleri ve Zekâsı adlı makalesi.....	9
Şekil 7: Prof. Cynthia Breazeal tarafından 2000 yılında tasarlanan 'Kismet' isimli robot.....	16
Şekil 8: Yapay Zekâ Tarihçesi (Türkiye.ai sitesinden alınmıştır)	19
Şekil 9: Ord. Prof. Dr. Cahit Arf'in "Makine Düşünebilir mi ve Nasıl Düşünebilir" çalışmasının aslı Dr. Emir Özgüner'in arşivinden dijital formata dönüştürülmüştür.....	20
Şekil 10: ENIAC (Electronic Numerical Integrator And Computer-Elektronik sayısal entegratör ve hesaplayıcı) elektronik veri işleme kapasitesine sahip ilk bilgisayar. II. Dünya Savaşı esnasında Amerika'da üretilmiştir.....	21
Şekil 11: Makineler ve insanlar arasındaki iş ilişkileri.....	25
Şekil 12: Yapay zekanın nöroşirurji alanındaki uygulamaları.....	31
Şekil 13: Yapay zeka uygulamalarının sağlık alanında kullanımı.....	32
Şekil 14 : Toronto Annotation Suite: AI-Powered Data Annotation ile görüntü etiketleme.....	41
Şekil 15: Mask R-CNN örnek segmentasyonu.....	43
Şekil 16: Modelin orijinal görüntü-1 üzerindeki test sonucu.....	48
Şekil 17: Modelin orijinal görüntü-2 üzerindeki test sonucu.....	48
Şekil 18: Modelin orijinal görüntü-3 üzerindeki test sonucu.....	49
Şekil 19: Modelin orijinal görüntü-4 üzerindeki test sonucu.....	49

SİMGELER ve KISALTMALAR

AAAI: Yapay Zekâ'nın Geliştirilmesi Derneği (Association for the Advancement of Artificial Intelligence)

AGI: Yapay Genel Zekâ (Artificial General Intelligence)

AIBO: Yapay Zekâ Robotu (Artificial Intelligence roBOt)

ALICE: Yapay Dil İnternet Bilgisayar Varlığı (Artificial Linguistic Internet Computer Entity)

ANI: Yapay Dar Zekâ (Artificial Narrow Intelligence)

ANN: Yapay Sinir Ağları (Artificial Neural Network)

AR: Arttırılmış Gerçeklik (Augmented Reality)

ASI: Yapay Süper Zekâ (Artificial Super Intelligence)

AUPR: Hassasiyet-Duyarlılık Eğrisinin Altındaki Alan (Area Under the Precision-Recall Curve)

AUROC: Alıcı İşletme Karakteristiği Eğrisinin Altındaki Alan (Area Under the Receiver Operating Characteristic Curve)

CNN: Evrişimli Sinir Ağı (Convolutional Neural Network)

ELIZA: İnsan-makine konuşma dilini simüle eden bir program

ENIAC: Elektronik Sayısal Entegratör ve Bilgisayar (Electronic Numerical Integrator and Computer)

FFNN: İleri Beslemeli Sinir Ağı (Feedforward Neural Network)

fMRI: Fonksiyonel Manyetik Rezonans Görüntüleme (Functional Magnetic Resonance Imaging)

FPR: Yanlış Pozitif Oran (False Positive Rate)

GPT: Üretken Önceden Eğitimli Dönüştürücü (Generative Pre-trained Transformer)

IBM: Uluslararası İş Makineleri (International Business Machines)

IDH: İsositrat Dehidrogenaz (Isocitrate Dehydrogenase)

LaMDA: Diyalog Uygulamaları için Dil Modeli (Language Model for Dialogue Applications)

LISP: Liste İşleme (List Processing)

LSVRC: Büyük Ölçekli Görsel Tanıma Yarışması (Large Scale Visual Recognition Challenge)

Mask R-CNN: Maske Tabanlı Alan Temelli Evrişimli Sinir Ağı (Mask Region-based Convolutional Neural Network)

MIT: Massachusetts Teknoloji Enstitüsü (Massachusetts Institute of Technology)

NASA: Ulusal Havacılık ve Uzay Dairesi (National Aeronautics and Space Administration)

MSE: Ortalama Kare Hata (Mean Squared Error)

NEIL: Sonsuz Görüntü Öğrenicisi (Never Ending Image Learner)

ROC: Alıcı İşletme Karakteristiği (Receiver Operating Characteristic)

RPA: Robotik Süreç Otomasyonu (Robotic Process Automation)

SVM: Destek Vektör Makineleri (Support Vector Machines)

TPR: Gerçek Pozitif Oran (True Positive Rate)

Yapay Zekâ Algoritmaları ile Ameliyat Sırasındaki Mikroskop Görüntüleri Üzerinden Derin Öğrenme Tekniği ile Pediatrik Posterior Fossa (Arka Çukur) Tümör Tanımlama Yapılması

Öğrencinin Adı: Dr. Ahmet KARAGÖZ

Danışmanı: Doç. Dr. Mustafa SAKAR

Anabilim Dalı: Beyin ve Sinir Cerrahisi ABD.

ÖZET

Amaç: Bu çalışmada; pediatrik posterior fossa (arka çukur) tümörlerinin ameliyat sırasındaki mikroskop görüntüleri alınarak, yapay zekânın derin öğrenme yöntemleri kullanılarak tümörlerin tanınması amaçlanmıştır.

Gereç ve Yöntem: Tarafımızca posterior fossa tümörü tanısı konulmuş hastalardan ameliyat sırasında kaydedilmiş görüntüleri alınacaktır. Bu veriler, hastanın ameliyat sırasında yapılan işlemlerin mikroskop tarafından kaydedilen, Marmara Üniversitesi Pendik Eğitim Araştırma Hastanesi'ndeki arşiv görüntülerinden oluşacaktır. Bu görüntüler yapay zekâ sinir ağı modelini eğitebilmek için farklı türde tümör dokularının bulunduğu görüntülerden oluşacaktır. Veri setlerinin bir kısmı ile öncelikle algoritmanın öğrenmesi sağlanacak, ardından diğer veri setleri ile algoritma test edilecektir. Tümör tespitinde başarılı sonuçlar elde edebilmek için her bir tümör tipi etiketine ait görüntü sayısının dağılımının dengeli bir biçimde yapılması sağlanacaktır.

Görüntülerin Etiketlenmesi: Hastanın mikroskop görüntüleri, tarafımızca etiketlenecek ve makine öğrenmesi aşamasına hazır hale getirilecektir. Etiketler çocukluk çağında en sık görülen posterior fossa tümör tiplerini (medulloblastom, ependimom, pilositik astrositom) içermektedir.

Makine öğrenmesi: Etiketlenen görüntüler kullanılarak model derin öğrenme algoritmaları ile eğitilecek ve doğruluk oranları gözlemlenecektir.

Uzman değerlendirmesi ile karşılaştırma: Yapay zekâ algoritmamızın ortaya koyduğu tahmin sonuçları, uzman beyin cerrahi hekimlerinin birlikte değerlendirmesi ile ortaya konulan verilerle karşılaştırılacak ve doğruluk oranları ortaya konulmaya çalışılacaktır.

Sonuç: Tek tek görüntüler ve geniş ekran üzerinden tümörün normal dokudan ayırt edilmesi ve sınırlarının çizilmesi; normal dokudan oldukça farklı fenotipteki en sık görülen pediyatrik posterior fossa tümörleri olan medulloblastom, ependimom ve pilositik astrositomda tecrübeli beyin cerrahi hekimleri tarafından rahatlıkla yapılabilmektedir. Ancak cerrahi stres altında, mikroskop loop görüşü alanında, tümörün normal dokudan ayırımını yapabilmek özellikle tecrübesiz bir göz için zorlayıcı olabilmektedir. İyi eğitilmiş bir yapa zekâ algoritmaları ile bu tümörlerin normal dokudan ayırt etmesi ve sınırlarının çizilebilmesi yüksek hassasiyet ve özgünlükte yapılabilmektedir.

Anahtar kelimeler: yapay zekâ, derin öğrenme, pediyatri, posterior fossa, medulloblastom, pilositik astrositom, ependimom, cerrahi mikroskop

Pediatric Posterior Fossa Tumor Identification Using Artificial Intelligence Algorithms and Deep Learning Techniques on Intraoperative Microscopic Images

Student's Name: Dr. Ahmet KARAGÖZ

Advisor: Assoc. Prof. Dr. Mustafa SAKAR

Department: Department of Neurosurgery

ABSTRACT

Objective: This study aims to recognize pediatric posterior fossa (back of the skull) tumors during surgery by capturing microscopic images and employing deep learning techniques of artificial intelligence.

Materials and Methods: We will collect intraoperative images from patients diagnosed with a posterior fossa tumor on our side. These data will consist of archived images from procedures recorded by the microscope at the Marmara University Pendik Training and Research Hospital. The images will encompass various tumor tissues to train the artificial neural network model. The algorithm will first learn from a subset of the dataset and then be tested on other datasets. To achieve successful tumor detection, the distribution of the number of images for each tumor type label will be balanced.

Image Labeling: Microscopic images of patients will be labeled by our team, preparing them for the machine learning phase. The labels will include the most commonly encountered posterior fossa tumor types in childhood, such as medulloblastoma, ependymoma, and pilocytic astrocytoma.

Machine Learning: Using the labeled images, the model will be trained with deep learning algorithms, and accuracy rates will be observed.

Comparison with Expert Evaluation: The prediction results generated by our artificial intelligence algorithm will be compared with the data assessed collectively by expert Neurosurgeons, and accuracy rates will be attempted to be determined.

Conclusion: Individually distinguishing and outlining tumors from normal tissue, both through individual images and on a wide screen, can be easily performed by experienced Neurosurgeons in the case of medulloblastoma, ependymoma, and pilocytic astrocytoma, which are the most commonly encountered pediatric posterior fossa tumors with a markedly distinct phenotype from normal tissue. However, under surgical stress, making the distinction between the tumor and normal tissue in the microscope loop view can be challenging, especially for an inexperienced eye. Well-trained artificial intelligence algorithms can achieve this differentiation and delineation of tumor boundaries with high sensitivity and specificity.

Keywords: artificial intelligence, deep learning, pediatrics, posterior fossa, medulloblastoma, pilocytic astrocytoma, ependymoma, surgical microscope

1. GİRİŞ VE AMAÇ

Beyin tümörleri, beynin kendi dokusundan ve çevre dokusundan kaynaklanan tümörleri veya başka bir odaktan sıçrama olan “metastaz” olarak adlandırılan tümörleri içerir. Posterior fossa, kafa arka çukuru olarak bilinir ve denge merkezi “Beyincik” ile hayati merkezleri oluşturan “Beyin Sapı”nın bulunduğu alandır. Çocukluk çağındaki en sık 2. tümör grubu santral sinir sistemi tümörleri olup, bunların en sık yerleştiği yer posterior fossadır. Bu tümörler; iyi veya kötü huylu davranabilmekte olup, genellikle tanı ve tedavi amacıyla cerrahi girişim gerekmektedir. Hastanın tanı sırasındaki radyolojik görüntüleri tümör cinsi, yeri, nöral yapılarla ilişkisi hakkında ön bilgi verebilmekte olup; ameliyat sırasındaki mikroskobik veya makroskobik görüntüler de patolojik ve fiziksel yapısı hakkında fikir verebilmektedir. Ancak kesin tanı patolojik inceleme ile konulabilmektedir. Ameliyat sırasında küçük bir doku parçası dondurularak patolojik olarak incelenebilmekte ve bu inceleme dokunun tümör veya nöral doku olduğu hatta tümörün alt türü hakkında bilgi verebilmektedir. Cerrahi sırasında tümörün türünü öğrenebilmek, özellikle dar bir alanda ve vital merkezlerin yakınında yapılan bir cerrahide, işlem sırasında cerrahların karar almasına önemli ölçüde yardımcı olabilir. Ancak, diğer bir zorluk da tümörün değerli nöral yapılardan ayırt edebilmek ve sınırlarını belirleyebilmektir.

Bu çalışmada; pediatrik posterior fossa tümörü olan hastaların, ameliyat esnasındaki tümörün cerrahi mikroskop görüntüleri kullanılarak, yapay zekâ derin öğrenme yazılımları ile tümörlerin normal dokudan ayırt edilmesi ve sınırlarının çizilmesi amaçlanmıştır. Bu bağlamda, retrospektif ameliyat videolarından elde edilmiş görüntüler tarafımızca yapay zekâ algoritmasına öğretilmek üzere etiketlenecektir. Bu veriler, Pendik Eğitim Araştırma Hastanesi’nde 2019 yılından sonra arşivlenen ameliyat videolarından oluşacaktır. Anonimize hale getirilen etiketlenmiş görüntülerden bir veri seti oluşturulduktan sonra yapay zekâ modeli eğitilecek ve test edilecektir.

Makine öğrenmesi yöntemlerinden derin öğrenme algoritmaları kullanılacaktır. Bu algoritmalar görüntü işleyebilen ve bu görüntüleri tanıyabilen algoritmalarlardır. Algoritmaların iyi sonuç verebilmesi ve tümörleri tanıyabilmesi için

çok sayıda etiketlenmiş verilere ve güçlü bilgisayarlara ihtiyaç vardır. Görüntüler poligonal şekilde etiketlenmiş, böylece tümörün sınırları açısından daha kesin bir sonuç ortaya konulmaya çalışılmıştır. Etiket ismi bütün tümör tipleri için sadece “tumor” olarak belirlenecektir. Sonrasında bu veriler ön işleme tabi tutularak, kullanımına hazır hale getirilip bir model oluşturulacaktır. Test işlemleri sonunda iyileştirmeler bilgisayar mühendisleri ile yapılacak, sonuçlar uzman beyin cerrahlarının işaretlemeleri ile karşılaştırılarak en iyi model oluşturulmaya çalışılacaktır.

2. GENEL BİLGİLER

2.1 Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme nedir?

İnsanlık tarih boyunca her zaman hayatlarını kolaylaştırma, imkanlarını geliştirme arayışında olmuştur. İlk olarak, taş ve tahta el aletleri ile başlayan süreçler; daha sonra çarklı mekanizmalar, buharlı makineler ve elektronik icatlarla devam etmiştir. Bu aşamalarda her zaman sorunları gören, fark eden, çözüm düşünen ve bulan insan aklı olmuştur. Coğrafi ve sosyolojik değişimlerle ihtiyaçlar her zaman katlanarak artmış ve bu durum her dönem insan aklını zorlamıştır. Bu zorluklar makinelerle insanlığın verdiği değeri her geçen yüzyılda arttırmıştır. Önce taştan bakıra, bakırdan çeliğe malzeme seçimleri farklılaşmış; sonra potansiyel enerji, buhar enerjisi, fosil yakıt enerjisi ve elektrik enerjisi gibi enerji seçimleri gelişmiştir. Bu akış da beraberinde her zaman makinelerin iş becerisinde insanı taklit edebilmesi ve insan gibi düşünebilmesi fikirlerini sürüklemiştir. Antik Yunan filozofu Arşimet’in “Taştan ve bakırdan yapılan makineler, işleri insanlardan daha iyi yapabilir mi?” sorusu bu düşüncenin bir örneğidir. Yine antik mit ve efsanelerde de canlı gibi görünen yapay varlık kavramlarından bahsedilmektedir. Antik bilim tarihçisi Adrienne Mayor; “İnsanlar henüz mümkün olmayan şeyleri hayal etme güdüsü duyuyor. Hayal gücü ve bilim arasında zamansız bir bağlantı var.” şeklinde düşüncelerini ifade etmiştir (Mayor, 2018).

Yapay zekâ (Artificial Intelligence-AI) insan zekâsını taklit eden makineleri tanımlayan bir kavramdır. Bu teknoloji, insanların düşünme, problem çözme ve

öğrenme gibi bilişsel yeteneklerini modellemeyi amaçlar. Yapay zekâ, yüz ve konuşma tanıma, karar verme, çeviri gibi insanların yaptığı karmaşık görevleri yerine getirebilmek için tahminleri ve otomasyonu kullanır. Farklı düzeylerde zekâ ve yetenekleri ifade eden 3 kategoriye ayrılır (IBM, 2023):

- Yapay Dar Zekâ (Artificial Narrow Intelligence- ANI): Belirli bir görevi tamamlamak için tasarlanmıştır. ANI'nin yetenekleri kısıtlıdır ve verilen bir görevi yerine getirmesi beklenir. Örneğin; dama oyunu kazanma, nesneleri tanıma veya dili anlama gibi spesifik görevleri yerine getirebilirler. Günümüzdeki sanal asistanlar, robotlar vb. birçok yapay zekâ modeli bu sınıftadır.
- Yapay Genel Zekâ (Artificial General Intelligence- AGI): Güçlü yapay zekâ olarak bilinir ve insan zekâsına ulaşma yeteneği olduğu düşünülür. Şu an için teoride ifade edilmekte olup pratik uygulaması henüz yoktur.
- Yapay Süper Zekâ (Artificial Super Intelligence- ASI): İnsan zekâsının ve becerilerinin ötesine geçebileceği düşünülen zekâ türüdür. Henüz var olmayan bir hedeftir ve olası sonuçları endişe oluşturmaktadır.

Şu anda, dünyada kullanılan yapay zekâ sistemlerinin çoğu ANI kategorisine girer. AGI ve ASI gibi daha güçlü yapay zekâ düzeyleri, hala araştırma ve geliştirme aşamasındadır. Gelecekteki potansiyel uygulamaları ve etkileri üzerinde çalışmalar devam etmektedir.


Yapay zekâ, birçok alt disipline ayrılır, ancak temel olarak şunları içerir (IBM, 2023):

- Makine Öğrenmesi ve Derin Öğrenme
- Doğal Dil İşleme
- Görüntü İşleme
- Otomatik Karar Verme
- Robotik


Makine Öğrenmesi ve Derin Öğrenme

Makine Öğrenimi (Machine Learning), veri kümelerini işleyip; sınıflandırma ve tanımlama yapabilen bilgisayar yazılımlarıdır (N. K. Chauhan and K. Singh). Makine öğrenimi, Arthur Samuel tarafından 1959'da tanımlandığı üzere; bilgisayarların açıkça programlanmadan öğrenme yeteneğidir (Hosch, 2023) (Ron Kohavi, 1998). Yapay zekânın bir alt kümesidir ve tek başına tahmin etmekten kaynaklanan hataları, eski verileri kullanarak en aza indirip daha doğru tahminler yapılmasını sağlamaktadır. Klasik makine öğreniminde ham veri işleme yeteneği kısıtlı olup bir uzman tarafından özelliklerin seçilmesi ve verilerin kümelenmesi gerekmektedir. Veri girişi ile verilerin sınıflandırılmasında insanların müdahale derecesi, çevreyle etkileşim ve geri bildirim alabilme yeteneklerine göre alt gruplara ayrılmaktadır (Hosch, 2023) (Ron Kohavi, 1998).

Derin Öğrenme (Deep Learning), makine öğreniminin bir alt kümesi olup öğrenme yöntemi ve veri kullanma düzeyi açısından farklılaşır. Derin öğrenmede yazılım ham verilerden, insan tarafından özelliklerin belirlenmesine ihtiyaç duymadan otomatik bilgi çıkarabilmekte ve kararlar alabilmektedir. Veri giriş ve çıkış süreci arasında doğrusal olmayan gizli katmanlar modelini kullanır. Yine temel bir ayrım olarak makine öğrenimi önceden kümelenmiş daha kısıtlı bilgi kullanırken; derin öğrenme doğruluğunu arttırmak için daha geniş veriye ihtiyaç duyup, daha karmaşık görevleri yerine getirebilmektedir (Y. LeCun, 2015) (N. Aloysius, 2017)



Şekil 1: Makine öğrenmesi ve Derin öğrenmenin ve ayrımı



Şekil 2: Yapay zekâ, Makine öğrenmesi Derin öğrenmenin kümesel gösterimi

2.2 Yapay Zekâ ve Derin Öğrenme (Deep Learning) Araştırmalarının Tarihçesi

Yapay zekâ düşüncesi, aslında insanların binlerce yıl öncesinden beri yapay varlıklar ve akıllı yaratıklar yaratma isteğinin bir devamıdır. Ancak modern anlamda yapay zekâ konsepti, 20. yüzyılın başlarındaki bilimsel ve teknolojik ilerlemelerle birlikte daha net bir şekil almaya başlamıştır. Yapay zekânın ve akıllı makinelerin tarihi, eski Yunan mitolojilerinden başlamaktadır (Argonautica) (Bibliothèque) (Rhodios, 2007). Akıllı yapay varlıklar ve otonom mekanik aygıtlar o dönem yazılı eserlerinde yer bulmuştur (Kressel, 2015) (Newquist, 1994). Esas olarak, yapay zekâ hakkında ilk çalışma; 1950 yılında Alan Turing'in "Computing Machinery and Intelligence" yazısı olarak kabul edilmektedir. Yine, John McCarthy'nin 1956'daki Dartmouth Konferansı da yapay zekanın temellerini atmada önemli bir adım olmuştur. (McCarthy, 1996)

Yapay zekânın tarihinde, 1950-1975 yılları arasının yapay zekâ için bir "altın çağ" olduğu söylenebilir. Ancak zaman içinde bir duraklama dönemine girilmiştir. Daha sonraki süreçte, özellikle 1980'lerden itibaren ve 1990'ların sonlarına kadar hem teorik hem de pratik açıdan yapay zekâ alanında bir yükseliş yaşanmıştır. Bu artışta medya araçları önemli bir rol oynamıştır. Medyanın etkisiyle yapay zekâ kavramı daha geniş kitlelere ulaşmış ve popüler hale gelmiştir (Newquist, 1994).

Ayrıca, yapay zekâ alanındaki gelişmeler sadece bilgisayar bilimcilerin değil, aynı zamanda istatistikçilerin, mühendislerin, matematikçilerin ve nörobilimcilerin iş birliğiyle mümkün olmuştur. Bu disiplinler arası yaklaşım, yapay zekânın gelişimini hızlandırmıştır.

Yapay zekânın gelişimi, farklı dönemlerde incelenmektedir (Newquist, 1994) (TableauSoftware):

- Yapay Zekâ Alanındaki İlk Çalışmalar
- Yapay Zekâ'nın Doğuşu: 1950-1956
- Yapay Zekâ'nın Olgunlaşması: 1957-1979
- Yapay Zekâ Patlaması: 1980-1987

- Yapay Zekâ Kışı: 1987-1993
- Yapay Zekânın Temsilcileri: 1993 – 2011
- Yapay Genel Zekâ: 2012'den Günümüze


Yapay Zekâ Alanındaki İlk Çalışmalar

17.yüzyılda, Gottfried Wilhelm Leibniz mantığı sembolik olarak temsil etmeyi amaçlayan “mantıksal hesap makinesi” fikrini öne sürdü. Leibniz’in teorisi insan muhakemesini hesaplamalara indirgeyebilmektir. Leibniz, düşünce farklılıklarını çözebilmek için yargıların matematiksel bir şekilde ifade edilmesi gerektiğini savunmuştur.

Ayrıca Leibniz, her düşüncenin bir “gerçek” karakterle ifade edilebileceği bir insan düşünce alfabesi olan “Characterica Universalis”i önerdi. Leibniz, bilgisayar bilimcisi ve enformasyon kuramcısı olarak kabul edilmekte olup, en önemli uğraşı olan ikili rakam sistemini de ortaya koymuştur. Bu hesaplama yöntemi, Turing makinesine de temel taşı olmuştur.

Leibniz’in eserlerinde, sibernetik kuramında merkezi bir role sahip olan geribildirim (feedback) kavramının da bulunduğu iddia edilmiştir (McCorduck, 2004) (Bekir S. Gür, 2005).

Diğer bir tarihsel aktör Charles Babbage, 1830’lu yıllarda “Diferansiyel Analitik Makine” adında bir icat üzerinde çalışmıştır (Swaine, 2023). Bu makine, programlanabilir ilk bilgisayar tasarımına benzemektedir (Şekil 1). Aynı dönem İngiliz şair, matematikçi ve bilgisayar bilimci Ada Lovelace, Charles Babbage’in mekanik bilgisayarını daha önce hiç düşünülmemiş bir şekilde kullanarak; bilgisayar programlamasının temelini atmış ve yaptığı açıklamalarla, bir bilgisayar programı yazan ilk kişi olarak kabul edilmiştir (Menabrea & Lovelace, 2008) (Fuegi & Francis, 2003).



Şekil 3: Londra Bilim Müzesi'nde sergilenen Charles Babbage'ın Analitik Makine'si

İslam bilginlerinden Cezeri, Orta çağ döneminde mekanik makineler tasarlamış ve bunların çalışma prensiplerini açıklamıştır. “The Book of Knowledge of Ingenious Mechanical Devices” adlı eseri yapay zekâ hakkında ilk eserlerden birisi olarak kabul edilmektedir.

İlk hesap makinesinden asırlar önce aynı sistemle çalışan benzer bir mekanizmayı, geliştirdiği saatte kullanan Cezeri; sadece otomatik sistemler kurmakla kalmamış, otomatik olarak çalışan sistemler arasında denge kurmayı da başarmıştı (Hayes, 1983).

Vannevar Bush 1945 yılında “As We May Think” adlı eserinde, insanların kendi bilgi ve kavramalarını genişleten bir sistemden bahsetmiştir. Bilginin depolanması ve erişilmesiyle ilgili yeni fikirler sunmuş; modern bilgi yönetimi, internetin gelişimi ve bilgisayar bilimi konusunda önemli katkısı olmuştur (Wright, 2015).

Bilgisayar bilimcisi Edmund Callis Berkeley, 1949’da yeni bilgisayar modellerini insan beyniyle karşılaştıran “Giant Brains; or, Thinking Machines” adlı kitabını yayınladı. Kitap, gelecekteki potansiyel uygulamaları ve bilgisayarların düşünce kapasiteleri gibi konuları içererek; ilgili sıradan okuyucuya bilgisayar bilimini anlatan popüler bir bilim eseri oldu. Ayrıca Berkeley, ilk kişisel bilgisayar örneği sayılabilecek “Simon” adlı bir cihazı tanıttı (Berkeley, 1955).

Yapay Zekanın Doğuşu: 1950 – 1956

1950’li yıllar, yapay zekâ alanındaki heyecan verici gelişmelerin yaşandığı bir dönemdir. Alan Turing’in “Computing Machinery and Intelligence” adlı makalesi, bilgisayarların düşünme yeteneği konusundaki temel gereklilikleri ortaya koyarak bu alandaki tartışmaları başlattı. Turing’in öne sürdüğü “Turing testi”, bilgisayarın insan gibi davranabilmesi durumunda zekâ kapasitesine sahip olacağını belirtmiştir (Turing, 1950).

VOL. LIX. NO. 236.]

[October, 1950

M I N D
A QUARTERLY REVIEW
OF
PSYCHOLOGY AND PHILOSOPHY

**I.—COMPUTING MACHINERY AND
INTELLIGENCE**
BY A. M. TURING

Şekil 6: Alan Turing’in Bilgisayar Makineleri ve Zekâsı adlı makalesi

1951’de, Christopher Strachey’in dama programı ve Dietrich Prinz’in satranç programı gibi bilgisayar oyunları üzerine yapılan çalışmalar, bilgisayarların stratejik oyunlarda performans sergileyebileceklerini gösterdiler. Bunlar, bilgisayarların sadece matematiksel hesaplamalarla değil, aynı zamanda karmaşık oyun stratejilerini de başarıyla ele alma potansiyeline sahip olduklarını gösteren önemli adımlardan biriydiler.

Arthur Samuel’in 1952’deki çalışması, bilgisayarların oyun oynama yeteneklerini daha da ileri taşıdı. Dama oynayan bir bilgisayar programını geliştiren Samuel, bu programın sadece oyunu oynamakla kalmayıp aynı zamanda oynadıkça kendini geliştirebilecek bir yapay zekâ modeli olduğunu ortaya koydu (Schaeffer, 1997).

1956 yılı, yapay zekâ alanında çığır açan bir dönemdi. John McCarthy, Marvin Minsky, Nathaniel Rochester ve Claude Shannon gibi önemli isimlerin katılımıyla gerçekleşen Dartmouth Konferansı’nda, “yapay zekâ” terimi ilk kez resmi olarak kullanıldı. Bu terim, alandaki çalışmaların genel bir adlandırması haline gelerek, yapay zekâ araştırmalarını daha geniş bir topluluk tarafından takip edilebilir hale getirdi. Konferansın temel amacı, bilgisayar bilimcilerini, matematikçileri ve bilişsel bilimcileri bir araya getirerek, yapay zekâ konusundaki en son gelişmeleri paylaşmak ve bu alandaki çalışmaları koordine etmektir. Konferans; makinelerin öğrenme yetenekleri, dil işleme, mantık yürütme ve problem çözme gibi temel konularda yapılan sunumlar ve tartışmalarla bilim dünyasına yapay zekâ disiplini tanıttı. Dartmouth Konferansı’nın etkileri büyük olmuştur. Yapay zekâ alanında bir ivme yaratmış ve araştırmacıları bu alandaki çalışmalarını derinleştirmeye teşvik etmiştir. (Chatterjee, N.S., & Hussain, 2021) (Skillings, 2008) (Crevier, 1993).

Yapay Zekanın Olgunlaşması: 1957 – 1979

1957 ile 1979 arasındaki dönem, yapay zekâ araştırmalarının çalkantılı ve hızlı bir evrim sürecine sahne oldu. Yapay zekâ teriminin ortaya çıktığı bu zaman dilimi, 1980’lere kadar hem büyüme hem de zorluklarla dolu bir süreci içermekteydi.

1950'lerin sonlarından 1960'lara kadar yaşanan süreç, bir başlangıç ve keşif zamanıydı; yapay zekâ kavramı, o dönemde kullanılan programlama dillerinden robot konseptini araştıran kitap ve filmlere kadar geniş bir yelpazede şekillendi (Russell & Norvig, 2003).

Bu dönemde, John McCarthy'in 1958'de yarattığı ve bugün hala popüler olan "LISP" (List Processing) programlama dili yapay zekâ araştırmalarında önemli bir rol oynadı. Arthur Samuel, 1959'da yaptığı bir konuşmada "Makine öğrenimi" terimini kullanarak bu alandaki kavramları daha da geliştirdi. 1960'lar, sembolik yaklaşımların öne çıktığı bir dönem olarak dikkat çekti ve sembolik mantık ile uzman sistemlerin temelleri atıldı (Edwin, 2003).

Teknolojik gelişmelerle birlikte, 1961'de ilk endüstriyel robot "Unimate"nin kullanılmaya başlanması ve 1965'te Edward Feigenbaum ile Joshua Lederberg'in ilk "Uzman sistemi"ni yaratması, yapay zekânın somut uygulamalarının örnekleridir. Joseph Weizenbaum, 1966'da doğal dil işleme kullanarak ilk sohbet robotu "ELIZA"yı yaratırken, 1968'de Sovyet matematikçi Alexey Ivakhnenko "Grup Veri İşleme Yöntemi"ni yayınladı. Ayrıca, 1974'te Hans Moravec, yüksek derecede akıl yürütmenin az işlem gerektirdiği ancak düşük seviyeli sensorimotor becerilerinin muazzam hesaplama kaynaklarına ihtiyaç duyduğu fikri ile "Moravec Paradoksu"nu ortaya koymuştur. Bu dönem, yapay zekâ araştırmalarının temelini oluşturarak, disiplini daha da derinleştiren ve çeşitli pratik uygulamalara evrilen bir süreç olarak kayda geçmiştir (McCorduck, 2004).

1978'de, orijinal "Battlestar Galactica" bilim kurgu dizisi, savaşçı robotlar olan "Cylon"ları tanıtarak yapay zekâ temasını daha geniş kitlelere ulaştırdı. 1979'da James L. Adams, otonom aracın ilk örneklerinden "The Stanford Cart"ı üretmiştir. Bu otomatik araç, sandalyelerle dolu bir odada insan yönlendirmesi olmadan başarılı bir şekilde gezinebilmiştir. Aynı yıl içinde, yapay zekâ alanındaki gelişmeleri desteklemek amacıyla "Amerikan Yapay Zekâ Derneği" olarak da bilinen "Association for the Advancement of Artificial Intelligence" (AAAI) kuruldu. Bu kuruluş, yapay zekâ alanındaki araştırmaların ve uygulamaların ilerlemesine katkıda bulunmayı amaçlamaktadır. Bu gelişmeler, yapay zekâ teknolojisinin popüler

kültürdeki yansımaları ve disiplinin kurumsal gelişimine yönelik önemli adımları temsil etmektedir (McCorduck, 2004) (Russell & Norvig, 2003).

Yapay Zekâ Patlaması: 1980 – 1987

1980 ile 1987 arasındaki dönem, yapay zekâ alanında yaşanan hızlı büyümeyle dikkat çeken ve “Yapay Zekâ Patlaması” olarak anılan bir zaman dilimini kapsar. Bu dönem hem araştırmalardaki atılımlar hem de hükümet fonlarının artışıyla nam salmıştır. Amerikan Yapay Zekâ Derneği’nin 1980’de düzenlediği ilk ulusal konferans, bu büyümenin bir yansımasıdır (McCorduck, 2004).

Yapay zekâ alanında “Derin Öğrenme Teknikleri” ve “Uzman Sistem” kullanımı bu dönemde öne çıktı. Bu teknikler, bilgisayarların hatalarından ders çıkarmalarına ve bağımsız kararlar almalarına olanak sağlayarak önemli gelişmeleri beraberinde getirdi. 1981’de Japon hükümeti; çeviri, konuşabilme ve anlama yeteneklerini gösterebilecek paralel hesaplama ve mantıksal programlama kullanabilen “Beşinci Nesil Bilgisayar” projesine oldukça yatırım yapmış, yapay zekâ uygulamalarını geliştirebilecek bir platform oluşturmayı amaçlamışlardır. Ancak, 10 yıllık bir proje sonrasında teorik anlamda büyük kazanımların yanında pratikte ticari başarısızlığa uğramıştır (Newquist, 1994) (McCorduck, 2004) (Russell & Norvig, 2003).

Yine 1985’te AAAI konferansında sergilenen sanatçı Harold Cohen tarafından tasarlanan “AARON” isimli otonom bir resim yapabilen bilgisayar programı dikkat çekti. Cohen LISP programlama dilinden de yararlanarak 2016’da ölümüne kadar yazılımı geliştirmeyi sürdürmüştür. 1986’da ise Münih Bundeswehr Üniversitesi’ndeki Ernst Dickmann ve ekibi, engelsiz bir yolda saatte 55 mil gidebilen ilk gerçek anlamda bir sürücüsüz arabayı sergilemiştir (Delcker, 2018).

Yapay zekâ patlaması olarak adlandırılan bu dönem, hem teknolojik yeniliklerin hız kazandığı bir zaman dilimini temsil ederken, hem de yapay zekâ alanındaki araştırmacıları destekleyen bir dönemi simgeler.

Yapay Zekâ Kışı: 1987 – 1993

1987 ile 1993 arasındaki dönem, Amerikan Yapay Zekâ Derneği'nin yapay zekâ alanında bir gerileme olduğu yönündeki uyarısı ile bilinen ve ‘Yapay Zekâ Kışı’nın yaşandığı bir evreyi temsil eder. Bu süre zarfında, yapay zekâ projelerine yönelik mali destek hem özel sektör hem de hükümet düzeyinde kısıtlanmış, genel ilgi ise belirgin bir şekilde azalmıştır (McCorduck, 2004) (Russell & Norvig, 2003) (Crevier, 1993).

Teknolojik açıdan, yapay zekâ sistemleri bu dönemde beklenen başarıya ulaşamamış ve genel halk arasında yüksek beklentilerin karşılanamamasıyla birlikte güven kaybına yol açmıştır. Ayrıca, bu dönemdeki ekonomik belirsizlik ve küresel faktörler, yapay zekâ alanındaki yatırımları olumsuz etkilemiştir. İnsanların yapay zekâ projelerine olan güvenini zayıflatan bu unsurlar, finansmanın azalmasına ve projelerin durdurulmasına neden olmuştur (McCorduck, 2004).

Makine Öğrenme ve Derin Öğrenme Yeniden Canlanması

1990’ların başlarından itibaren, yapay zekâ ve makine öğrenme alanlarındaki gelişmeler, özellikle istatistiksel makine öğrenme alanında önemli bir canlanma yaşadı. Bu dönemde, yeni algoritmalar ve yaklaşımların ortaya çıkmasıyla birlikte, yapay zekâ alanındaki araştırmalara olan ilgi tekrardan önemli ölçüde arttı. Makine öğrenmesi, büyük veri setlerinin işlenmesinde ve karmaşık problemlerin çözülmesinde giderek daha fazla kullanılmaya başlandı (McCorduck, 2004).

‘Destek Vektör Makineleri’ (Support Vector Machines-SVM) ve ‘Karar Ağaçları’ gibi algoritmalar, bu dönemde popülerlik kazandı ve birçok uygulama alanında başarıyla kullanıldı. Özellikle ‘Sınıflandırma’ ve ‘Regresyon’ (değişkenler arasındaki ilişkileri tahmin etmede kullanılan istatistiksel yöntem) problemlerinde etkili olan bu algoritmalar, veri madenciliği ve bilgi çıkarma süreçlerinde önemli bir rol oynadı. Ayrıca, bu dönemdeki teknolojik ilerlemeler ve

bilgi işleme kapasitesindeki artış, daha karmaşık makine öğrenme modellerinin geliştirilmesine olanak tanıdı (Russell & Norvig, 2003).

1990'ların ortalarına doğru, derin öğrenme konsepti daha fazla dikkat çekmeye başladı. Bu, yapay sinir ağlarının daha derin ve karmaşık yapılarının keşfedilmesini de içermekteydi. Derin öğrenme, özellikle büyük veri setlerindeki desenleri tanıma ve karmaşık görevleri gerçekleştirme yeteneği açısından önemli bir ilerleme sağladı. Yapay zekâ alanındaki bu canlanma, bilgisayar bilimcilerini ve araştırmacıları, makine öğrenme ve derin öğrenme alanındaki potansiyelleri daha yakından keşfetmeye yönlendirdi. Otomatik dil işleme, görüntü tanıma, oyun stratejileri ve sağlık sektörü gibi birçok alanda başarı sağlandı. Böylece kısa bir kışın ardından yeni hedef ve heyecanlarla bir yapay zekâ baharına giriş yapıldığı söylenebilir (Baral, Fuentes, & Kreinovich, 2015).

Yapay Zekanın Temsilcileri: 1993 – 2011

Yapay zekâ kışı döneminde finansman eksikliği yaşanmasına rağmen, 1990'ların başlarında yapay zekâ alanında bir dizi çarpıcı gelişme ve ilerleme yaşandı. Bu dönem, bilgisayar bilimi ve teknolojiye öncü çalışmaların bir araya gelerek ortaya koyduğu yenilikleri içeriyordu. Özellikle bu dönemde gerçekleşen dikkat çekici bir adım, dünya şampiyonu satranç oyuncusunu yenebilecek bir yapay zekâ sisteminin tanıtılması oldu (McCorduck, 2004).

1995 yılında, bilgisayar bilimcisi Richard Wallace liderliğindeki bir ekip, Joseph Weizenbaum'ın ELIZA'sından ilham alarak sohbet robotu "ALICE"i (Yapay Dilsel İnternet Bilgisayar Varlığı) geliştirdi. ALICE, kullanıcılarla doğal dilde etkileşime geçebilen ve örneklerden öğrenen bir yapay zekâ örneği olarak ön plana çıktı (Wallace, Roberts, & Beber, 2009). Aynı dönemde, Windows işletim sistemi, Dragon Systems tarafından geliştirilen bir konuşma tanıma yazılımını kullanıcılara sundu; bu da bilgisayarlarla konuşma yeteneğini önemli ölçüde genişletti.

1997 yılı, yapay zekâ alanında bir dönüm noktasıydı. IBM'nin geliştirdiği "Deep Blue" adlı bilgisayar programı, dünya satranç şampiyonu Gary Kasparov'u yenerek yapay zekanın bir insan şampiyonunu mağlup ettiği tarihi bir olaya imza


atmıştır (McCorduck, 2004). Aynı dönemde, Dave Hampton ve Caleb Chung, “Furby” isimli ilk oyuncak robotu tasarlayarak dikkat çekmişlerdir. 1999 yılında ise Sony, Furby ile uyumlu çalışan ve çeşitli sesli komutları anlayabilen robotik evcil köpek “AIBO”yu tanıttı. AIBO, sahipleri ve çevresi ile etkileşime geçebilen, öğrenme yeteneğine sahip bir yapay zekâ örneği olarak dikkat çekti (Wikipedia, 2023).

14

Bu gelişmeler, yapay zekanın stratejik oyunların yanında, aynı zamanda günlük yaşamımızın bir parçası haline gelmeye başladığı bir döneme sürüklüyordu. Yapay zekâ, hızla günlük kullanımda geniş bir yelpazede uygulama alanları bulmaya başlamıştı ve bu da teknolojinin hayatımızın her alanında hiçbir zaman olmadığı kadar çok var olacağının bir işaretiydi. Nitekim daha sonra o günlerin, insanlık tarihinde teknolojik gelişmelerin en yüksek ivmeyle günlük hayata etkili olduğu bir dönemin başlangıcı olduğu görüldü.

Yapay zekânın 2000’li yıllardaki evrimi, bir dizi kritik olay ve önemli gelişmelerle şekillendi. Bu dönemde, yapay zekâ teknolojileri önemli ölçüde gelişerek birçok sektörde çeşitli uygulamalarla karşımıza çıktı.

2000 yılında, Profesör Cynthia Breazeal, MIT’de Kozmik İletişim Laboratuvarı’nda çalışırken, “Kismet” adlı robotu tasarladı. Kismet (İngilizceye türkçeden geçmiş ve eş anlamda kullanılmaktadır), yüz ifadelerini taklit edebilen, gözleri, kaşları, kulakları ve ağzı olan bir robottu. Bu, yapay zekanın duygusal ifadeler ve insanlarla etkileşim yetenekleri üzerine yapılan önemli çalışmalardan birisiydi (Breazeal, 2000).



Şekil 7: Prof. Cynthia Breazeal tarafından 2000 yılında tasarlanan 'Kismet' isimli robot

2002’de iRobot tarafından üretilen “Roomba”, evlerde otomatik süpürge olarak kullanılan ilk ticari robot oldu. Bu cihaz, çevresel sensörler ve temizlik algoritmaları aracılığıyla odalarda dolaşabilir ve zemindeki kirleri temizleyebilirdi. Roomba’nın başarısı, ev robotları ve yapay zekâ kullanımının günlük yaşama entegrasyonunu hızlandırdı.

Yine aynı yıl NASA’nın Mars’a gönderdiği iki kâşif robotu, “Spirit” ve “Opportunity”, kendi başlarına kararlar alabilen ve keşif yapabilen yapay zekâ teknolojilerini barındırıyordu. Bu adım, insansız gezegen keşiflerinde yapay zekânın kullanımının önemli bir temsiliydi.

2006 yılında, büyük teknoloji şirketleri, yapay zekâ algoritmalarını reklamcılık ve kullanıcı deneyimi geliştirmek için kullanmaya başladı. Twitter, Facebook ve Netflix gibi sosyal platformlar, kullanıcı tercihlerini analiz etmek ve kişiselleştirilmiş içerik sunmak amacıyla yapay zekâyı benimsemeye yöneldi.

Yine aynı yıl içinde, bilgisayar bilimcisi Geoffrey Hinton, derin öğrenmenin temelini atan “Deep Neural Network” (Derin Sinir Ağı) kavramını geliştirdi. Bu, yapay zekâ sistemlerinin karmaşık örüntüleri daha etkili bir şekilde öğrenmesini

sağladı ve derin öğrenme alanında bir devrim niteliği taşıdı (Baral, Fuentes, & Kreinovich, 2015).

2010'lu yılların başlarında, Microsoft "Xbox 360 Kinect"i piyasaya sürüldü. Bu, vücut hareketini izleyen ve oyun yönergelerine dönüştüren bir teknolojiydi. Aynı dönemde IBM tarafından geliştirilen "Watson", doğal dil işleme yetenekleri ile programlanmış bir bilgisayar olarak bir çeşit soru cevaplama oyunu "Jeopardy" oyununda zafer elde etti. Apple ise 2011 yılında "Siri" adlı sesli asistanını piyasaya sürerek sesli komutlarla etkileşimde bulunma deneyimini kullanıcılara sundu.

16

Bu dönemdeki gelişmeler, yapay zekânın sadece bir bilim kurgu ögesi olmaktan çıkıp günlük yaşamın ayrılmaz bir parçası haline gelmesini sağladı. Duygusal zekâ, robotik, ev eşyaları ve kişisel asistanlar gibi birçok alanda yapılan çalışmalar, yapay zekânın insan yaşamını daha verimli, etkileşimli ve zengin bir hale getirmesine olanak sağladı.

Yapay Genel Zekâ: 2012'den Günümüze

Yapay zekâ, 2012'den günümüze kadar geçen süreçte çeşitli önemli kilometre taşları ve evrimlerle belirgin bir şekilde ilerledi. 2012'de Alex Krizhevsky, Ilya Sutskever ve Geoff Hinton tarafından geliştirilen "AlexNet" adlı "Evrişimli Sinir Ağı" (CNN-Convolutional Neural Network), görüntü işleme odaklı "Large Scale Visual Recognition Challenge" (LSVRC) yarışmasında büyük bir başarı elde ederek derin öğrenmenin etkinliğini kanıtladı. Aynı yılda, Carnegie Mellon Üniversitesi'nden bir araştırma ekibi, görüntü ilişkilerini karşılaştırabilen ve analiz edebilen semantik bir makine öğrenme sistemi olan "Never Ending Image Learner"ı (NEIL) piyasaya sürdü (LeCun, Bengio, & Hinton, 2015).

Geçen yıllar, yapay zekânın sadece teknik bir algoritma olmaktan öte, günlük hayatın vazgeçilmez bir parçası haline gelmesine şahit oldu. 2014'te Google, sürücüsüz araç teknolojisinin öncüsü oldu ve aynı yıl Amazon'un sanal asistanı "Alexa", evlerimizdeki akıllı cihazlar üzerinden yapay zekâ teknolojisini

benimsememize öncülük etti. 2015'te büyük dil modelleri ve "Rekürren Sinir Ağları" (Recurrent Neural Networks-RNN), doğal dil işleme alanında önemli birer oyuncu haline geldi; bu da insan-makine etkileşimindeki yeni bir dönemi başlattı.

2016'da Hanson Robotics'in tanıttığı insansı robot "Sophia", duygusal ifadelerle iletişim kurma yeteneğiyle dikkat çekti. Aynı yıl Google DeepMind'in "AlphaGo"su, dünya tarihinde bilinen en eski strateji oyunu olan "Go" oynunda dünya şampiyonu Lee Sedol'u mağlup ederek yapay zekanın karmaşık strateji oyunlarında ne kadar ileri gidebileceğini gösterdi. 2018'de Google'ın "BERT" modeli, duygu analizi, soru cevaplama, metin tahmini, metin oluşturma ve özetleme gibi yetenekleri ile dil anlama alanında devrim niteliğinde bir ilerleme sağlayarak doğal dil işlemenin sınırlarını genişletti.


2019'da OpenAI'nin "GPT-2"(Generative Pre-trained Transformer-2) modeli, doğal dil işleme konusunda çığır açarak büyük bir ilgi topladı. 2020'de ise OpenAI'nin "GPT-3" modeli, çok sayıda dil görevini başarıyla gerçekleştirerek yapay zekânın çok boyutlu bir deneyim sunmasını sağladı. 2021 ve sonrasında ortaya çıkan OpenAI'nin "GPT-4" ve Google'ın "LaMDA" modeli gibi gelişmeler, yapay zekânın metin ve görsel girdilerle çok yönlü bir deneyim sunmasını sağlayarak teknolojinin sınırlarını daha da genişletti. Bu süreç, yapay zekânın sadece bilim dünyasında değil, günlük hayatımızın her alanında etkileşimde bulunduğu bir dönemi simgelemektedir.

Bu gelişmelerle birlikte, yapay zekâ sadece dil işleme ve görsel tanıma alanlarında değil, aynı zamanda otonom araçlar, robotlar, sağlık hizmetleri ve daha birçok sektörde de önemli uygulamalar bulmaya başladı. Yapay zekâ, özellikle derin öğrenme ve büyük veri kullanımıyla daha karmaşık görevleri gerçekleştirebilen modellerin ortaya çıkmasını sağladı. 2022'de Stable Diffusion tarafından oluşturulan "Derin Üretici Sinir Ağı" (Deep Generative Neural Network) olarak tanımlanan modeller, bilgisayar grafikleri ve yapay zekâ alanında yeni ufuklar açtı. Bu uygulama, bulut hizmetleri kullanılarak değil, aynı zamanda ortalama bir ev bilgisayarının kendi grafik işleme kapasitesiyle de çalışabilme yeteneği ile dikkat çekti.

Meta şirketi, yapay zekâ modeli “Blenderbot 3”ü tanıtarak sosyal medya ve iletişim platformlarındaki etkileşimleri daha akıcı ve anlamlı hale getirmeyi amaçladı. 2023’e gelindiğinde ise OpenAI, GPT-3 dil modelini tüm dünyanın kullanımına açarak, “ChatGPT” adlı sohbet robotuyla yapay zekânın metin ve görsel girdileri etkili bir şekilde işleyebilen GPT-4 sürümünü piyasaya sürdü. Bu, yapay zekânın çoklu modaliteye (metin ve görüntü) olan hakimiyetini daha da güçlendirdi.

Gelecekte yapay zekâ, daha fazla sektörde daha karmaşık görevleri yerine getirecek, yaşam kalitemizi artıracak ve insanlık için çeşitli sorunlara çözümler sunacaktır. Ancak, bu hızlı gelişimle birlikte, etik, güvenlik ve mahremiyet gibi konularda da dikkatli adımlar atılması gerektiği vurgulanmaktadır.

(IBM, 2023)




Şekil 8: Yapay Zekâ Tarihçesi (Türkiye.ai sitesinden alınmıştır)

Türkiye’de Yapay Zekâ Tarihi

Türkiye’de yapay zekâ tarihi ünlü matematikçi Prof. Dr. Cahit Arf ile başlar. Cahit Arf, 1958–1959 öğretim yılında Atatürk Üniversitesi tarafından düzenlenen “Halk Konferansları” etkinliğiyle yapay zekâ üzerine çalışmalara başladı. Arf’ın bu etkinlikte ele aldığı konu, “Makine Düşünebilir mi ve Nasıl Düşünebilir?” oldu.


Konuşmasının önemli bir kısmını düşünen makinelerin tanımlandığı anlatımlara ayıran Arf, öncelikle II. Dünya Savaşı sonrasında gazete ve radyolarda bahsedilen 3 mucizeden söz eder. Bu mucizeler; atom enerjisinin elde edilmesi, duruma göre karar verip bu kararları uygulayan düşünen makineler (yani elektronik beyinler) ve uzaya fırlatılan suni uydulardır (Arf, 1959).



Şekil 9: Ord. Prof. Dr. Cahit Arf'in "Makine Düşünebilir mi ve Nasıl Düşünebilir?" çalışmasının aslı Dr. Emir Öngüner 'in arşivinden dijital formata dönüştürülmüştür.

Prof. Dr. Cahit Arf'a göre makineler, insan beynine kıyasla belirli görevleri son derece hızlı bir şekilde yerine getirebilirler. Ancak, hafıza kapasiteleri ne kadar büyük olursa olsun, makinelerin anlama ve esneklik konusunda insan beynine göre geride kaldığını belirtir. İnsan beyninin kendi başına gelişebilme özelliği bulunduğunu ifade eder ve mevcut makine tasarımlarının genellikle aynı seviyede kaldığını vurgular. Arf'a göre, kendini kısmen geliştirebilen makineler tasarlamak mümkündür. Ancak asıl fark, insan beyninin estetik etkileri anlama, estetik kararlar alma ve bir işi yapma veya yapmama konusunda özgür hissetme yeteneğine sahip olmasıdır. Bu tür yeteneklerin genellikle makinelerde bulunmadığını belirtir ve geliştirilmesinin çok zaman alabileceğini hatta hiç var olmayabileceğini belirtir (Arf, 1959).

Arf, bilgisayarların çalışma mantığını anlatarak o dönemde piyasaya yeni sürülen ilk bilgisayar “ENIAC”tan bahseder ve makine teknolojisinin anlaşılabilirliğinin akıl ve sabır gerektirdiğine vurgu yapar.



Şekil 50: ENIAC (Electronic Numerical Integrator And Computer-Elektronik sayısal entegratör ve hesaplayıcı) elektronik veri işleme kapasitesine sahip ilk bilgisayardır. II. Dünya Savaşı esnasında Amerika’da üretilmiştir (Russell & Norvig, 2003).

Arf, davranışçılık düşüncesini benimseyerek, makinelere etki ve tepki yeteneklerini atfeder. Arf’ın sunduğu alternatif senaryolar, makinenin tepki yeteneklerini çeşitlendirmeyi amaçlar. Örneğin, bir çalar saate kendi dilimizle saat dörtte bizi uyandırmasını söylediğimizde, makine bu talebi anlar ve belirlenen saatte çalar. Eğer makine belirlenen saatte bizi uyanık göremezse alternatif bir çözüm geliştirerek başımıza su dökerek bizi uyandırabilir. Arf’ın örnekleri, makinenin çeşitli etkileşimlere tepki verme yeteneği ve dil kullanımını tartışarak, insan benzeri davranışların makinelerle nasıl başarıyla simüle edilebileceğini anlatır (Arf, 1959).

Daha sonraki dönemlerde de yapay zekâ teknolojisinin gelişimi, Türkiye’de de hızla ilerlemekte ve birçok sektörde önemli değişimlere öncülük etmektedir. Ülkede yapay zekâ alanındaki çalışmalar, akademik kurumlar, özel sektör şirketleri

ve devlet destekli projeler aracılığıyla büyük bir ivme kazanmıştır. Özellikle üniversitelerdeki araştırma merkezleri ve laboratuvarlarla yapay zekâ konusunda önemli bir altyapı oluşturmuştur. Bu kurumlar, derin öğrenme, doğal dil işleme, görüntü işleme ve robotik gibi çeşitli yapay zekâ alanlarında önemli çalışmalar yürütmekte ve uluslararası alanda dikkat çekmektedir.

Özellikle sağlık, finans, ulaşım ve güvenlik gibi sektörlerde yapay zekâ uygulamaları Türkiye’de hızla yaygınlaşmaktadır. Sağlık sektöründe, hastalıkların teşhisi, tedavi planlamaları ve hasta takibi gibi birçok alanda yapay zekâ teknolojilerinden faydalanılmaktadır. Finans sektöründe ise sahtecilik tespiti, müşteri hizmetleri ve risk yönetimi gibi konularda yapay zekâ sistemleri kullanılmaktadır.

21

Türkiye’nin yapay zekâ alanındaki bu hızlı ilerleyişi, özellikle devlet destekli projelerle daha da desteklenmektedir. Yapay zekâ strateji ve eylem planları, bu alandaki yetenekleri artırmaya yönelik politikaların belirlenmesinde etkili olmaktadır. Ayrıca, özel sektördeki firmaların yapay zekâ tabanlı çözümlere yatırım yapması ve bu teknolojileri iş süreçlerine entegre etmesi, Türkiye’nin dijital dönüşümünde önemli bir rol oynamaktadır.

2.3 Yapay Zekâ Uygulamaları ve Özellikleri

Yapay Zekânın Günlük Hayatta Kullanımı

Teknolojik gelişmelerin ivme kazandığı 1990’lı yıllardan itibaren, yapay zekâ alanındaki ilerlemeler hayatımızı temelde değiştirmiştir. Başlangıçta bilim kurgu gibi görünen yapay zekâ, artık günlük yaşamımızın vazgeçilmez bir parçası haline gelmiştir. Gerçek nöronları taklit eden sinir ağları ve makine öğrenimi sayesinde, makineler karmaşık verileri işleyip doğru bilgiler sunabilir hale gelmiştir. Bu teknolojik evrimin en çarpıcı yansımalarından biri otonom araçlar konusunda görülmektedir. Yapılan araştırmalara göre, otonom araçlar sayesinde kaza oranları önemli ölçüde azalmış ve özellikle alkol ve uyuşturucu kaynaklı kazaların sayısında

belirgin bir düşüş yaşanmıştır (Tomáš Zavodjančík, 2021). Sürücü güvenliği açısından önemli bir kilometre taşı olan otonom araçlar, insan hatalarını en aza indirerek trafik güvenliğini artırmıştır. Yapay zekâ tarafından geliştirilen robotlar, tehlikeli işlerde insanların yerine geçerek bomba imha gibi riskli görevleri üstlenmiş ve binlerce yaşamın kurtarılmasına yardımcı olmuştur. İnsan sağlığını tehlikeye atan veya aşırı risk içeren işlerde kullanımı, insan hayatını koruma amacını güçlendirmiştir.

Bilgisayarlı yöntemlerdeki gelişmeler, günlük hayattaki etkileşimlerimizi kökten değiştirmiştir. GPS uygulamaları, akıllı telefon teknolojisi ve yazım denetimi gibi yapay zekâ tabanlı sistemler, hata oranını minimize ederek zaman tasarrufu sağlamış ve günlük aktiviteleri daha verimli hale getirmiştir. Bu, kullanıcıların daha hızlı ve daha etkili bir şekilde bilgiye ulaşmalarını sağlayarak yaşam kalitesini artırmıştır. Bankacılık sektöründen tıp araştırmalarına kadar birçok alanda kullanılması, veri analizi ve doğru bilgi yönetimi konusunda önemli bir rol oynamaktadır (Lee, 2020).

Yapay zekâ gerekli insan iş gücünün azaltılması ve iş verimliliğinin artırılması konusunda büyük avantajlar sağlamıştır. Üretim sektöründe, makinelerin sürekli çalışma kapasitesi ve tekrarlayan görevlerin otomatize edilmesi, iş süreçlerini hızlandırmış ve kaliteyi artırmıştır. Bu teknolojik devrim, insanların günlük yaşamını ve iş dünyasını daha etkili bir şekilde yönetmelerine olanak tanımıştır (Lee, 2020).

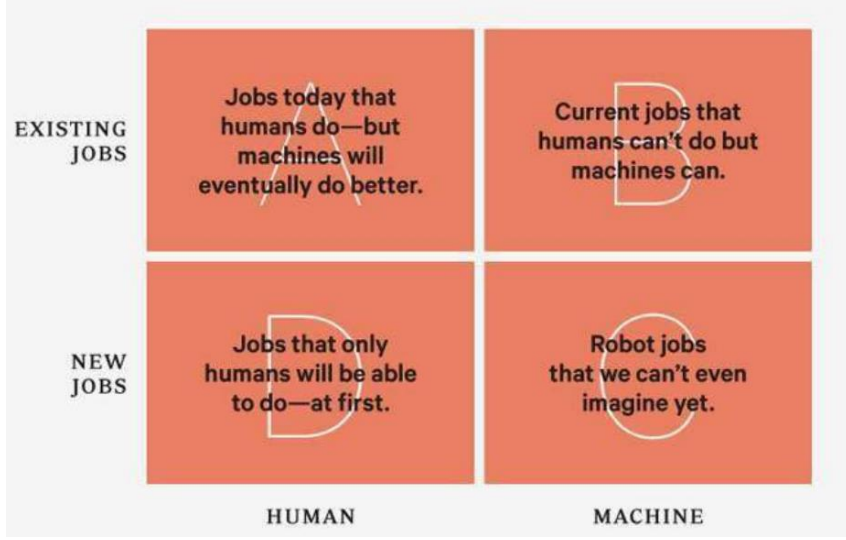
Özellikle zamanın çokça kıymet taşıdığı günümüz dünyasında zaman tasarrufu sağlama konusunda da önemli bir role sahiptir. Yapay zekâ, birçok görevi eş zamanlı ve hızlı bir şekilde yerine getirebilme yeteneğiyle veri analizi ve çözüm üretme konusundaki hızı, insanlara kıyasla oldukça etkileyicidir. Eğitim alanında, yapay zekâ destekli öğrenme platformları bireysel öğrenci ihtiyaçlarına göre özelleştirilmiş eğitim sağlayarak öğrenme deneyimini zenginleştirmekte ve öğrencilerin daha etkili bir şekilde bilgi edinmelerine yardımcı olmaktadır. Bu, öğrencilerin kendi tempolarında öğrenmelerine ve güçlü yönlerini fark etmelerine olanak tanırken, zayıf yönlerini güçlendirmelerine de yardımcı olabilmektedir.

Sanayi ve üretim sektörlerinde, üretim süreçlerini daha verimli hale getirerek maliyetleri düşürüp ve kaliteyi artırabilmektedir. Sosyal medya ve dijital

platformlarda kullanımı, kullanıcı deneyimini kişiselleştirebilme yeteneği sayesinde büyük bir önem kazanmıştır. Örneğin, yapay zekâ tarafından desteklenen öneri algoritmaları, kullanıcılara ilgi alanlarına uygun içerikleri sunarak daha etkili bir kullanıcı deneyimi sağlamaktadır. Bu, dijital içerik üreticileri için izleyici kitlesini genişletme ve içeriklerini daha hedeflenmiş bir şekilde sunma fırsatları yaratmaktadır.

Yapay zekâ tabanlı dil çeviri araçları, kültürler arası iletişimi kolaylaştırarak dünya genelinde bilgi ve deneyim paylaşımını artırmıştır. Finans sektöründe ise, algoritmalar risk analizi yapabilmekte, dolandırıcılığı önleyebilmekte ve portföy yönetimini optimize edebilmektedir. Aynı zamanda sanat ve yaratıcılık alanlarında da etkisini göstermektedir. Müzik, resim, edebiyat ve film gibi sanatsal ifadelerde, yapay zekânın yaratıcılığı destekleyen ve yeni perspektifler sunan uygulamaları ortaya çıkmaktadır. Örneğin, yapay zekâ tarafından oluşturulan müzik eserleri, resimler ve yazılar, geleneksel sanat anlayışını zenginleştirerek yeni sanat formlarının ortaya çıkmasına neden olmaktadır.

Ancak, tüm bu olumlu etkilerin yanında beraberinde getirdiği bazı zorluklar ve endişeler de bulunmaktadır. Özellikle güvenlik, etik sorunları, işsizlik riski ve özel hayatın gizliliği gibi konular, yapay zekânın ilerlemesini izleyenler arasında önemli birer tartışma konusu haline gelmiştir. Bu nedenle, yapay zekâ teknolojisinin gelişimiyle birlikte, etik standartlar ve düzenleyici çerçeveler oluşturmak da önemli bir sorumluluk haline gelmiştir. Gelecekte, yapay zekâ teknolojisinin daha da gelişerek insan hayatını daha fazla kolaylaştırması, sorunlara çözüm bulması ve daha sürdürülebilir bir dünya için kullanılması beklenmektedir. Ancak, bu süreçte bilinçli ve dengeli bir yaklaşım benimsemek, teknolojinin getirdiği potansiyel riskleri azaltmak için önemli olacaktır. Yapay zekâ, bu çeşitlilik ve geniş kapsamlı etkileriyle, insanlık için yeni fırsatlar ve zorluklar sunmaya devam edecektir (Poola, 2017).



Şekil 11: Makineler ve insanlar arasındaki iş ilişkileri

Yapay Zekâ ve Derin Öğrenmenin Sağlık Bilimlerinde Uygulamaları ve Özellikleri

Yapay zekâ ve benzer teknolojiler, özellikle sağlık sektöründe, iş dünyasında ve toplumda hızla yaygınlaşmaktadır. Bu teknolojiler, hasta bakımını geliştirmek ve sağlık kuruluşlarının işleyişini optimize etmek konusunda büyük bir potansiyele sahip olduğu görülmektedir. Araştırmalar, yapay zekânın temel sağlık görevlerini insanlar kadar başarılı, hatta bazen daha başarılı bir şekilde yerine getirebileceğini göstermiştir. Örneğin, algoritmalar radyologları bile geçerek insan gözünün ayırt edemediği kötü huylu tümörleri tespit edebilmekte ve yine bilimsel araştırmalarda pahalı klinik denemeler için uygun kohort oluşturma yolunda rehberlik edebilmektedir (Davenport T, 2019).

Sağlıkta yapay zekâ; makine öğrenimi, doğal dil işleme, robotlar ve otomasyon gibi birçok teknolojiyi içermektedir. Makine öğrenimi, özellikle sinir ağları ve derin öğrenme, hastalıkların tedavi protokollerinin başarı olasılıklarını tahmin etmede kullanılabilir. Bir hastanın çeşitli özelliklerine ve tedavi ihtiyacına dayanarak hangi tedavi protokollerinin başarılı olabileceği olasılığını tahmin edebilmektedir. Ancak denetimli öğrenme metodolojisinde yürütülen süreç, hastalığın başlangıç gibi çıkış değişkeninin bilindiği bir eğitim veri setini

gerektirmektedir. Derin öğrenme, radyomikte; yani insan gözü tarafından algılanamayan görüntü verilerindeki klinik olarak önemli özellikleri tespit etme konusunda, giderek daha fazla kullanılmaktadır. Radyomiks, tıbbi görüntülerden çıkan büyük miktardaki veriyi detaylı analiz eden ve bu veriden hassas klinik veriler çıkaran bir alandır. Özellikle onkolojiye odaklanan radyomiksi ve derin öğrenmeyi içeren bu analizler, radyoloji görüntülerindeki potansiyel kanserli lezyonları tanıma konusunda önemli gelişmeler sağlamaktadır. Yani, bu teknolojilerin bir araya gelmesi, gözle görülemeyen detayları inceleyerek kanser teşhisi ve tedavisi konularında daha etkili bir analiz sunmaktadır (Vial A, 2018).

Sinir ağları, 1960'lı yıllardan bu yana var olan ve uzun yıllardır sağlık araştırmalarında kullanılan, makine öğrenmesinin daha karmaşık bir formunu temsil eder. Bu teknolojik yaklaşım, kişinin belirli bir hastalığa yakalanma olasılığını belirleme gibi sınıflandırma uygulamalarında kullanılmıştır. Sinir ağları, problemleri çözmek adına girişleri, çıkışları ve değişkenlerin ağırlıklarını belirleyen bir yapıya sahiptir. 1970'li yıllardan itibaren, hastalık teşhisi ve tedavisi, özellikle Stanford'da kan yoluyla bulaşan bakteriyel enfeksiyonları teşhis etmek amacıyla geliştirilen "MYCIN" gibi yapay zekâ odaklı sistemlerle yoğun bir şekilde ilgilenilen bir alan haline gelmiştir (Buchanan BG, 1946). Sinir ağları, bu bağlamda hastalık teşhisi ve tedavisi alanında çeşitli ve etkili uygulamalara imkân tanımış, önemli ilerlemeler kaydedilmiştir.

Doğal Dil İşleme yapay zekanın bir alt türü olup, odak noktasını insan dilini anlamaya yöneliktir. Konuşma tanıma, metin analizi, çeviri gibi dil ile ilgili hedefleri içerir. Sağlık alanında, klinik belgeleri ve yayınlanmış araştırmaları oluşturma, anlama ve sınıflandırma gibi çeşitli görevlerde kullanılmaktadır. Bu sistemler, yapılandırılmamış klinik notları analiz edebilir, raporlar oluşturabilir, hasta etkileşimlerini yazılı olarak kaydedebilmektedir. Son zamanlarda, IBM'in Watson'u özellikle kanser teşhisi ve tedavisi üzerine odaklanarak büyük ilgi çekmiştir. Watson, makine öğrenimi ve doğal dil işleme yeteneklerini bir araya getirerek, sağlık alanında önemli bir potansiyel sunmaktadır. Ancak, bu teknolojinin erken dönemdeki heyecanı, kullanıcıların Watson'a belirli kanser türleriyle nasıl başa çıkılacağını öğretmenin ve Watson'ı tedavi süreçlerine nasıl entegre edeceğinin zorluğunu fark etmeleriyle biraz azalmıştır (Ross C, 2017).

Cerrahi robotlar, ABD’de 2000 yılında onaylanarak cerrahi alanında devrim niteliğinde bir gelişme sağlamıştır. Bu robotik sistemler, cerrahların üstün yetenekler elde etmelerine olanak tanıyarak, görme yeteneklerini artırma, hassas ve minimal invaziv kesiler oluşturma, yaraları dikme gibi işlemlerde cerrahların becerilerini güçlendirmiştir. Gelişmiş robotik cerrahi sistemleri, cerrahların uzaktan kontrol edebilmesine imkân vererek uzak bölgelerdeki cerrahi müdahaleleri gerçekleştirmelerine olanak sağlamaktadır. Bu, özellikle uzak ve savaşın olduğu bölgeler gibi ulaşılması zor bölgelerdeki cerrahi operasyonlarda büyük bir avantaj sağlamaktadır (Hussain A, 2014).

Robotik cerrahi sistemleri, kompleks ve detaylı operasyonlarda da cerrahlara destek olabilir. Üç boyutlu görüntüleme ve yüksek çözünürlüklü kameralar aracılığıyla cerrahlara detaylı bir ameliyat alanı görüntüleme imkânı sunarak cerrahi müdahalelerin daha hassas bir şekilde planlanmasına olanak sağlarlar. Bu sayede cerrahlar, daha önce ulaşılması zor olan anatomik bölgelere daha rahat bir şekilde erişebilirler (Hussain A, 2014).

Robotik cerrahi sistemleri, cerrahi müdahalelerin yanı sıra eğitim ve öğretim amaçlı da kullanılabilir. Cerrahi ekipler, simülasyonlar aracılığıyla robotik cerrahi sistemlerini kullanarak çeşitli senaryolarda pratik yapabilirler. Bu da cerrahi ekibin yeteneklerini geliştirirken yeni cerrahi tekniklerin öğrenilmesine de olanak tanımaktadır.

Ancak, bu teknolojik gelişmelerin yaygın olarak benimsenmesi için maliyet, eğitim süreçleri ve teknolojiye erişim gibi faktörler göz önünde bulundurulmalıdır. Cerrahi pratiği dönüştüren önemli bir araç olmaya devam etseler de kullanımının yaygın hale gelmesinin zaman alacağı düşünülmektedir (Hussain A, 2014).

Kural tabanlı uzman sistemler de, ‘eğer-ise’ kurallarının koleksiyonlarına dayanarak klinik karar destek amacıyla sağlıkta yaygın olarak kullanılmaktadır. Özellikle tekrarlayan görevlerde, örneğin talepler ve gelir döngüsü yönetimi gibi, oldukça faydalıdır. Diğer bir teknoloji olan RPA (Robotic Process Automation- Robotik Süreç Otomasyonu), tanımlanmış görevleri idari amaçlar için gerçekleştiren bir teknolojidir. Hasta kayıtlarını güncelleme, faturalandırma gibi görevlerde

kullanılabilmekte ve diğer yapay zekâ teknolojileriyle entegre olabilmektedir. (Utermohlen, 2018).

Teknoloji firmaları, çeşitli sağlık sorunlarına çözümler üretmek için titizlikle çalışmaktadırlar. Örneğin; Google, sağlık tesisleriyle iş birliği yaparak klinikleri sepsis ve kalp yetmezliği gibi yüksek riskli durumlar konusunda uyaracak büyük veri tahmin modelleri oluşturmaktadır. Google, Enlitic vb. bazı şirketler yapay zekâ destekli görüntü yorumlama algoritmaları geliştirirken, Jvion ise hastaların tedaviye yanıt verme şansını ölçebilen, tedavi prognozunu öngörebilen bir “klinik başarı makinesi” üzerinde çalışmaktadır. Bu gelişmeler, klinisyenlere hastalar için en iyi teşhisi ve tedaviyi belirleme konusunda yardımcı olabilecektir (Davenport T, 2019).

Birçok kanser türü genetik bir temeli olup, bunların tüm genetik varyantlarını ve bunların yeni ilaçlara ve protokollere yanıtını ortaya koymak oldukça zorludur. Bu amaçla genetik profillerine dayanarak belirli kanser türleri için teşhis ve tedavi önerilerine odaklanan birkaç firma bulunmaktadır. Roche tarafından şu anda sahip olunan Foundation Medicine ve Flatiron Health gibi firmalar, genetik profiller temelinde daha özelleştirilmiş teşhis ve tedavi önerileri sunmaktadır (Aicha AN & ., 2018)(RajkomarA,2018).

Hastaların sağlık planları, sağlık profesyonelleri tarafından özenle hazırlanmasına rağmen, hastaların bu plana uymaması durumunda; örneğin kilo verme, kontrollere gelme veya ilaçları düzenli kullanma gibi davranış değişiklikleri yapmaması sorunlara yol açabilmektedir. Bu amaçla yapay zekâ uygulamalarının, bakımı kişiselleştirmede ve davranış değişikliklerine motive etmede önemli bir rol oynayabileceği düşünülmektedir. Makine öğrenimi algoritmaları, tedavi sürecinde hastanın randevu tarihi, ilaç kullanımı, diyetle uyumluluğu gibi takiplerde kullanılarak; önemli anlarda bildirimlerle hasta uyumunu arttırabilmektedir. Bu, umut vadeden bir araştırma alanı olarak dikkat çekmektedir.

Sağlık alanında yapay zekâ kullanımıyla ilgili bir dizi etik sorun bulunmaktadır. Özellikle derin öğrenme algoritmalarının görüntü analizi gibi alanlarda şeffaflık sorunu ortaya çıkmaktadır. Yapay zekâ sistemlerinin hatalarının sorumluluğu karmaşık olabilmekte ve hastalar, tıbbi bilgilerini empati kurabilen normal bir klinisyenden almayı tercih edebilmektedir. Ayrıca, yapay zekâ sistemleri

cinsiyet veya ırk temelinde algoritmik önyargılara maruz kalabilir ve bu da sağlık sonuçlarında eşitsizliklere neden olabilecektir (Davenport T, 2019) (Char DS & ., 2018).

Erken teşhis ve tedavi çabalarına paralel olarak, yapay zekânın bu alanda hâkim olacağı öngörülmekte, özellikle görüntü analizindeki hızlı ilerlemeler göz önüne alındığında, muhtemelen radyoloji ve patoloji görüntülerinin çoğu bir noktada yapay zekâlar tarafından inceleneceği düşünülmektedir. Ancak, yapay zekânın günlük klinik uygulamada benimsenmesinde zorluklar mevcuttur. Bu zorlukları aşmak için sistemlerin benzer şekilde çalıştığı standartlar oluşturulmalı, düzenleyiciler tarafından onaylanmalı, sağlık kayıt sistemlerine entegre edilmeli, sağlık profesyonellerine eğitim verilmelidir. Bu zorluklar aşılması muhtemel olsa da teknolojinin tam olarak benimsenmesi zaman alacaktır. Yapay zekâ sistemlerinin, klinisyenleri destekleyerek daha fazla hasta bakımına katkıda bulunması ve insanların daha nitelikli görevlere odaklanmalarına olanak tanınması öngörülmektedir. Ancak, yapay zekâ ile iş birliği yapmayı reddeden sağlık profesyonelleri dışında, iş kaybına neden olması beklenmemektedir (Davenport T, 2019).

28

Nöroşirurji Alanında Yapay Zekâ Uygulamaları

Yapay zekâ ve makine öğrenimi, nöroşirurji alanında tümör, omurga, epilepsi ve vasküler patolojilerde çeşitli şekillerde kullanılarak cerrahi sonuçları önemli ölçüde geliştirmekte büyük potansiyele sahiptir. Beyin tümörü alanında bu teknikler, diferansiyel tanı, preoperatif değerlendirme ve cerrahi hassasiyetin artırılması gibi alanlarda etkin bir şekilde kullanılmıştır (Mofatteh, 2021). Özellikle beyin tümörlerinin sınıflandırması son dönemde özel bir çalışma alanı olmuştur. Buchlak ve ark. tarafından 2021 yılında yapılan bir sistematik derleme 153 çalışmadan oluşmaktadır. Burada, MR görüntülemeleri ortak temelinde çeşitli diğer değişkenlerde eklenerek evrışimli sinir ağları (CNN), destek vektör makinesi gibi farklı makine öğrenmesi uygulamaları kullanan ve tümör evresi, teşhisi, prognoz gibi birçok öngörü veren çalışmaların performansı mükemmel olarak değerlendirilmiştir (AUC = 0.87 ± 0.09 ; hassasiyet = 0.87 ± 0.10 ; özgünlük = 0.86 ± 0.10 ; tahmin = 0.88

± 0.11). Çalışma makine öğrenmesinin özellikle tümör tanı ve sınıflamasında büyük potansiyeli olduğunu vurgulamıştır (Buchlak, ve diğerleri, 2021).

Ayrıca cerrahi sonrası 30 günlük ve 6 aylık sağkalım oranlarını tahmini gibi alanlarda çalışılmış olup, glioma hastalarındaki “Isositrat Dehidrogenaz” (IDH) mutasyon durumu ve “1p19q kod silinmesi” gibi vektörlerin tedavi prognozu için önemli bir rol oynadığı gözlemlenmiştir. Chang ve ark.’larının 2018 tarihli bu çalışmasında 538 glioma hastasının preoperatif MR’ları incelenmiş; “Rastgele Orman” (RF) algoritması ile gliomaları “IDH-wildtype”, “IDH-mutant-1p19q kod delesyonu olanlar” ve “IDH-mutant-1p19q kod delesyonları olmayanlar” olarak üç kategoriye sınıflandırma modeli oluşturmuşlardır. Prognoz değerlendirmesi de yapılan çalışmada mutasyon durumlarını %78 oranında doğru tahminleme ile güçlü bir tahmin değeri ortaya koyup; aynı zamanda hasta yaşı, tümör şekli gibi değişkenlerinde önemli vektörler olduklarını ortaya koymuştur (Chang K, 2018). Diğer bir çalışmada yine MR bulgularına dayanarak “GBM” ile “Primer Merkezi Sinir Sistemi Lenfoması” ayrımı yapılmıştır. McAvoy ve ark. tarafından yapılan CNN tabanlı analizle 320 hastanın görüntüsü kullanılmış ve ayırıcı tanıda radyologlara güçlü bir yardımcı olabileceğini ortaya koymuşlardır (AUC = 0.71) (McAvoy, ve diğerleri, 2021). Yine intraoperatif olarak cerrahiye yardımcı olarak da “Yapay Sinir Ağları” (ANN) ve “Destek Vektör Makineleri” (SVM) kişiselleştirilmiş anatomik modeller oluşturmak için kullanılmıştır. Bu modellerin “Arttırılmış Gerçeklik” (AR) ile entegre edilmesinin cerrahi hassasiyeti arttırabileceği gösterilmiş olup, intraoperatif karar almayı kolaylaştırabileceği ortaya konulmuştur (Tonutti, Gras, & Yang, 2017). 2021 yılında Shen ve ark.’nın çalışmasında ise intraoperatif teşhiste ufuk açan bir yaklaşım sunulmuştur. Çalışmada glioma tanısı konulmuş 23 hastanın floresan modunda mikroskop görüntüsü alınarak CNN ile değerlendirildiğinde tümör normal doku ayrımını uzman bir nöroşirürjiyenden daha iyi yapabildiği ve tanı konusunda yüksek duyarlılık (%82) ve yüksek özgünlük (>%80) gösterdiğini ortaya koymuştur (Shen, ve diğerleri, 2021).


Spinal cerrahide lomber dejeneratif spondilolistezis cerrahisi sonrası komplikasyonları, yine spinal cerrahi sonrası uzun dönem opioid kullanma riskini, uzamış taburculuk risklerini tahmin etmek için başarıyla kullanılmıştır. Ayrıca, spinal metastatik hastalığı olan hastalarda cerrahi sonuçları tahmin etme ve erişkin spinal

deformitede sonuçları tahmin etmek için cerrahi faktörleri tanımlamada etkili olmuştur (Kim JS, 2018).


Epilepsi alanında; cerrahi sonrası nöbet bağımsızlığını öngörme, epilepsi hastalarını preoperatif ‘fonksiyonel Manyetik Rezonans Görüntüleme’ (fMRI) verilerine dayalı olarak sınıflandırma ve epilepsi teşhisi ile tedavisini geliştirme konularında önemli katkılarda bulunmuştur (Chiang S, 2015).

Ayrıca, anevrizma tahmini, stabilite değerlendirmesi, serebral iskemi tahmini, beyin arteriyovenöz malformasyon prognoz tahmini ve mikrovasküler cerrahi beceri değerlendirmesi alanlarında uygulanmıştır (Titano JJ, 2018) (Ueda D, 2018).

Sonuç olarak, yapay zekanın nöroşirürji alanında teşhis, tedavi ve sonuç tahmini alanlarında potansiyeli büyük olsa da; bu teknolojilerin klinik entegrasyonu için genelleştirilebilirlik ve yorumlanabilirlik konularında daha fazla doğrulama, büyük veri setleri ve dış doğrulama çalışmalarına ihtiyaç duyulmaktadır (Mofatteh, 2021).



Şekil 16: Yapay zekanın nöroşirürji alanındaki uygulamaları (Tangsrivimol JA, 2023)



Şekil 17: Yapay zekâ uygulamalarının sağlık alanında kullanımı (Tangsrivimol JA, 2023)

2.4 Makine Öğrenmesi ve Derin Öğrenmenin Özellikleri ve Çeşitleri

Yapay zekâ, genellikle insanlar tarafından gerçekleştirilen görevleri otomatikleştirmeye odaklanan bir alandır ve bunu başarmak için makine öğrenimi ve derin öğrenme en önemli yöntemlerdir.

Makine Öğrenmesi Yöntemleri

Makine öğrenmesi, veri kümesinden öğrenmeye odaklanan bir alandır. Klasik programlamadan farklı olarak, özelliklerin ve ağırlıkların yeni kombinasyonlarını içerebilecek veri alt kümelerini kullanarak algoritmalar oluşturur. Bunun için dört yaygın öğrenme yöntemi kullanır: denetimli, denetimsiz, yarı denetimli ve takviyeli öğrenme. Bu yöntemleri açıklamak için araba fiyatlarını ve ilişkili özellikleri tahmin eden hayali bir otomobil galerisi örneğini kullanacağız (Ron Kohavi, 1998) (Davenport T, 2019) (Choi RY, 2020).

Denetimli öğrenme, bir arabanın belirli özelliklerine dayanarak arabanın fiyatını tahmin etmeyi içeren bir yaklaşımdır. Süreç, arabanın gözlemlenmesi ve ilişkili özellikleri temsil eden örnekleri içeren bir veri kümesi toplamakla başlar. Özellikler, fiyatları tahmin etmek için kullanışlı olabilecek bir arabanın özellikleridir,

hedef ise bu durumda araba fiyatı olan tahmin edilecek özelliktir. Veri kümesi, eğitim, doğrulama ve test veri kümelerine ayrılır. Eğitim veri kümesindeki desenler kullanılarak, özellikleri hedefe eşleyen bir algoritma geliştirilir ve böylece gelecekteki veri kümelerinde fiyat tahminleri yapılabilir. Doğrulama seti ise modelin genellenebilirliğini ölçen, gerekirse düzenleme yapılabilmesini ve uygun modelin seçilmesini sağlayan veri kümesidir. Algoritmanın performansı, daha önce görmediği test veri kümesinde değerlendirilir. (Hosch, 2023) (Choi RY, 2020).

En yaygın denetimli öğrenme görevleri regresyon ve sınıflandırmadır. Regresyon, sayısal verileri tahmin etmeyi içerir; örneğin bir sınavın puanları veya bir öge fiyatları gibi. Sınıflandırma, bir örneğin hangi kategoriye ait olduğunu tahmin etmeyi içerir. Örneğin; bir otomobil galerisi, tam olarak araba fiyatlarını tahmin etmek yerine bir arabanın muhtemel satış fiyatı aralığını tahmin etmek isteyebilir. Bu durumda, veri bilimciler, sayısal hedef değişkenini araba fiyatlarını ayrı sınıflara bölen kategorik bir değişkene dönüştürürler. Bu sınıflar, kategorilerle ilişkilendirilmiş doğal bir sıralama olup olmamasına bağlı olarak sıralı veya nominal olabilir (Ron Kohavi, 1998) (Davenport T, 2019).

Denetimsiz öğrenme, hedefe yönlendirilmeden bir veri kümesinde desenleri tespit etmeyi ve bireysel örnekleri kategorilere ayırmayı içerir. Ortak görevler arasında kümeleme, ilişkilendirme ve anormallik tespiti bulunur. Kümeleme, özellik kombinasyonlarına dayanarak örnekleri ayrı kümelerde gruplandırır. Örneğin, bir galeri, veri kümesindeki arabaları tasarlayan farklı markaları temsil eden belirgin kümeleri bulmak için bir kümeleme algoritması kullanabilir (Davenport T, 2019) (Choi RY, 2020).

Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenme arasında bir orta noktadır. Genellikle etiketli ve etiketsiz verilerin bulunduğu veri kümeleriyle çalışmak için kullanışlıdır. Bu genellikle resimleri etiketlemenin zaman alıcı veya maliyetli olduğu durumlarda kullanılır. Yarı denetimli öğrenmede, bir kullanıcı tarafından etiketlenmiş küçük bir resim alt kümesi bir modeli eğitmek için kullanılır. Bu eğitilmiş model daha sonra geriye kalan etiketsiz resimleri sınıflandırmak için kullanılır. Bu modelin genellikle denetimsiz modellerden daha iyi performans göstermesi beklenir (Choi RY, 2020).

Takviyeli öğrenme, bir algoritmanın veri yerine deneme yanılma yoluyla belirli bir görev için eğitildiği bir tekniktir. Bu, insanların öğrenme şekline benzer. Takviyeli öğrenme, video oyunları gibi bir hedefe ulaşmak için ödül ve ceza yoluyla öğrenen bir algoritmayı eğitmek gibi örnekler içerir. Ancak, bu yöntem henüz pratik uygulamalara önemli bir etki yapmamıştır (N. K. Chauhan and K. Singh) (Choi RY, 2020).

Performans değerlendirme

Performans değerlendirmesinde, genellikle bir modelin gerçek dünya verilerine ne kadar iyi uyarlandığını kontrol etmek için eğitim veri kümesi iki bölüme ayrılır: birincisi daha küçük olan eğitim seti ve ikincisi ise doğrulama setidir. Bu bölme, modelin sadece eğitim verilerine değil, aynı zamanda daha önce görmediği, genel bir veri kümesine de uyum sağlayıp sağlamadığını kontrol etmek içindir. Doğrulama seti, veri bilimcilerine algoritmayı ayarlamak ve modelin yeni bir veri kümesinde başarılı olup olmadığını değerlendirmek için bir fırsat sunar. Ancak, doğrulama setinin, özellikle bilinmeyen örneklem önyargısı nedeniyle, genellikle daha büyük nüfusu tam olarak temsil etmediği unutulmamalıdır. Bu nedenle, modelin performansı ve genelleme kabiliyeti sadece doğrulama seti performansına dayanarak değerlendirilmemektedir. Yine de temel model performansının takibi genellikle eğitim ve doğrulama veri kümelerindeki doğruluk üzerinden yapılır. Artan ve birbirine yaklaşan doğruluk, modelin verileri öğrendiğini ve genel bir deseni kavradığını gösterir. Ancak, doğruluk artmıyorsa, modelin verilere uygun şekilde öğrenmediği bir durum ortaya çıkabilir. Ayrıca, eğer eğitim seti performansı doğrulama seti performansından belirgin şekilde daha hızlı artarsa, model aşırı uyumlu olabilir ve sadece eğitim veri kümesine özgü özellikleri öğrenmiş olabilir (Choi RY, 2020) (Hastie T & 2009) (James G, 2013).

İdeal bir uyum modeli ise her iki veri kümesinde de güçlü performans sergiler, yani hem eğitimde öğrendiği desenleri hem de test veri kümesinde yeni verilere başarılı bir şekilde uygular. Regresyon modelleri için ise, “Ortalama Kare Hata” (MSE) yaygın bir performans ölçüsüdür ve tahmin edilen değerlerin hedef değerlere ne kadar yakın olduğunu ölçer (Hastie T & 2009) (James G, 2013).

İkili sınıflandırmada da bir modelin performansını değerlendirmek için “Özgüllük”, “Hassasiyet” ve “Alıcı İşletme Karakteristik” (ROC) eğrisi önemli kavramlardır. Özgüllük, negatif örneklerin doğru bir şekilde negatif olarak tanımlanma oranını ölçerken; hassasiyet, pozitif örneklerin doğru bir şekilde pozitif olarak tanımlanma oranını ölçer. ROC eğrisi ise farklı karar eşiklerinde modelin performansındaki dengeyi gösterir (Choi RY, 2020) (James G, 2013).

ROC eğrisi, farklı karar eşiklerinde “Gerçek Pozitif Oranı” (TPR) ve “Yanlış Pozitif Oranı”nı (FPR) hesaplayarak elde edilir. Yani, farklı bir “Karar Eşiği” seçildiğinde, modelin ne kadar iyi pozitif ve negatif örnekleri ayırt edebildiğini gösterir. “ROC Eğrisinin Altındaki Alan” (AUROC), sınıflandırıcının genel performansını değerlendirmek için kullanılan bir ölçüdür. Eğer sınıflar dengesizse, yani pozitif ve negatif örnek sayıları birbirinden farklıysa, hassasiyet ve “Geri Çağırma Eğrisinin Altındaki Alan” (AUPR) daha iyi bir ölçü olabilir (Choi RY, 2020) (Hastie T & 2009).

AUROC veya AUPR değeri 0.50 ise, modelin şansa göre performans göstermediğini, 1.00 ise mükemmel bir modeli temsil ettiğini gösterir. Yani, bu değer ne kadar yüksekse, modelin o kadar iyi performans gösterdiği anlamına gelir. Bu ölçüler, modelin sınıfları ne kadar iyi ayırt ettiğini ve doğru tahminlerde bulunup bulunmadığını değerlendirmek için kullanılır (Choi RY, 2020).

Sonuç olarak, eğitilmiş bir modelin gerçek dünya verilerine ne kadar iyi genelleme yapabildiğini değerlendirmek için ayrı bir test seti kullanmak önemlidir. Modelin aşırı uyumlu olup olmadığını veya gerçekten genelleme yeteneğine sahip olup olmadığını anlamak için eğitim ve test veri kümeleri arasındaki performans farkları dikkate alınmalıdır (Choi RY, 2020).

Klasik Makine Öğrenimi Metodları

Doğrusal regresyon, veri analizinde kullanılan basit bir algoritmadır ve sayısal özellikler ile sayısal bir hedef arasındaki ilişkiyi bulmak için kullanılır. Bir veri kümesini açıklamak için düz bir çizgi kullanır ve $y=ax+b$ şeklinde temsil edilebilir, burada a eğim, b ise kestirimcidir. Algoritma, x değerlerini y değerleriyle en iyi ilişkilendiren a ve b değerlerini belirler (Hosch, 2023) (Choi RY, 2020). Pratik uygulamalarda, genellikle tek bir fonksiyonun bir veri kümesine mükemmel bir şekilde uyması nadirdir. Bir uyumla ilişkilendirilen hata, tahmin edilen değerlerle gerçek değerler arasındaki dikey mesafeleri hesaplayarak ölçülür. Makine öğreniminde, "Maliyet Fonksiyonu", bir modeldeki hataları en aza indirmeyi amaçlayan matematiksel bir terimdir. Bu, "Gradyan İnişi" adlı bir optimizasyon algoritması kullanmayı içerir. Doğrusal regresyon, maliyet fonksiyonu olarak ortalama kare hatasını kullanır ve bu fonksiyonu en aza indirerek en iyi uyumlu modeli bulmaya çalışır. Tüm model tabanlı öğrenme algoritmalarının bir maliyet fonksiyonu vardır ve amacı en doğru modeli bulmak için bunu en aza indirmektir (N. K. Chauhan and K. Singh) (Choi RY, 2020).

Lojistik regresyon, özellikler ile belirli bir sonucun olasılığı arasındaki ilişkiyi bulan bir sınıflandırma algoritmasıdır. Bir sigmoid eğrisi kullanarak sınıf olasılığını tahmin eder, özellikleri 0 ile 1 arasında tek bir sayısal değere dönüştüren bir "S" şeklinde eğri üretir. Bu yöntem, olasılıkların 0 ile 1 arasında sınırlı olması avantajlıdır, bu nedenle hem binom hem de multinominal sonuçlar için kullanışlıdır (Choi RY, 2020).

Karar ağaçları, veri analizinde kullanılan bir denetimli öğrenme yöntemidir. Başlangıçta bir kök düğümü ile oluşturulan bu ağaç, en iyi özellikleri kullanarak veriyi sınıflandırır veya regresyon yapar. Veriyi ikili gruplara ayırmak için tekrarlanan bölme adı verilen bir yöntem kullanılır. "Rastgele Ormanlar"(RF), birden fazla karar ağacının bir araya gelerek oluşturulduğu bir genişleme yöntemidir (Choi RY, 2020).

Yapay Sinir Ağları ve Derin Öğrenme

İleri Beslemeli Sinir Ağları (FFNN)

Yapay sinir ağı, biyolojik sinir ağlarından ilham alan bir makine öğrenimi algoritmasıdır ve birbirleriyle iletişim kuran düğümlerden meydana gelir. Bu düğümler arasındaki bağlantılar, istenilen sonucu elde edebilmelerine bağlı olarak belirli ağırlıklarla oluşturulur. Yani, her bir bağlantının gücü ve etkisi, ağırlıklar aracılığıyla belirlenir (Davenport T, 2019) (Y. LeCun, 2015).

Perceptron, bu yapılarda temel bir birimdir ve adını ‘tek hücreli algılayıcı’ oluşturan bu yapıdan alır. Perceptronlar, farklı sınıfları çok boyutlu bir uzayda ayırmak için; bir çizgi, düzlem veya hiper düzlem bulmaya çalışan makine öğrenimi algoritmalarıdır. Bu algoritmalar, girdi özelliklerini dönüştürmek için bir sigmoid fonksiyonu kullanır. Birden çok perceptron bağlandığında, çok katmanlı bir perceptron veya ‘‘Yapay Sinir Ağı’’ oluştururlar. Yapay sinir ağları genellikle bir giriş katmanı, bir çıkış katmanı ve bir veya daha fazla gizli katmana sahiptir ve her katmanda istenilen sayıda düğüm bulunmaktadır. Çoklu sınıf sınıflandırma durumunda, çıkış katmanındaki düğüm sayısı genellikle tahmin edilecek sınıfların sayısına bağlı olarak belirlenir. İkili sınıflandırma için ise genellikle bir sigmoid aktivasyonlu tek bir düğüm veya regresyon için lineer bir aktivasyon fonksiyonu kullanılır (Y. LeCun, 2015) (Choi RY, 2020). İleri beslemeli sinir ağlarında bilgi, bir katmandaki her düğümden bir sonraki katmandaki her düğüme doğru tek yönlü bir şekilde akar. Bu, tekrarlayan sinir ağlarından farklıdır. Çünkü ileri beslemeli sinir ağlarında, tekrarlayan sinir ağlarının aksine bilgi bir katmandaki düğümler arasında veya önceki katmanlara geçmemektedir (Y. LeCun, 2015) (Choi RY, 2020).

Her düğümde aktivasyon fonksiyonları kullanılır ve girdiyi istenen çıktıya dönüştürmek için hizmet eder. Aktivasyon fonksiyonları basit olabilir; örneğin doğrusal olmayan fonksiyonlar kullanılabilir. Her katman, girişlere bir dönüşüm uygular. Örneğin; girişler 0’dan büyükse dönüşüm lineer olabilmekte, ancak girişler 0’dan küçükse, dönüşüm 0.25'e ayarlanabilmektedir. Bu, girişlerin her katmandan

geçtikçe orijinal durumlarından farklı bir şekilde değiştirildiği anlamına gelir (Y. LeCun, 2015) (Choi RY, 2020).

Bu nihai giriş; temsili, teorik olarak istenen çıktının daha öngörülebilir ve anlamlı hale gelmesine yardımcı olur. Yapay sinir ağları, bu katmanlı yapı ve aktivasyon fonksiyonları sayesinde karmaşık öğrenme ve çeşitli görevleri gerçekleştirmek için kullanılmaktadır (Choi RY, 2020).

Evrişimli Sinir Ağı (CNN)

Evrişimli Sinir Ağı, özellikle görüntü tanıma görevlerinde mekânsal bağlamın kaybolma sorununu (konumsal özelliklerin göz ardı edilmesi sorunu) çözmek için tasarlanmış bir yapay sinir ağı türüdür. Sıradan bir beslemeli sinir ağının her pikseli ayrı bir giriş olarak ele almasına karşılık, bu orijinal görüntüyü belirli yama parçaları olarak alan ve bu yamalar üzerinde belirli filtrelerle işlemler gerçekleştiren düğümleri kullanır. Bu filtreler, pikseller arasındaki mekânsal ilişkiyi korur ve belirli özellikleri ortaya çıkarır (N. Aloysius, 2017).

Evrişim işlemleri, orijinal görüntü üzerinde “Küçük Matris Geçirme” ve “Eleman Bazlı Matris Çarpımı” işlemlerini içerir. Bu evrişim işleminin çıktısı, bir özellik haritası olarak adlandırılır ve belirli bir özelliğin varlığını gösterir. CNN’ler, bu filtreler aracılığıyla belirli özellikleri çıkararak bir nesneyi tanımlar (N. Aloysius, 2017). Elde edilen özellik haritaları, bir sonraki katmana giriş olarak kullanılır ve bu süreç devam ettikçe özellikler soyutlaşır ancak aynı zamanda görev için daha anlamlı hale gelir. Bu süreç, “Derin öğrenme” (DL) olarak adlandırılır. Derin öğrenme, “Görüntü içindeki nesneleri tanımlama” ve “Görüntü segmentasyonu” gibi görevleri içerir (N. K. Chauhan and K. Singh) (N. Aloysius, 2017).

Derin öğrenme, retinal kan damarı tespiti veya meme kanseri gibi görevlerde pikselleri kullanarak önemli başarılar elde edebilir. Elde edilen görüntüler daha sonra bir uzman tarafından daha fazla değerlendirme için incelenebilir. Bu sayede, evrişimli sinir ağları kompleks görüntü işleme görevlerinde etkili bir şekilde kullanılabilir (Choi RY, 2020).

Tıpta derin öğrenme modelleri, sınırlı sayıda ve kalitedeki eğitim verisi nedeniyle zorluklarla karşılaşır. Gerekli veri miktarını belirlemek zordur; çünkü bu, görevin karmaşıklığına ve kalitesine bağlı değişmektedir. Özellikle nadir hastalıklar için modeller geliştirmek zorlayıcı olabilir, çünkü geniş veri setleri mevcut olmayabilir. Daha fazla veri, teorik olarak faydalı olabilir. Ancak eğitim verisi doğru değilse veya test popülasyonundan farklıysa, modeller gerçek dünya senaryolarında başarılı olmayabilir. Ayrıca, veri setlerinin sıklıkla yanlış veya eksik etiketlere sahip olması, veri bilimcileri için başka bir sorun teşkil edebilmektedir (Choi RY, 2020).

Derin öğrenme yöntemleri, model çıktısının nasıl oluştuğu ve bu çıktıların nasıl katkıda bulunduğu konusunda belirsizlik içeren “kara kutu” sorunuyla mücadele etmektedir. Diğer yandan, basit doğrusal algoritmalar, her bir özellik için hesaplanan ağırlıkları sağlayarak daha kolay yorumlanabilir. Derin öğrenme, matris çarpımı ve soyut filtrelerle karmaşıklık ekleyerek yorumlanabilirliği daha zor hale getirir. Aktivasyon haritaları, bu sorunu ele almaya çalışan bir çözümdür; ancak bu yöntemler hala insan yorumlaması gerektirir ve aktif bir araştırma alanıdır. Özellikle bir doktorun, derin öğrenme modeli tarafından tanımlanan özelliklerin teşhisleriyle uyumlu olup olmadığını ve bu bulguların hangi anlamı taşıdığını belirlemesi gerekir (N. K. Chauhan and K. Singh) (N. Aloysius, 2017) (Choi RY, 2020).

3. YÖNTEM

Bu tez retrospektif bir çalışma olarak oluşturulmuş ve Marmara Üniversitesi etik kurul komitesi tarafından 09.2023.1748 numaralı onay numarası ile kabul edilmiştir.

3.1 GÖRÜNTÜLERİ ELDE ETME


Marmara Üniversitesi Beyin ve Sinir Cerrahisi Bölümü tarafından yürütülen bu tez çalışmasında, cerrahi müdahale sırasında elde edilen görüntü verileri kullanılarak, çocukluk posterior fossa tümörlerinin tespit edilmesi ve sınırlarının çizilmesi hedeflenmiştir. Çalışmanın metodolojisi, etik kurallara uygun bir şekilde hasta verilerini toplamak ve gizliliği korumak üzere titiz bir şekilde düzenlenmiştir.

Çalışmada verinin derin öğrenmeye hazır hale getirilmesi sürecinde 4 temel aşama bulunmaktadır. Bu aşamalar; ameliyat videolarının elde edilmesi, videoların görüntülere dönüştürülmesi, görüntülerin filtrelenmesi ve görüntülerin etiketlenmesidir. İlk aşamada posterior fossa tümörü olan hastalar belirlenmiş ve bu ameliyatlara ait mikroskop görüntülerinden oluşan bir veri seti oluşturulmuştur. Elde edilen videolar genellikle yaklaşık olarak bir saatlik sürelerden oluşmaktadır ve mp4 formatındadır. Videoların görüntülere dönüştürülmesi için VLC Media Player ® kullanılmıştır. Her bir saniyede bir görüntü elde edilecek şekilde videolar görüntülere dönüştürülmüştür. Bu çalışma kapsamında Marmara Üniversitesi Beyin ve Sinir Cerrahisi bölümünde gerçekleştirilen ameliyatlara ait 22 hasta videosu alınmış ve “jpg” formatında görüntülere dönüştürülmüştür.


3.2 VERİ SETİ OLUŞTURMA VE ETİKETLEME

Hastalara ait ameliyat videoları cerrahi mikroskoptan alınan videolardan oluşmaktadır. Bu sebeple cerrahi mikroskobun odaklanması sırasında oluşan bulanık görüntüler, ameliyat sırasında kanama sebebiyle oluşan yoğun kan görüntüleri ve cerrahi aletin görüntü kalite ve içeriği engellemesi durumlarından dolayı oluşan ve model eğitime katkı sağlamayacak görüntülerin filtrelenmesi gerekmektedir. Örneğin videoların görüntülere dönüştürülmesi ile 1486 görüntüden oluşan filtresiz görüntü veri seti, uzman hekimlerin filtrelemeleri ile 103 görüntüye düşürülmüştür. Görüntülerde herhangi bir kırpma, döndürme ya da renk değişikliği uygulanmamıştır. 22 hastaya ait toplam 2800 filtrelenmiş ve etiketlenmeye hazır görüntü elde edilmiştir.



Tümörün sınırlarının tespit edilmesi için tümörlerin poligonlar şeklinde etiketlenmesi gerekmektedir. Toronto Üniversitesinde geliştirilen “Toronto Annotation Suite: AI-Powered Data Annotation” aracı web tabanlı yapay zekâ destekli bir etiketleme platformudur (Toronto Annotation Suite). Hekimler bu platform üzerinden görüntüleri yapay zekâ desteği ile çok hızlı ve doğru şekilde etiketlemişlerdir. Etiketleme aracına ait örnek görüntüler Şekil 14’ de verilmiştir.



(a) Etiketlenecek görüntü



(b) Yapay zeka destekli etiketlenmiş görüntü



(c) Etiketlenen dokunun sınırlarının belirtilmiş hali

Şekil 18 : Toronto Annotation Suite: AI-Powered Data Annotation ile görüntü etiketleme

Öncelikle etiketlenecek görüntüler Toronto Annotation Suite aracına yüklenmektedir. Sonrasında görüntüler etiketlenmek üzere hekimlere atanmaktadır. Her hekim kendine ait hastayı görmekte ve tümör dokusunu etiketleyebilmektedir. Yukarıdaki şekilde (a) etiketlenecek görüntüyü göstermektedir. (b)' de ise, görüntünün bir sınırlayıcı kutu (bounding box) ile seçilmesi sonucu yapay zeka destekli nesne tespiti gerçekleşmiştir. Burada her bir nesne x ve y noktalarından oluşan poligonlarla temsil edilmektedir. Yapay zekâ ile elde edilen nesne tespiti sonucundaki noktalar hekimler tarafından gerekmesi durumunda değiştirilebilmektedir. (c) 'de etiketlenmiş görüntünün gerçek boyutlu hali ve etiketlenen nesnenin etiket bilgisi verilmektedir. Bu çalışma kapsamında her bir görüntüde bulunan posterior fossa tümörü etiketlenmiş ve "tumor" etiketi ile

kaydedilmiştir. Tüm görüntülerin etiketlenmesi sonucu 2800 görüntü için 2806 tumor etiketi elde edilmiştir. Etiket dosyası json dosyası olarak kaydedilmiştir.


Veri seti eğitim(train), doğrulama(validation) ve test(test) olmak üzere 3'e ayrılmıştır. Eğitim için 2623, doğrulama için 95 ve test için 82 görüntü kullanılmıştır.

3.3 DERİN ÖĞRENME

3.3.1. Mask R-CNN

Mask R-CNN (Maske Tabanlı Evrişimsel Sinir Ağı), bilgisayarla görme ve makine öğrenimi uygulamalarında “Örnek Segmentasyonu” (Instance Segmentation) zorluğunu ele almak için tasarlanmış bir derin sinir ağıdır. Bir regresyon ve sınıflandırma problemi olarak dikdörtgen kutular kullanarak nesne tespitine odaklanan “Faster R-CNN” modelinin bir uzantısıdır. Mask R-CNN, nesne sınırlarının hassas bir şekilde tanımlanmasına olanak tanıyan nesne maskesini çıkaran ek bir dal sunar (He, 2020). Bu özellik, Mask R-CNN' i; insan pozu tahmini, meyve tespiti, çekirdek segmentasyonu ve tıbbi görüntülemelerde optik sinir başı, disk tespiti gibi çok çeşitli görevler için uygun hale getirir (Yang, 2019) (Almubarak, 2020). Modelin esnekliği ve uyarlanabilirliği; otomatik sayaç okuma, tarım robotları için meyve algılama ve yüz maskesi algılama sistemleri gibi uygulamalarda da gösterilmiştir (Yang, 2019) (Johnson, 2019). Mask R-CNN'nin çok yönlülüğü ve etkinliği, onu çeşitli gerçek dünya senaryolarında sağlamlık ve yetenekler sunan örnek segmentasyon görevleri için önemli bir çözüm olarak konumlandırmıştır.

Örnek düzeyinde tanıma için sağlam bir çözüm sunarak nesne algılama ve görüntülerin piksel segmentasyonu gibi görevleri başarıyla gerçekleştirdiğinden dolayı tercih edilmektedir. Mask R-CNN, tıp alanında, özellikle de çeşitli tıbbi görüntüleme ve patoloji uygulamalarında da önemli bir kullanım alanı bulmuştur. Örneğin, MRI görüntülerinden beyin tümörlerinin tespiti ve sınıflandırılmasında kullanılmıştır (Masood, 2021). Ayrıca, Mask R-CNN karaciğer yağlanması damlacıklarının kümeler halinde segmentasyonunda kullanılmış ve karaciğer analizine yardımcı olmuştur (Guo, 2019).



Şekil 15: Mask R-CNN örnek segmentasyonu

Mask R-CNN, derin sinir ağı mimarisine entegre edilmiş bir örnek segmentasyon modelidir. Bu model, özellikle ‘İlgi Bölgesi’ (RoI) yerelleştirmesi üzerine odaklanarak nesne tanıma ve segmentasyon görevlerinde üstün performans sergileyen bir öğrenme çerçevesidir. RoI yerelleştirmesi, modelin görüntü üzerinde belirli ilgi bölgelerini tanımlamasına ve bu bölgelerde daha ayrıntılı analizler yapmasına olanak tanır (Lee H. H., 2021). Mask R-CNN, nesne tanıma sürecinde hem nesnenin varlığını algılamak hem de her pikselin hangi nesneye ait olduğunu belirlemek amacıyla geliştirilmiştir. Bu model, önce ilgi bölgelerini belirler, ardından her bir bölgeyi daha ayrıntılı bir şekilde işleyerek nesne sınıflandırması ve piksel bazlı segmentasyonu gerçekleştirir. Bu yaklaşım, önceki segmentasyon modellerine kıyasla daha hassas sonuçlar ve daha yüksek performans sağlamaktadır. Mask R-CNN’nin uçtan uca öğrenme çerçevesi, nesne tanıma ve segmentasyon görevlerini aynı anda ele alır, bu da modelin genel etkinliğini artırır. Bu sayede, görüntü verilerinden karmaşık nesne yapılarını doğru bir şekilde çıkarmak ve belirlemek için kullanılabilecek güçlü bir araç sunar.

3.3.2 Değerlendirme Metrikleri

Hassasiyet ve duyarlılık, sınıflandırma ve nesne tespiti sistemlerinin performansını değerlendirmek için kullanılan temel ölçütlerdir. Hassasiyet, alınan örnekler arasında ilgili örneklerin oranını ölçerken, duyarlılık, veri kümesindeki ilgili

örneklerin toplam miktarı üzerinden alınan ilgili örneklerin oranını ölçer. Hassasiyet ve duyarlılık için formüller aşağıdaki gibidir:

$$\text{Hassasiyet} = \text{Doğru Pozitifler} / (\text{Doğru Pozitifler} + \text{Yanlış Pozitifler})$$

$$\text{Duyarlılık} = \text{Doğru Pozitifler} / (\text{Doğru Pozitifler} + \text{Yanlış Negatifler})$$

Burada Doğru Pozitifler doğru tanımlanmış pozitif örnekler, Yanlış Pozitifler yanlış tanımlanmış pozitif örnekler ve Yanlış Negatifler yanlış tanımlanmış negatif örneklerdir. Bu metrikler, bir modelin ilgili örnekleri doğru bir şekilde tanımlama ve yanlış pozitif ve yanlış negatiflerden kaçınma konusundaki etkinliğini değerlendirmede önemlidir. Hassasiyet ve duyarlılık genellikle birlikte kullanılır ve ikisi arasında bir ters orantı yaygındır. Örneğin, hassasiyet arttığında tipik olarak duyarlılık azalır ve bunun tersi de geçerlidir. Hassasiyeti ve duyarlılığı dengelemek için genellikle hassasiyet ve geri çağırmanın harmonik ortalaması olan ve her iki ölçütü de dikkate alan tek bir ölçüm sağlayan F1 skor kullanılır. Daha yüksek bir F1 skor daha iyi model performansına işaret eder; 1 mümkün olan en iyi değer, 0 ise en kötü değerdir.

$$\text{F1 Skor} = 2 * (\text{Hassasiyet} * \text{Duyarlılık}) / (\text{Hassasiyet} + \text{Duyarlılık})$$

Dice benzerlik katsayısı ve Jaccard indeksi (Jaccard benzerlik katsayısı olarak da bilinir), segmentasyon algoritmalarının performansını, tahmin edilen ve gerçek segmentasyonlar arasındaki örtüşmeyi değerlendirmek için yaygın olarak kullanılan ölçütlerdir. Genellikle Dice skoru olarak adlandırılan Dice benzerlik katsayısı, iki ikili maske arasındaki uzamsal örtüşmenin bir ölçüsüdür ve iki kümenin kesişiminin iki katının iki kümenin kardinalitelerinin toplamına oranı olarak tanımlanır. Dice katsayısı için formül şöyledir:

$$\text{Dice} = (2 * |A \cap B|) / (|A| + |B|)$$

Burada:

- A ve B iki kümedir (örneğin, tahmin edilen segmentasyon maskesi ve temel gerçek maskesi).

- $|A \cap B|$, A ve B'nin kesişiminin kardinalitesini temsil eder.

- $|A|$ ve $|B|$ sırasıyla A ve B'nin eleman sayılarını temsil eder.

Dice katsayısı 0 ile 1 arasında değişir; burada 0 iki küme arasında uzamsal örtüşme olmadığını, 1 ise mükemmel uzamsal örtüşmeyi gösterir.

Jaccard benzerlik katsayısı olarak da bilinen Jaccard endeksi, iki küme arasındaki benzerliğin bir ölçüsüdür ve kümelerin kesişiminin büyüklüğünün kümelerin birleşiminin büyüklüğüne oranı olarak tanımlanır. Jaccard indeksi için formül şöyledir:

$$\text{Jaccard} = |A \cap B| / |A \cup B|$$

Burada:

- A ve B iki kümedir (örneğin, tahmin edilen segmentasyon maskesi ve temel gerçek maskesi).

- $|A \cap B|$, A ve B'nin kesişiminin kardinalitesini temsil eder.

- $|A \cup B|$, A ve B'nin birleşiminin eleman sayısını temsil eder.

Dice katsayısına benzer şekilde, Jaccard indeksi de 0 ile 1 arasında değişir; 0 benzerlik olmadığını, 1 ise mükemmel benzerliği gösterir.

Hem Dice katsayısı hem de Jaccard indeksi tıbbi görüntüleme, bilgisayarla görme ve diğer alanlarda segmentasyon algoritmalarının doğruluğunu ve tahmin edilen ve gerçek segmentasyonlar arasındaki uyumu niceliksel olarak değerlendirmek için yaygın olarak kullanılır.

4. BULGULAR

Eğitim ve doğrulama seti kullanılarak 200 epoch model eğitimi yapılmıştır. Eğitim süreci, ‘Python 3.7’, ‘Tensorflow’ ve ‘Keras’ gibi açık kaynaklı kütüphaneler, aynı zamanda diğer destekleyici kütüphaneler kullanılarak gerçekleştirilmiştir. Bu çalışma, tümör tespiti görevini gerçekleştirmek amacıyla tasarlanmıştır. Eğitim süreci sırasında, baştan sona bir ağı eğitmek yerine, önceden eğitilmiş bir modelin ağırlıkları kullanılmıştır. Bu önceden eğitilmiş model, ‘Microsoft COCO’ veri kümesi üzerinde eğitilmiştir. Elde ettiği bilgi ve öğrenmeler, yeni uygulamanın eğitimi için temel oluşturmuştur. Bu yöntem, eğitim sürecini hızlandırarak ve daha az veriyle daha iyi sonuçlar elde etmeyi amaçlamaktadır.

Değerlendirme metrikleri olarak, hassasiyet (precision), duyarlılık (recall), DICE ve JAC indeksleri kullanılmaktadır. Hassasiyet, pozitif olarak tahmin edilen değerlerin, görüntülerin veya dokuların gerçekte kaç adedinin pozitif olduğunu gösterir. Bu metrik, modelin ne kadar doğru ve spesifik tahminler yaptığını ölçer. Duyarlılık ise, pozitif olarak tahmin edilmesi gereken değerlerin ne kadarının doğru bir şekilde pozitif olarak tahmin edildiğini gösteren bir metriktir. Yani, duyarlılık, gerçek pozitiflerin tüm pozitif değerlere oranını ifade eder ve modelin ne kadar kapsayıcı olduğunu ölçer.

DICE ve JAC indeksleri ise genellikle özellikle nesne tespiti ve benzeri görevlerde kullanılan metriklerdir. DICE indeksi, modelin tahmin ettiği bölgenin gerçek bölgeyle ne kadar örtüştüğünü ölçerken, JAC indeksi ise bu örtüşme oranını değerlendirir.

Bu metriklerin kombinasyonu, modelin performansını geniş bir perspektiften değerlendirerek, özellikle nesne tespiti ve benzeri görevlerde başarısının anlaşılmasına yardımcı olur.

	Hassasiyet	Duyarlılık	DICE		JAC	
			Mask	Box	Mask	Box
Mask R-CNN Posterior fossa Tümör Tespiti	0.90	0.94	0.77	0.78	0.72	0.70

Tablo 1: Modelin Mask R-CNN ile Posterior fossa tümör tespiti hassasiyet, duyarlılık, DICE ve JAK değerleri tablosu.


Mask R-CNN modelinin 70 test görüntüsü üzerinde elde ettiği sonuçlara göre, ortalama hassasiyet değeri 0.90 ve duyarlılık değeri 0,94 olarak hesaplanmıştır. Ortalama hassasiyet değerinin 0.90 olması, modelin pozitif olarak sınıflandırdığı tümörlerin büyük bir kısmının gerçekten pozitif olduğunu gösterir. Yüksek bir hassasiyet, modelin doğru tahminler yaptığını ve yanlış pozitif tahminlerin düşük olduğunu gösterir.

Duyarlılık değerinin 0.94 olması ise, modelin gerçek pozitif tümörlerin büyük bir kısmını tespit ettiğini gösterir. Bu yüksek duyarlılık değeri, modelin tümörleri kaçırmama yeteneğinin güçlü olduğunu ve verilen görüntülerdeki pozitif örnekleri etkili bir şekilde algılayabildiğini ifade eder.


Sonuç olarak, Mask R-CNN modelinin 70 görüntü üzerinde elde ettiği ortalama hassasiyet 0.90 ve duyarlılık 0.94 değerleri, modelin tümör tespiti görevinde güvenilir ve etkili bir performans sergilediğini göstermektedir.

Mask R-CNN modelinin elde ettiği sonuçlara göre, Dice metriği maskelere göre 0.77 ve kutulara(box) göre ise 0,78 olarak hesaplanmıştır. Modelin Dice mask değerinin 0.77 olması, modelin maske tahminlerinin gerçek maske bölgeleriyle yüzde 77 oranında örtüştüğünü gösterir. Yüksek bir Dice mask değeri, modelin tümör maske tahminlerinin gerçek tümör maske bölgeleriyle iyi bir uyum içinde olduğunu ve bu tahminlerin güvenilir olduğunu ifade eder. Ayrıca JAC metriği de maskelere göre 0.72 ve kutulara(box) göre ise 0,70 olarak hesaplanmış ve örtüşme göstermiştir.


Eğitim sonucu oluşan modelin test seti üzerindeki sonuçları aşağıda görüntüler halinde sunulmuştur.



(a) Orijinal görüntü (1)



(b) Etiketlenen görüntü




(c) Mask R-CNN ile tespit edilen tümör görüntüsü


Şekil 16: Modelin orijinal görüntü-1 üzerindeki test sonucu



(a) Orijinal görüntü (2)



(b) Etiketlenen görüntü




(c) Mask R-CNN ile tespit edilen tümör görüntüsü


Şekil 17: Modelin orijinal görüntü-2 üzerindeki test sonucu



(a) Orijinal görüntü (3)




(b) Etiketlenen görüntü




(c) Mask R-CNN ile tespit edilen tümör görüntüsü

Şekil 18: Modelin orijinal görüntü-3 üzerindeki test sonucu



(a) Orijinal görüntü (4)



(b) Etiketlenen görüntü



(c) Mask R-CNN ile tespit edilen tümör görüntüsü

Şekil 19: Modelin orijinal görüntü-4 üzerindeki test sonucu

5. TARTIŞMA VE SONUÇ

Yapay zekâ teknolojileri sosyal hayatın yanında birçok sektörel alanda yaygınlaşmakta olup sağlık sektörü en gözde alanlardan birisidir. Bu teknolojilerin hasta bakımını geliştirmede önemli potansiyeli olduğu son dönemde bariz örneklerle görülmektedir. Radyoloji, patoloji gibi tanısal alanların yanında ilaç geliştirme, cerrahi planlama ve robotik gibi farklı alanlarda da kullanılmaya başlanmıştır. Nöroşirurji alanı da bu gelişmelerden en çok faydalanabilecek branşların başında gelmektedir. Son yıllarda tümör, spinal, hidrosefali, epilepsi ve vasküler cerrahi gibi nerdeyse tüm nöroşirürjikal hastalık alt gruplarında çalışmalar mevcuttur (Mofatteh, 2021). Özellikle beyin tümörlerinin sınıflandırması son dönemde özel bir çalışma alanı olmuştur. Buchlak ve ark. tarafından 2021 yılında yapılan bir sistematik derleme 153 çalışmada MR görüntülemeleri ve diğer vektörler kullanılarak makine öğrenmesi uygulamaları ile tümör evresi, teşhisi, prognoz gibi birçok öngörü veren çalışmaların performansı oldukça yüksek bulunmuştur (Buchlak, ve diğerleri, 2021). Ayrıca cerrahi sonrası 30 günlük mortalite ve 6 aylık sağkalım oranlarını tahmini gibi alanlarda çalışılmış olup, glioma hastalarındaki “Isositrat Dehidrogenaz” (IDH) mutasyon durumu ve “1p19q” kod silinmesi gibi vektörlerin tedavi prognozu için önemli bir rol oynadığı gözlemlenmiştir (Chang K, 2018). Diğer bir çalışmada yine MR bulgularına dayanarak “GBM” ile “Primer Merkezi Sinir Sistemi Lenfoması” ayrımı yapılmıştır (McAvoy, ve diğerleri, 2021). Yine intraoperatif olarak cerrahiye yardımcı olarak da “Yapay Sinir Ağları” (ANN) ve “Destek Vektör Makineleri” (SVM) kişiselleştirilmiş anatomik modeller oluşturmak için kullanılmıştır. Bu modellerin “Arttırılmış Gerçeklik” (AR) ile entegre edilmesinin cerrahi hassasiyeti arttırabileceği gösterilmiş olup intraoperatif karar almayı kolaylaştırabileceği ortaya konulmuştur (Tonutti, Gras, & Yang, 2017). 2021 yılında Shen ve ark.’nın çalışmasında ise glioma tanısı konulmuş 23 hastanın floresan modunda mikroskop görüntüsü alınarak CNN ile değerlendirildiğinde tümör normal doku ayrımını uzman bir nöroşirürjiyenden daha iyi yapabildiği ve tanı konusunda yüksek duyarlılık (%82) ve yüksek özgünlük (>%80) gösterdiğini ortaya koymuştur (Shen, ve diğerleri, 2021).

Preoperatif görüntülemeler ve diğer klinik verilerle tümör tanısı ve sınıflaması ile ilgili çokça çalışma olmasına karşın; intraoperatif olarak tümör sınırlarının çizilmesi, sağlıklı doku ile tümör dokusu ayrımı yapılmasına yönelik çalışmalar son derece kısıtlıdır. Özellikle yeterli sayıda veri toplanma zorluğu, cerrahi alanın nispeten kısıtlı olması, tümörün derinliği, tümörün boyutu gibi net ve işlenebilir görüntü elde etme konusunda birçok engelin olduğu pediyatrik posterior fossa tümörlerinin tanınması, sınırlarının çizilmesi konusunda literatürde henüz bir çalışma yoktur.

Çalışmamızda retrospektif olarak pediyatrik posterior fossa tanısı konulan 22 hastaya ait toplam 2800 filtrelenmiş ve etiketlenmeye hazır görüntü kullanılmıştır. Bu görüntüler web tabanlı yapay zekâ destekli bir etiketleme platformu Toronto Annotation Suite' da 2623 görüntü eğitim, 95 doğrulama ve 82 görüntü ise test amacıyla kullanılmıştır ve pediyatrik posterior fossa tümörü tespiti tahmini amaçlanmıştır. Mask R-CNN modelinin 70 görüntü üzerinde elde ettiği sonuçlara göre, ortalama hassasiyet değeri 0,90, duyarlılık değeri 0,94, Dice metriği maskelere göre 0,77 ve kutulara(box) göre ise 0,78 olarak, JAC metriği de maskelere göre 0,72 ve kutulara(box) göre ise 0,70 hesaplanmıştır. Yani modelin doğru tahminler yaptığı ve tümörleri kaçırmama yeteneğinin güçlü olduğunu ve verilen görüntülerdeki pozitif örnekleri etkili bir şekilde algılayabildiği görülmüştür. Sonuç olarak modelin pediyatrik posterior fossa tümörlerini normal dokudan ayırt etme ve sınırlarını çizmede güvenilir ve etkili bir performans sergilediği görülmüştür.

Çalışmada en kısıtlayıcı aşama görüntülerin elde edilmesi aşaması olmuştur. Tek merkezde kısa bir süre aralığında kısıtlı bir tümör grubunun görüntüsünü bulmak zorlayıcı olmuştur. Ayrıca çalışmaya alınan görüntülerde tümörün ekranda net ve kansız görüldüğü, cerrahi aletlerin görüntüyü engellemediği görüntülemeleri seçme sırasında görüntü sayısı oldukça azaltılmıştır. Veri azlığı nedeniyle çalışma sadece pediyatrik posterior fossa tümörlerinin intraoperatif görüntülemelerde tanınması olarak sınırlandırılmış olup daha geniş zaman aralığında daha çok veri ile tümör sınıflaması yapılması ve olası genetik alt tiplerinin belirlenmesi de ileri çalışmaya hedef olarak belirlenmiştir.

Bu alıřma, intraoperatif yapay zekâ destekli olarak t m r sınırlarının izilmesi ve normal doku ile t m r arasındaki ayrımın yapılabilmesi imkanının elde edilmesiyle birlikte,  zellikle pediyatrik posterior fossa t m rlerinin cerrahisi gibi ocuk yař grubunda ve temel vital becerilerin y netildięi dar bir alanın cerrahisi konusundaki deneyimsiz ve deneyimli t m n rořir rjiyenlerin omuzlarındaki y k  kısmen hafifletebileceęi d ř ncesini sunmaktadır. İleri alıřmaların kısa zamanda g n m z teknolojilerine dahi s ratle entegre olabileceęi d ř n lmektedir.

