



**BEYİN MR GÖRÜNTÜLERİNİ SINIFLANDIRARAK
YAPAY SİNİR AĞLARI KULLANARAK BEYİN TÜMÖRÜ
TESPİTİ**

(Yüksek Lisans Tezi)

Ahmed M. A. ABUSAMRA

Kütahya - 2024

T.C.
KÜTAHYA DUMLUPINAR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

**BEYİN MR GÖRÜNTÜLERİNİ SINIFLANDIRARAK YAPAY
SİNİR AĞLARI KULLANARAK BEYİN TÜMÖRÜ TESPİTİ**

Danışman:
Dr. Öğr. Üyesi Muammer AKÇAY

Hazırlayan:
Ahmed M. A. ABUSAMRA

Kütahya-2024

Kabul ve Onay

KÜTAHYA DUMLUPINAR ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalında, 202085151022 öğrenci numaralı, Ahmed M. A. ABUSAMRA'nın hazırlamış olduğu “*BEYİN MR GÖRÜNTÜLERİNİ SINIFLANDIRARAK YAPAY SİNİR AĞLARI KULLANARAK BEYİN TÜMÖRÜ TESPİTİ*” başlıklı yüksek lisans tez çalışması ile ilgili tez savunma sınavı jüri tarafından yapılmış ve adayın tezinin OY BİRLİĞİ ile kabul edilmesine karar verilmiştir.

30/05/2024

Tez Jürisi	İmza	
	Kabul	Ret
Dr. Öğr. Üyesi Muammer AKÇAY (Danışman)		
Doç. Dr. Hasan TEMURTAŞ		
Prof. Dr. Eyyüp GÜLBANDILAR		

Onay

Doç. Dr. Eray ACAR

Enstitü Müdürü

Bilimsel Etik Bildirimi

Yüksek Lisans tezi olarak hazırladığım “*Beyin MR Görüntülerini Sınıflandırarak Yapay Sinir Ağları Kullanarak Beyin Tümörü Tespiti*” adlı çalışmanın öneri aşamasından sonuçlandığı aşamaya kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığımı, bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

30/05/2024

Ahmed M A ABUSAMRA

Özgeçmiş

Ahmed Abu Samra, ilkokul eğitimini Beni Suhayla İlkokulu'nda tamamlamış, ortaokul eğitimini Abdülkerim el-Kurmi Okulu'nda almış ve lise eğitimini Filistin'deki El-Mutanabbi Okulu'nda tamamlamıştır. 2018 yılında Kudüs Açık Üniversitesi'nde Teknoloji ve Uygulamalı Bilimler bölümünden mezun olduktan sonra Bilgi ve İletişim Teknolojileri alanında uzmanlaşmıştır. Yüksek lisans eğitimine 2020 yılında Dumlupınar Üniversitesi Yüksek Lisans Enstitüsü'nde Bilgisayar Mühendisliği bölümünde başlamıştır.



ÖZET

BEYİN MR GÖRÜNTÜLERİNİ SINIFLANDIRARAK YAPAY SİNİR AĞLARI KULLANARAK BEYİN TÜMÖRÜ TESPİTİ

ABUSAMRA Ahmed M. A.

Yüksek Lisans Tezi, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Muammer AKÇAY

Mayıs, 2024, 91 sayfa

Beyin, insan vücudu için hayati bir merkez olarak kabul edilirken, maalesef içinde beyin tümörleri gibi ciddi hastalıklar ortaya çıkabilir ve bu hastalıkların doğru teşhis edilmesi, tedavi ve sağkalım şansını artırmak için hayati öneme sahiptir. Yapay zekâ (AI) bu noktada devreye girer ve karmaşık hastalıkların sınıflandırılmasını iyileştirmek için kullanılabilir. Bu bağlamda, Derin Sinir Ağları (CNN) genel olarak görüntülerin sınıflandırılmasında büyük bir başarı elde etmiştir. CNN, görüntü işleme ve görsel verilerin anlaşılmasında önemli bir ilerleme sağlamış ve görüntülerdeki desenlerin ve nesnelerin tanınmasını geliştirebilir. Bu ağlar, bilgileri görüntülerden aşamalı olarak çıkarmak için evrimsel ve havuzlama katmanları gibi bir dizi katmanı kullanır. Derin öğrenme teknikleri kullanarak, CNN karmaşık desenleri ve ayrıntıları tanıyabilir, nesneleri ve insanları sınıflandırabilir, nesneleri algılayabilir ve görüntülerdeki nesneleri yüksek hassasiyetle ayırabilir. Özellikle manyetik rezonans görüntüleme (MRG) kullanarak beyin tümörlerini sınıflandırmak için, CNN'lerin tıbbi görüntülerin doğru sınıflandırılması ve analizi konusundaki etkinliği kanıtlanmıştır. Bu teknoloji, görüntülerden önemli bilgileri çıkarmak ve tümörlerin türünü ve konumunu hassas bir şekilde belirlemek için kullanılabilir, bu da doktorları doğru tedaviye yönlendirmeye ve beyin tümörü hastalarının tedavi başarısını artırmaya yardımcı olabilir. CNN'lerin desenleri öğrenme ve performansı geliştirme yeteneği, birçok farklı alanda temel bir araç haline gelirken, görsel verilerin daha iyi ve daha hassas bir şekilde anlaşılması için sürekli gelişmeye ve uygulamaya devam etmektedir. Bu çalışmada, VGG16, EfficientNetB3 ve ResNet50 gibi üç farklı yapay sinir ağı modeli kullanıldı. Önceden sınıflandırılmış beyin tümörü MRG görüntülerinden oluşan büyük bir veri kümesi kullanıldı. Bu veri kümesi, modellerin performansını değerlendirmek için eğitim ve test verilerine ayrıldı. Çalışmanın sonuçları oldukça umut vericiydi, çünkü EfficientNetB3 modelinin sınıflandırma doğruluğu %99,21'e ulaşarak en iyi sonuçları elde etti. Bu, bu modelin tümörler arasındaki ayrımı istisnai bir hassasiyetle gerçekleştirebileceğini

göstermektedir. Yapay zekânın beyin tümörleri sınıflandırmasında kullanılması, teşhis doğruluğunu artırabilir ve hastalar için en uygun tedaviyi yönlendirmede yardımcı olabilir. Ayrıca, beyin hastalıklarının teşhis ve tedavisini iyileştirmek için yeni tekniklerin geliştirilmesine katkıda bulunabilir. Bu çalışma, akıllı teknoloji kullanarak beyin tümörlerini sınıflandırmada parlak bir geleceğe doğru bir adım olarak kabul edilmektedir.

Anahtar Kelimeler: Bilgisayarlı Görü, Derin Öğrenme, Transfer Öğrenmesi, Yapay Zekâ



ABSTRACT**BRAIN TUMOR DETECTION USING NEURAL NETWORKS BY
CLASSIFYING BRAIN MRI IMAGES****ABUSAMRA Ahmed M. A.****Master Thesis, Department of Computer Engineering****Supervisor: Asst. Prof. Dr. Muammer AKÇAY****May, 2024, 91 pages**

The brain, regarded as a vital center for the human body, unfortunately may harbor serious conditions such as brain tumors, making accurate diagnosis of these diseases crucial for enhancing treatment efficacy and survival rates. Artificial intelligence (AI) intervenes at this juncture and can be employed to improve the classification of complex diseases. In this context, Convolutional Neural Networks (CNNs) have generally demonstrated significant success in image classification. CNNs have advanced image processing and comprehension of visual data, enhancing the recognition of patterns and objects within images. These networks employ a series of layers, including convolutional and pooling layers, to progressively extract information from images. Utilizing deep learning techniques, CNNs can recognize intricate patterns and details, classify objects and individuals, detect objects, and distinguish objects within images with high accuracy. Particularly in classifying brain tumors using magnetic resonance imaging (MRI), CNNs have proven effective in accurately classifying and analyzing medical images. This technology can be utilized to extract critical information from images and precisely determine the type and location of tumors, thereby assisting in guiding doctors towards appropriate treatment and improving the treatment success of brain tumor patients. As CNNs' ability to learn patterns and enhance performance becomes fundamental across various fields, continual development and implementation persist for better and more precise comprehension of visual data. In this study, three different artificial neural network models, namely VGG16, EfficientNetB3, and ResNet50, were employed. A large dataset consisting of pre-classified brain tumor MRI images was utilized. This dataset was split into training and testing data to evaluate the models' performance. The results of the study were highly promising, as the EfficientNetB3 model achieved a classification accuracy of 99.21%, demonstrating the potential for this model to distinguish tumors with exceptional precision. Utilizing artificial intelligence in the classification of brain tumors can enhance diagnostic accuracy and aid in directing patients towards the most suitable treatment. Moreover, it can contribute to the

development of new techniques to improve the diagnosis and treatment of brain diseases. This study is considered a step towards a bright future in classifying brain tumors using intelligent technology.

Keywords: Artificial Intelligence, Computer Vision, Deep Learning, Transfer Learning



ÖNSÖZ

Bu çalışmada bana yardımcı olan, tecrübesiyle bana ışık tutan, yüksek lisans tezimde karşılaştığım her engeli ve zorluğu aşmamda bilgi ve birikimlerini cömertçe benimle paylaşan değerli danışmanım Dr. Öğr. Üyesi Muammer AKÇAY'a şükranlarımı sunarım.

Bu tezi, Gazze'nin cesur şehitlerine adıyorum, onların fedakârlıkları daima hatırlanacaktır.

Ayrıca hayatım boyunca maddi, manevi desteği ile hep yanımda olan, aldığım kararlarda beni sürekli destekleyen canım anneme, babama ve kardeşlerime teşekkürlerimi borç bilirim.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
ABSTRACT	vii
TABLolar LİSTESİ	xii
ŞEKİLLER LİSTESİ	xiii
KISALTMALAR	xiv
GİRİŞ	1

BİRİNCİ BÖLÜM

LİTERATÜR ÇALIŞMALARI

1.1. LİTERATÜR TARAMASI	6
-------------------------------	---

İKİNCİ BÖLÜM

GENEL KISIMLAR

2.1. İNSAN BEYNİ	11
2.2. BEYİN TÜMÖRÜ	12
2.3. BEYİN TÜMÖRLERİNDE YAPAY ZEKÂ VE DERİN ÖĞRENMENİN ROLÜ	13
2.4. CNN'LERİN BEYİN TÜMÖRLERİNİN TEDAVİSİNDE KULLANIMI	15

ÜÇÜNCÜ BÖLÜM

MATERYAL VE METOD

3.1. YAPAY ZEKÂ	18
3.2. MAKİNE ÖĞRENME	19
3.3. DERİN ÖĞRENME	20
3.4. YAPAY SİNİR AĞLARI	21
3.5. EVRİŞİMSEL SİNİR AĞLARI	22
3.5.1. Evrişim Katmanı	23
3.5.2. Havuzlama Katmanı	24
3.5.3. Tam Bağlantılı Katman	25
3.6. ÖNERİLEN CNN MODELİ	26
3.6.1. VGG16	26

3.6.2. Resnet50	28
3.6.3. EfficientNetB3	30
3.7. VERİ SETİ	33
3.8. ÖN İŞLEMLER.....	34
3.8.1. Verileri Artırma	35
3.8.2. Veri Boyutunun Değiştirilmesi (Ölçekleme)	36
3.8.3. Görüntü Kodlama	37
3.9. ÇALIŞMA AKIŞ ŞEMASI	38

DÖRDÜNCÜ BÖLÜM

BULGULAR VE TARTIŞMA

4.1. ResNet50 SONUÇLARI	42
4.2. EfficientNetB3 SONUÇLARI	49
4.3. VVG16 SONUÇLARI	57

BEŞİNCİ BÖLÜM

SONUÇ VE ÖNERİLER

5.1. SONUÇ VE ÖNERİLER	66
KAYNAKÇA	70
DİZİN	75

TABLOLAR LİSTESİ

	<u>Sayfa</u>
Tablo 1.1: CNN Modellerinin Fonksiyonel Karşılaştırması	3
Tablo 1.2: Çalışmaları Karşılaştırma	9
Tablo 3.1: Çalışmada Kullanılan Veri Setine Dair Sayısal Veriler	34
Tablo 4.1: Resnet50 Modelinin Mimarisini	44
Tablo 4.2: ResNet50 Modelinin Performans Değerlendirmesi	45
Tablo 4.3: ResNet50 Modeli için Sınıflandırma Raporu	47
Tablo 4.4: EfficientNetB3 Modelinin Mimari Özeti	52
Tablo 4.5: EfficientNetB3 Modelinin Doğruluk Sonuçları	52
Tablo 4.6: EfficientNetB3 Modeli için Sınıflandırma Raporu	55
Tablo 4.7: VGG16 Modelinin Mimari Özeti	59
Tablo 4.8: VGG16 Modelinin Performans Değerlendirmesi	60
Tablo 4.9: VGG16 Modeli için Sınıflandırma Raporu	62
Tablo 5.1: Derin Öğrenme Modellerinin Beyin Tümörü Tanısındaki Doğruluğu	67

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1: İnsan Beyninin Kesit Diyagramı	11
Şekil 3.1: Yapay Zekâ, Makine Öğrenimi, Derin Öğrenme ve CNN Arasındaki İlişkinin Çizilmesi	19
Şekil 3.2: Yapay Sinir Ağı Mimarisi	21
Şekil 3.3: CNN Mimarisi	23
Şekil 3.4: Tam Bağlantılı Katman Yapısı	25
Şekil 3.5: Vgg16 Model Mimarisi	27
Şekil 3.6: ResNet50 Model Mimarisi	29
Şekil 3.7: EfficientNetB3 Model Mimarisi	31
Şekil 3.8: Çalışmada Kullanılan Rastgele Bir Dizi Mr Verisi	33
Şekil 3.9: Çalışma Akış Şeması	39
Şekil 4.1: ResNet50 Modeli Katmanları ve Parametreleri	42
Şekil 4.2: ResNet50 Modeli için Karışıklık Matrisi	46
Şekil 4.3: ResNet50 Modelinin Eğitim Kaybı ve Doğruluk Eğrisi	48
Şekil 4.4: EfficientNetB3 Modeli Katmanları Ve Parametreleri	49
Şekil 4.5: EfficientNetB3 Modeli için Karışıklık Matrisi	54
Şekil 4.6: EfficientNetB3 Modelinin Eğitim Kaybı ve Doğruluk Eğrisi	56
Şekil 4.7: VVG16 Modeli Katmanları ve Parametreleri	57
Şekil 4.8: VGG16 Modeli için Karışıklık Matrisi	61
Şekil 4.9: VGG16 Modelinin Eğitim Kaybı ve Doğruluk Eğrisi	63
Şekil 5.1: Derin Öğrenme Modellerinin Beyin Tümörü Tanısındaki Doğruluğu	67

KISALTMALAR

BCI	Beyin-Bilgisayar Arayüzleri (Brain-Computer Interfaces)
CNN	Evrişimli Sinir Ağları (Convolutional Neural Networks)
CSP	Ortak Mekansal Model (Common Spatial Pattern)
CVM	Çapraz doğrulama yöntemi (Cross-validation method)
CWT	Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)
DFT	Ayrık Fourier Dönüşümü (Discrete Fourier Transform)
DL	Derin Öğrenme (Deep Learning)
KNN	k-en yakın komşular (k-nearest neighbors)
LSTM	Uzun Kısa Süreli Bellek (Long Short Term Memory)
LTM	Uzun vadeli izleme (Long-term monitoring)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
ML	Makine Öğrenimi (Machine Learning)
MSE	Ortalama Karesel Hata (Mean Squared Error)
PET	Pozitron Emisyon Tomografisi (Positron Emission Tomography)
PSD	Güç Spektral Yoğunluğunu (Power Spectral Density)
RNN	Tekrarlayan Sinir Ağları (Recurrent Neural Networks)
ROC	Alıcı Çalışma Karakteristiği (Receiver Operating Characteristic)
STFT	Kısa Süreli Fourier Dönüşümü (Short-Time Fourier Transform)
SVM	Destek Vektör Makineleri (Support Vector Machines)
TMS	Transkraniyal Manyetik Stimülasyon (Transcranial Magnetic Stimulation)
YSA	Yapay Sinir Ağları (Artificial Neural Networks)
YZ	Yapay Zekâ (Artificial Intelligence)



TEZ METNİ

GİRİŞ

Beyin tümörleri, karmaşıklıkları ve çeşitlilikleri nedeniyle, sürekli araştırma ve ileri tıbbi teknolojiler gerektirmesi nedeniyle önemli bir tıbbi zorluk teşkil etmektedir. İyi huylu veya kötü huylu olabilirler ve beyindeki anormal hücre büyümesinden kaynaklanabilirler. Çeşitliliklerinden dolayı tümörlerin tipi ve semptomları beyindeki lokasyonlarına bağlıdır. Beyin tümörlerinin teşhisi karmaşıktır ve belirtileri diğer hastalıkların belirtilerine benzeyebileceğinden erken teşhis zordur (Badr et al., 2020).

Teşhis, manyetik rezonans görüntüleme (MRI) ve manyetik rezonans spektroskopisi (MRS) gibi ileri tekniklerin yanı sıra tümörün tipini ve doğasını belirlemek için hassas testleri içerir. Bu alandaki araştırma zorlukları tıbbi ilerlemenin hayati bir parçası olmaya devam ediyor. Bilim insanları ve doktorlar, beyin tümörlerinin nedenlerini daha iyi anlamak, erken teşhis için etkili teknikler geliştirmek ve tedavi süreçlerini iyileştirmek için çalışıyor (Kumar, 2023).

Bu nedenle, beyin tümörleri yalnızca tıbbi bir sorunu değil, aynı zamanda tanı ve tedaviyi geliştirmek için sürekli araştırma ve işbirlikçi çabalar gerektiren bir alanı da temsil etmektedir. Bu çabalar hastalara destek sağlamaya ve yaşam kalitelerini iyileştirmeye odaklanmalıdır. Beyin tümörleri iyi huylu ve kötü huylu olmak üzere iki ana gruba ayrılır. İyi huylu beyin tümörleri her ne kadar sağlık sorunlarına yol açsa da kanserli değilken, kötü huylu beyin tümörleri düzensiz hücre büyümesi nedeniyle daha büyük tehdit oluşturuyor. Dünya Sağlık Örgütü'ne (WHO) göre yılda 100.000 kişi başına 6-12 beyin tümörü vakası görülüyor (Miller vd., 2021).

İyi huylu ve kötü huylu beyin tümörleri arasındaki bu ayrım, tanı ve tedavi süreçlerini etkilemektedir. Çoğunlukla sinir hücrelerinden oluşan kötü huylu beyin tümörleri, hızla büyüyen ve çevre dokulara yayılan en tehlikeli türlerdir (Wong & Wu, 2020).

Beyin hücrelerini destekleyen hücrelerden oluşan gliomalar en sık görülen türler arasındadır. İyi huylu beyin tümörleri ise daha az tehlikelidir, yavaş büyürler ve çevre dokulara yayılmazlar. Beyni çevreleyen zarlardan oluşan meningiomlar ve hipofiz bezinden kaynaklanan hipofiz tümörleri en sık görülen türler arasındadır. Sinir hücrelerinden oluşmaları ve hızla yayılmaları ile karakterize edilen glioma gibi kötü huylu beyin tümörleri en yaygın ve tehlikeli türlerdir. Tersine, menenjiyomlar ve hipofiz tümörleri gibi iyi huylu beyin tümörleri genellikle kanserli değildir, yavaş büyür ve

sıklıkla ameliyatla etkili bir şekilde çıkarılabilir. Bu çeşitlilik, erken tanının ve her vakanın ihtiyaçlarını karşılayacak en uygun tedavinin seçilmesinin önemini vurgulamaktadır (Kocher vd., 2020).

Yapay Zekâ (AI), makinelerin insan zekâsı gibi akıl yürütme, öğrenme ve problem çözme yeteneğine sahip olması fikrini içerir. Hem akademik hem de endüstriyel araştırmalarda hızla gelişen bir alandır ve çeşitli uygulamalarda kullanılmaktadır. Derin öğrenme, makine öğrenimi algoritmalarının bir alt alanıdır ve bu algoritmalar, insan beyninin işleyişini taklit eden yapay sinir ağlarını kullanır (Zhang & Lu, 2021). Derin öğrenme algoritmaları, büyük miktarda veriden öğrenerek karmaşık görevleri yerine getirebilir. Son yıllarda yapay zekâ alanındaki en önemli gelişmelerden biri olan derin öğrenme, birçok farklı alanda uygulanabilir hale gelmiştir (Sejnowski, 2020).

Veri seti, gliyoma, menenjiyom, tümör yok ve hipofiz olmak üzere dört farklı sınıfa ayrılmış toplam 7023 insan beyin MRG görüntüsünü içeren üç veri setinin bir kombinasyonunu içerir. Bu görüntüler, tümör varlığı veya yokluğuna göre ilgili sınıflara ayrılmıştır; gliyoma, menenjiyom ve hipofiz belirli tümör tiplerini temsil ederken "tümör yok" sınıfı tümörsüz beyinleri gösteren görüntüleri ifade eder (Masoud Nickparvar, 2021).

Evrişimli Sinir Ağları (CNN'ler), derin öğrenme alanında etkin bir rol oynayan ve özellikle görüntü işleme ile tanıma alanlarında başarıyla uygulanan bir yapay sinir ağı türüdür. Bu tür ağlar, biyolojik görme sistemini taklit etmek amacıyla tasarlanmıştır ve veri içindeki desenleri tanımlamak ve çıkarmak için kullanılırlar. CNN'lerin temel yapısı, giriş verilerinden hiyerarşik ve öğrenilmiş özelliklerin elde edilmesini sağlayan evrişim ve havuzlama katmanlarından oluşur. Evrişim katmanları, verideki özellikleri tanımlamak için filtrelerle uygulanırken, havuzlama katmanları özellik haritalarını küçültmek ve hesaplama yükünü azaltmak amacıyla kullanılır (Lindsay, 2021). CNN'lerin öne çıkan avantajlarından biri, özelliklerin manuel olarak belirlenmesi yerine, eğitim verisi üzerinden otomatik olarak öğrenilmesidir. Ayrıca, genellikle CNN'lerin katmanlarının derinleştikçe ve karmaşıklık arttıkça performanslarını iyileştirdiği gözlemlenmektedir. CNN algoritmalarının çeşitli türevleri, temel CNN mimarisini değiştirerek veya geliştirerek farklı uygulama alanlarına uyum sağlarlar. Bu türevler arasında LeNet, AlexNet, VGG, GoogLeNet, ResNet gibi birçok örnek bulunmaktadır (Alzubaidi vd., 2021).

Derin öğrenme, görüntü işleme ve nesne tanıma gibi alanlarda belirgin bir etkiye sahiptir. CNN gibi derin öğrenme modelleri, bu alanlarda yaygın olarak kullanılan bir türdür. CNN'lerin farklı türleri, çeşitli özelliklere ve işlevlere sahiptir. Bu karşılaştırma, işlevsel bir bakış açısıyla bazı önemli CNN türlerini ele almaktadır.

Tablo 1.1: CNN Modellerinin Fonksiyonel Karşılaştırması

Model	Fonksiyonel Özellikler	Avantajlar	Sınırlamalar
LeNet	Basit ve kompakt yapı	Kolay uygulama	Karmaşık Görüntülerle Sınırlı Performans
AlexNet	Derin ve güçlü mimari	Yüksek doğruluk	Yoğun Hesaplama
VGG16	Basit ve etkili	Kolay eğitim	Çok Derin, Performans Düşüşüne Neden Olabilir
GoogLeNet	Karmaşık ve yenilikçi Inception modülü	Yüksek verimlilik ve azaltılmış parametre sayısı	Karmaşık Yapı, Eğitimi Zorlaştırabilir
ResNet50	Kalan bağlantıların kullanımı	Performans düşüşünü önler	Karmaşık Yapı
EfficientNetB3	Mobil cihazlar için optimize edilmiş	Hafif ve hızlı	Yeni Yapı, Daha Fazla Araştırma Gerektirebilir

CNN modellerinin özellikleri, avantajları ve dezavantajları farklılık gösterir, bu da farklı uygulamalara uygun olmalarını sağlar. LeNet modeli, basit bir yapıya ve kolay uygulanabilirliğe sahiptir, bu da küçük veri kümeleri ve sınırlı hesaplama kaynakları için uygundur. Diğer yandan, AlexNet derin ve güçlü bir yapıya sahiptir, bu da yüksek doğruluk sağlar, ancak yoğun hesaplama gereksinimleri ve büyük veri miktarları gerektirir.

VGG, basit ve etkili yapısı sayesinde kolay eğitim sağlar, ancak derin yapısı performansın bozulmasına neden olabilir. GoogLeNet yüksek verimlilik ve düşük parametre sayısı ile öne çıkar, ancak karmaşık bir yapıya ve eğitim zorluklarına sahiptir.

ResNet, kalıntı bağlantıları kullanarak performansın bozulmasını önler, bu da derin yapılar için yüksek doğruluk sağlar, ancak karmaşık ve zorlu eğitim gerektirir. Öte yandan, EfficientNet, taşınabilir cihazlar için özel olarak tasarlanmıştır ve hafif ve hızlı bir yapı sunar, ancak daha fazla araştırma gerektirir ve karmaşık bir yapıya sahiptir.

Bu çeşitlilik, uygun CNN modelinin seçiminin veri türüne, veri boyutuna, performans gereksinimlerine ve mevcut hesaplama kaynaklarına bağlı olduğunu göstermektedir.

Tüm uygulamalar için mükemmel bir CNN modeli bulunmamaktadır. Her modelin özelliklerini, avantajlarını ve dezavantajlarını anlamak, ihtiyaçlarınıza uygun model seçmek için önemlidir.

Bu çalışma, beyin MR görüntülerinde tümörleri tespit etmek için derin öğrenme algoritmalarının kullanıldığı bir sınıflandırma işlemini gerçekleştirmiştir. Üç farklı derin sinir ağı (CNN) modeli tercih edilmiştir: VGG16, EfficientNetB3 ve ResNet50. ResNet50, artan ağ derinliğiyle performans düşüşü sorununu ele alma yeteneği nedeniyle seçilmiştir. EfficientNetB3 ise yüksek hesaplama verimliliği ve mükemmel performansı ile tercih edilmiştir. VGG16 ise basitliği ve görsel özelliklerden etkin bir şekilde bilgi çıkarma yeteneği nedeniyle seçilmiştir. Bu çalışmada, EfficientNetB3 modeli en yüksek doğruluk oranını (%99.21) elde etmiş ve VGG16 ile ResNet50'yi geride bırakmıştır. Bu sonuç, EfficientNetB3'ün hesaplama kaynaklarını verimli bir şekilde kullanma yeteneği, model doğruluğu ile hesaplama verimliliği arasında denge kurmak için kullandığı Compound Scaling teknolojisi ve verilerdeki ayırt edici özellikleri daha iyi öğrenme yeteneğiyle bağlantılıdır. Bu çalışmanın sonuçları, derin öğrenme tekniklerinin beyin tümörlerini yüksek doğrulukla sınıflandırma potansiyelini vurgulamaktadır. Bu da beyin tümörlerinin teşhis ve tedavisinde önemli gelişmelere yol açabileceklerini göstermektedir.



BİRİNCİ BÖLÜM
LİTERATÜR ÇALIŞMALARI

1.1. LİTERATÜR TARAMASI

Erçelik, Ç. ve Hanbay, K. (2023), "Beyin Tümörü Sınıflandırmada Histogram Eşitleme Yönteminin Bazı Derin Öğrenme Modellerine Etkileri"de. 3590 MR görüntüsü içeren bir veri seti üzerinde yaptıkları çalışmada, VGG16, VGG19 ve MobileNet mimarilerini karşılaştırmışlardır. Histogram eşitleme işlemini uyguladıktan sonra, MobileNet mimarisinin en yüksek doğruluk oranını elde ettiğini bulmuşlardır. Bu sonuç, histogram eşitleme işleminin görüntülerin kalitesini iyileştirerek derin öğrenme mimarilerinin performanslarını artırabileceğini göstermektedir (Erçelik, Ç., & Hanbay, 2023).

Doğanalp (2022), farklı sekans MR görüntüleri kullanılarak beyin tümörlerinin sınıflandırılması için derin öğrenme modellerini araştırmıştır. BRATS 2019 veri seti üzerinde yaptığı çalışmada, AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve InceptionV3 mimarilerini karşılaştırmıştır. Araştırma sonucunda, AlexNet modelinin FLAIR modalitesinde, InceptionV3 modelinin ise 4 sınıf çıkışlı sınıflandırmada en yüksek performansı gösterdiği bulunmuştur. AlexNet modeli, 3 sınıf çıkışlı sınıflandırmada da iyi bir performans göstermiştir. 12 sınıf çıkışlı sınıflandırmada ise AlexNet modeli, tüm performans kriterlerinde en yüksek değerleri elde etmiştir (Doğanalp, 2022).

Mahmoud ve diğerleri (2023), tıbbi görüntülemelerde doğru beyin tümörü sınıflandırması için derin öğrenmenin kullanılmasını araştırdı. Aquila Optimizer ile CNN modellerini (VGG-16, VGG-19, Inception-V3) eğittiler ve glioma, meningeoma ve hipofiz gibi üç yaygın tümörü ayırt etmek için kullandılar. Doğruluk odaklı olarak, VGG-19 modeli ile %98.95 başarısına ulaştılar ve tümör tespitini otomatikleştirmeyi ve doğru teşhisi desteklemeyi hedefleyerek, yanlış teşhisleri ve insan hatasını potansiyel olarak azaltmaya çalıştılar (Mahmoud vd., 2023).

Sadad ve diğerleri (2021), gelişmiş derin öğrenme tekniklerini kullanarak beyin tümörü tespiti ve çok sınıflandırmayla ilgilendi. U-Net segmentasyonu ile ResNet50 ve evrimsel algoritmalar ve güçlendirme öğrenme ile transfer öğrenme gibi çeşitli yaklaşımları karşılaştırdılar. MobileNet V2, Inception V3 ve ResNet50 gibi farklı CNN modelleri yüksek doğruluklar elde etti (91.8% - 93.1%), ancak NASNet etkileyici bir %99.6 doğrulukla şampiyon olarak ortaya çıktı. Bu araştırma, otomatik, yüksek hassasiyetli beyin tümörü teşhisi için gelişmiş derin öğrenmenin potansiyelini

sergileyerek, erken teşhisi artırma ve hasta sonuçlarını iyileştirme konusundaki potansiyeli gösteriyor (Sadad vd., 2021).

Ahmad ve Choudhury (2022), MR görüntülerinden beyin tümörü tespiti için derin transfer öğrenme ağlarının performansını araştırdı. VGG16, ResNet50 ve DenseNet201 gibi önceden eğitilmiş 7 CNN mimarisi ile birlikte geleneksel sınıflandırıcıların (SVM, Rastgele Orman) kullanımını incelediler. Normal ve anormal beyin MR görüntülerinden oluşan bir veri seti üzerinde gerçekleştirilen deneylerde en iyi model %99.39 doğruluk elde etti. Araştırma, beyin tümörü tespiti için derin transfer öğrenmenin potansiyelini ve uygun yöntem seçimi açısından önemini vurgulayarak erken teşhis ve hasta bakımı açısından umut vadediyor (Ahmad ve Choudhury, 2022).

Maram ve Rana (2021) beyin tümörü tespiti için hızlı ve doğru bir yöntem geliştirmeyi amaçladılar. MICCAI BraTS2020 challenge kapsamında bulunan BraTS2020 veri setinden MR görüntüleri kullanarak, U-Net mimarisini özelleştirerek %98,485 eğitim doğruluğu elde ettiler. Bu sonuç, BraTS2020 veri setindeki diğer mimarilerle karşılaştırıldığında daha iyi performans gösterdiğini ortaya koydu. Bu çalışma, U-Net'in beyin tümörü tespiti için yüksek potansiyele sahip olduğunu ve özelleştirmelerle daha da iyileştirilebileceğini göstermektedir (Maram ve Rana, 2021).

Sachdeva ve Kushwaha (2023), makalede kanserli tümörlerin erken teşhisine yardımcı olabilecek akıllı sınıflandırma sistemleri için derin öğrenmenin potansiyelini incelemektedir. Çalışma, vücudun farklı bölgelerindeki tümörlerin sınıflandırılmasında derin öğrenme kullanan son araştırmaları kapsamlı bir şekilde analiz etmektedir. Araştırma soruları çerçevelenerek ve literatür incelenerek cevapların bulunması hedeflenmektedir. Makale, makine öğreniminin ve derin öğrenimin kavramlarını açıkladıktan sonra, mevcut çalışmaların güçlü ve zayıf yönlerini vurgulamaktadır. Ayrıca öncü çalışmaların kullandığı yaklaşımlar, yöntemler, veri setleri ve performans ölçütleri ile ilgili nitel ve nicel karşılaştırmalar sunmaktadır. Son olarak, araştırmacıların karşılaştığı zorlukları özetleyen çalışma, tümör sınıflandırması için gelecekte derin öğrenme tekniklerinin uygulanmasına ilişkin önerilerde bulunmaktadır (Sachdeva ve Kushwaha, 2023).

Sowjanya ve Kumar (2021), beyin tümörlerini tespit ve sınıflandırmak için önceden eğitilmiş VGG-16 CNN mimarisini kullanarak transfer öğrenme yönteminin etkinliğini araştırdı. Figshare veri setinden temin edilen menenjioma, glioma ve pitüiter

tümörü olmak üzere üç farklı türden MRI görüntüleri üzerinde yaptıkları çalışmalarında, tümör tespiti için %92, tespit edilen tümörlerin sınıflandırılması için ise %98.66 (menenjioma), %98.53 (glioma) ve %99.54 (pitüiter) doğruluk elde etti. Bu sonuçlar, transfer öğrenmenin beyin tümörlerinin hassas tespit ve sınıflandırması için umut vadettiğini göstermektedir (Sowjanya ve Kumar, 2021).

Kumar ve ark. (2023), beyin tümörlerinin tespiti için son derece hassas ve etkili yöntemler geliştirmek için derin öğrenme (DL) ve makine öğrenimi (ML) yöntemlerinin sistematik bir şekilde incelenmesini sağladı. Sistematik inceleme, 36 makaleyi inceledi ve farklı yaklaşımların ve yöntemlerin güçlü ve zayıf yönlerini vurguladı. Araştırmacılar, DL ve ML yöntemlerinin birleştirilmesinin, erken teşhis ve tedavi için daha doğru ve etkili bir yaklaşım sağlayabileceğini buldu (Kumar vd., 2023).

Arefin ve diğerleri (2023), derin öğrenme kullanarak MRI görüntülerinde beyin tümörü tespiti ve lokalizasyonu ile ilgilendi. İki yaklaşımı karşılaştırdılar: ResNet-50 ve InceptionV3 ile tümörleri sınıflandırmak ve U-Net'in ya ResNet-50 ya da InceptionV3 ile eşleştirilerek tümörleri segmente etmek. Önerdikleri U-Net ile ResNet-50, etkileyici bir %99.77 doğruluk elde ederek, hem bireysel sınıflandırıcılardan hem de U-Net ile InceptionV3'ten (%99.55) daha başarılı oldu. Bu araştırma, doğru ve otomatik beyin tümörü teşhisi için derin öğrenmenin potansiyelini vurgulayarak, erken teşhis ve hasta sonuçlarını iyileştirmeye yardımcı oluyor (Arefin vd., 2023).

Al-Zoghby ve diğerleri (2023), beyin tümörü sınıflandırması için devrim niteliğinde bir yapay zekâ sistemi geliştirdi ve neredeyse mükemmel bir doğruluk elde etti. Dual Deep CNN (DCTN) modeli, VGG-16 ve özel CNN mimarilerinden oluşan bir yapıya sahipti ve MRI görüntülerinde meningiomaları, gliomaları ve hipofiz tümörlerini %100 eğitim ve %99 test doğruluğuyla sınıflandırdı, mevcut yöntemleri aşarak. Bu kendi öğrenen, güçlü derin öğrenme yaklaşımı, manuel teşhise göre önemli bir zaman tasarrufu avantajı sunar ve hayat kurtarmak ve muhtemelen diğer hastalık sınıflandırmalarına adapte edilmek için sağlık sektörünü devrimleştirmek için potansiyele sahiptir (Al-Zoghby vd., 2023).

ZainEldin ve diğerleri (2022), beyin tümörü tespiti ve sınıflandırmasıyla ilgilenen, yeni bir algoritma tarafından optimize edilmiş bir derin öğrenme modeli geliştirdi. Önceden eğitilmiş bir CNN mimarisi (Inception-ResNetV2) ile adaptif bir optimizasyon algoritması (ADSCFGWO) birleştirilerek, BraTS 2021 veri setinde

etkileyici bir %99.98 doğruluk elde ettiler. Bu çalışma, derin öğrenmenin, geleneksel yöntemlere kıyasla daha hızlı ve daha doğru beyin tümörü teşhisi için potansiyelini sergileyerek, hasta sonuçlarını iyileştirme ve sağlık maliyetlerini azaltma potansiyelini gösteriyor (ZainEldin vd., 2022).

Tablo 1.2: Çalışmaları Karşılaştırma

Yazar	Yıl	Modeller	En İyi
Ahmad	2022	VGG16, ResNet50, DenseNet201, DVM ve Rastgele Orman	VGG-16
Al-Zoghby	2023	VGG-16	VGG-16
Arefin	2023	ResNet-50 ve InceptionV3	ResNet-50
Doğanalp	2022	AlexNet, GoogleNet, ShuffleNet, SqueezeNet InceptionV3	AlexNet
Erçelik	2023	VGG16, VGG19 ve MobileNet	MobileNet
Mahmoud	2023	VGG-16, VGG-19, Inception-V3	VGG-19
Maram	2021	U-Net	U-Net
Sadad	2021	NASNet, MobileNet V2, Inception V3 ve ResNet50	NASNet
Sowjanya	2021	VGG-16	VGG-16
ZainEldin	2022	Inception, ResNetV2 ve ADSCFGWO	ADSCFGWO

Tablo 1.2, tezin literatür taraması bölümünde yer alan farklı yazarların çalışmalarının bir karşılaştırmasını sunmaktadır. Tabloda, her yazarın çalışmasının yayın yılı, kullanılan model ve elde edilen en iyi sonuç gösterilmektedir.

Karşılaştırma ve Sonuç:

Tablodaki bilgiler ışığında, aşağıdaki karşılaştırmalar ve sonuçlar çıkarılabilir:

- Kullanılan Modeller: Farklı yazarlar, VGG16, ResNet50, Inception V3 gibi yaygın olarak kullanılan modelleri kullanmışlardır. Ayrıca, NASNet ve ADSCFGWO gibi daha az bilinen modeller de kullanılmıştır.
- En İyi Sonuçlar: En iyi sonuçları elde eden model, ADSCFGWO modelidir. Ancak, bu modelin sadece bir çalışmada kullanılmış olması ve diğer modellerle yeterince karşılaştırılmamış olması önemlidir.
- Genel Değerlendirme: Tablodaki bilgiler, farklı yazarların çalışmalarının bir karşılaştırmasını sunmakta ve farklı modellerin performansı hakkında bilgi vermektedir. Ancak, kesin bir sonuca varmak için daha fazla araştırmaya ihtiyaç vardır.




İKİNCİ BÖLÜM
GENEL KISIMLAR

2.1. İNSAN BEYNI

İnsan beyni, insan vücudundaki en karmaşık ve şaşırtıcı organlardan biri olarak kabul edilir, çünkü tüm vücut fonksiyonları ve zihin üzerinde kontrol merkezi olarak kabul edilir. Beyin, düşünme, hareket etme, hafıza, duyarlar ve duygular gibi çeşitli görevleri yerine getirmek için bir arada çalışan milyarlarca sinir hücresinden oluşur. Beyin, ön, yan, kabuk, beyincik ve omurilik gibi çeşitli ana bölmelere ayrılır. Bu bölümlerin her biri, insanın yaşamını düzenlemesine ve dış dünya ile etkileşimine katkıda bulunan belirli görevleri yerine getirir. Beyindeki sinir hücrelerinin etkileşimi ve iletişimi, derin düşünme ve çalışma gerektiren karmaşık ve şaşırtıcı bir süreçtir, böylece tamamen anlaşılabilir.

Bunun yanı sıra, beyin anatomisinin kesitsel görüntülerinden faydalanarak yapısını daha iyi anlamak ve içindeki farklı bölümlerin etkileşimini görmek mümkündür. Bu görüntüler, beyin iç yapısını gösterir ve sinir hücreleri arasındaki muhteşem ağı gösterir ve düşünme, hareket kontrolü ve diğer yaşamsal fonksiyonların düzenlenmesine katkıda bulunur. Şekil 2.1'de insan beyninin kesitsel bir diyagramı gösterilmektedir.

Şekil 2.1: İnsan Beyninin Kesit Diyagramı



Beynin anatomik görüntüleri sayesinde, bu hayati organın iç yapısının ve derin bileşiminin ince ayrıntılarını keşfedebiliriz. Bu şaşırtıcı güzellikteki görüntüler, beyni oluşturan sinir ağını ve dokuyu vurgulayarak bu organı karakterize eden olağanüstü karmaşıklığı ve organizasyonu yansıtıyor.

Buna ek olarak, fonksiyonel MR gibi fonksiyonel görüntüleme teknikleri, belirli görevleri yerine getirirken beyin aktivitesini izlemek için kullanılabilir, bu da beyin farklı zorluklar ve görevler karşısında nasıl çalıştığını anlamaya yardımcı olur. Bununla birlikte, MR görüntülerinin önemi sadece beyin işleyişini anlamakla sınırlı olmayıp, yapay zekâ kullanarak beyin tümörlerini sınıflandırmak gibi modern teknolojileri kullanarak hastalıkları tespit ve teşhis etme alanına da uzanmaktadır. MR görüntüleri, nörolojik hastalıkların doğru ve etkili bir şekilde tanımlanması ve teşhis edilmesinde ve tümörlerin ortadan kaldırılmasında çok önemli bir rol oynamaktadır. Bu gelişmiş teknolojiler, tedavi olanaklarının ve hasta bakımının iyileştirilmesine yardımcı olarak genel olarak sağlık hizmetlerinin kalitesinin artmasına yol açmaktadır.

Bu araçlar, bilim insanları ve doktorların beyni etkileyen çeşitli hastalıkları anlamaları ve beyin fonksiyonlarını iyileştirmeyi ve ilgili sağlık sorunlarını tedavi etmeyi amaçlayan tedaviler ve tıbbi teknolojiler geliştirmeleri için değerlidir.

2.2. BEYİN TÜMÖRÜ

Beyin tümörü, beyinde bulunan hücrelerin kontrolsüz çoğalmasıyla oluşan bir hastalıktır. Beyin tümörleri, iyi huylu (benign) veya kötü huylu (malignant) olarak sınıflandırılır. İyi huylu beyin tümörleri, vücudun diğer bölgelerine yayılmaz ve genellikle yavaş büyür. Kötü huylu beyin tümörleri ise vücudun diğer bölgelerine yayılabilir ve hızlı büyür (Boutry vd., 2022).

Beyin tümörlerinin belirtileri, tümörün büyüklüğüne, yerine ve tipine göre değişebilir. En sık görülen belirtiler şunlardır:

- Baş ağrısı
- Bulantı ve kusma
- Görme bozuklukları
- Denge ve yürüme bozuklukları
- Konuşma bozuklukları
- Nöbetler

Beyin tümörleri, genellikle beyin görüntüleme yöntemleriyle (MR, BT) teşhis edilir. Teşhis konulduktan sonra, tümörün tipine ve evresine göre tedavi planı yapılır (Gesaka vd., 2024).

Beyin tümörlerinin tedavisi, cerrahi, radyoterapi ve kemoterapiyi içerebilir. Cerrahi, tümörün tamamen veya kısmen çıkarılmasını amaçlar. Radyoterapi, tümör hücrelerini öldürmek için yüksek enerjili ışınların kullanıldığı bir tedavi yöntemidir. Kemoterapi, tümör hücrelerini öldürmek için ilaçların kullanıldığı bir tedavi yöntemidir.

Beyin tümörlerinin tedavisinde, hastanın yaşına, genel sağlık durumuna ve tümörün özelliklerine göre en uygun tedavi yöntemi seçilir (Bent vd., 2023).

Beyin Tümörlerinin Sıklığı

Beyin tümörleri, tüm kanserlerin %2-3'ünü oluşturur. Her yıl dünyada yaklaşık 200.000 yeni beyin tümörü vakası görülmektedir. Beyin tümörleri, her yaşta görülebilen bir hastalıktır, ancak en sık 45-65 yaş arasında görülür (Miller vd., 2021).

Beyin Tümörlerinin Nedenleri

Beyin tümörlerinin kesin nedeni bilinmemektedir. Ancak, aşağıdaki faktörlerin beyin tümörü riskini artırabileceği düşünülmektedir:

- Radyasyona maruz kalma
- Bazı kalıtsal hastalıklar
- Bazı kimyasallara maruz kalma
- Bazı virüsler

Beyin Tümörlerinin Önlenmesi

Beyin tümörlerinin önlenmesi için kesin bir yol yoktur. Ancak, yukarıda bahsedilen risk faktörlerinden kaçınmak, beyin tümörü riskini azaltmaya yardımcı olabilir (Badr et al., 2020).

Beyin Tümörlerinin Geleceği

Beyin tümörlerinin tedavisinde, son yıllarda önemli gelişmeler kaydedilmiştir. Yeni tedavi yöntemlerinin geliştirilmesi ile beyin tümörü hastalarının yaşam süreleri ve yaşam kaliteleri artmaktadır (Badža ve Barjaktarović, 2020).

2.3. BEYİN TÜMÖRLERİNDE YAPAY ZEKÂ VE DERİN ÖĞRENMENİN ROLÜ

Beyin tümörlerinin erken ve doğru teşhisi, etkili bir tedavi için oldukça önemlidir. Beyin tümörlerinin teşhisinde, genellikle manyetik rezonans görüntüleme (MRG) ve bilgisayarlı tomografi (BT) gibi görüntüleme yöntemleri kullanılır. Ancak, bu

yöntemler bazen tümörleri yanlış veya eksik teşhis edebilir w

Yapay zekâ ve derin öğrenme, beyin tümörlerinin teşhisinde ve tedavisinde önemli bir rol oynama potansiyeline sahiptir. Yapay zekâ, bilgisayarların insan benzeri düşünme ve öğrenme yeteneğine sahip olmasını sağlayan bir teknolojidir. Derin öğrenme ise yapay zekânın bir alt alanı olup, bilgisayarların insan beyni gibi öğrenmesini sağlayan bir tekniktir (Karakaya et al., n.d.).

Yapay zekâ ve derin öğrenme, beyin tümörlerinin teşhisinde aşağıdaki şekillerde kullanılabilir:

- MRG ve BT görüntülerinin analizinde: Yapay zekâ ve derin öğrenme, MRG ve BT görüntülerini analiz ederek tümörleri daha doğru bir şekilde tespit edebilir.
- Yeni teşhis yöntemlerinin geliştirilmesinde: Yapay zekâ ve derin öğrenme, beyin tümörlerinin teşhisinde daha etkili olan yeni görüntüleme yöntemlerinin geliştirilmesine yardımcı olabilir (Yenikaya ve Oktaysoz, 2023).

Yapay zekâ ve derin öğrenme, beyin tümörlerinin tedavisinde aşağıdaki şekillerde kullanılabilir:

- Tedavi planlamasında: Yapay zekâ ve derin öğrenme, beyin tümörlerinin özelliklerine göre en uygun tedavi planının oluşturulmasına yardımcı olabilir.
- Tedavi sürecinin izlenmesinde: Yapay zekâ ve derin öğrenme, beyin tümörlerinin tedavisinin etkinliğini ve yan etkilerini izlemeye yardımcı olabilir.

Yapay zekâ ve derin öğrenme, beyin tümörlerinin teşhisinde ve tedavisinde önemli bir potansiyele sahiptir. Bu teknolojilerin geliştirilmesiyle, beyin tümörlerinin erken ve doğru teşhisi ve daha etkili tedavisi mümkün hale gelebilir (Yenikaya ve Oktaysoz, 2023).

CNN'nin Beyin Tümörlerinde Kullanımı

Konvolüsyonel sinir ağları (CNN), görüntü işleme ve makine öğrenimi alanında yaygın olarak kullanılan bir yapay zekâ tekniğidir. CNN'ler, görüntülerdeki benzerlikleri tespit etmek için tasarlanmıştır (Alzubaidi et al., 2021).

CNN'ler, beyin tümörlerinin teşhisinde aşağıdaki şekillerde kullanılabilir:

- MRG ve BT görüntülerinin analizinde: CNN'ler, MRG ve BT görüntülerini analiz ederek tümörleri daha doğru bir şekilde tespit edebilir. CNN'ler, görüntülerdeki doku özelliklerini ve şekillerini analiz ederek

tümörleri çevreleyen dokulardan ayırt edebilir (Badža ve Barjaktarović, 2020).

- Yeni teşhis yöntemlerinin geliştirilmesinde: CNN'ler, beyin tümörlerinin teşhisinde daha etkili olan yeni görüntüleme yöntemlerinin geliştirilmesine yardımcı olabilir. Örneğin, CNN'ler, tümörleri daha iyi tespit etmek için yeni sinyal işleme tekniklerinin geliştirilmesine yardımcı olabilir (Ayadi et al., 2021).

CNN'lerin Beyin Tümörlerinin Teşhisinde Etkinliği

CNN'lerin beyin tümörlerinin teşhisinde etkinliği, yapılan çalışmalarda gösterilmiştir. Örneğin, bir çalışmada, CNN'ler MRG görüntülerini kullanarak beyin tümörlerini %95 doğrulukla tespit edebilmiştir. Bu doğruluk oranı, insan radyologlarının doğruluk oranından daha yüksektir (Alzubaidi et al., 2021).

Genel olarak, CNN'ler, beyin tümörlerinin teşhisinde ve tedavisinde önemli bir rol oynama potansiyeline sahiptir. CNN'lerin geliştirilmesi ile, beyin tümörlerinin erken ve doğru teşhisi ve daha etkili tedavisi mümkün hale gelebilir (Alzubaidi et al., 2021).

2.4. CNN'LERİN BEYİN TÜMÖRLERİNİN TEDAVİSİNDE KULLANIMI

Evrişimli yapay sinir ağları (CNN'ler), beynin tıbbi görüntülerini analiz ederek ve tümörleri daha doğru bir şekilde teşhis ederek beyin tümörlerini tedavi etmek için kullanılabilir. CNN, görüntüleri analiz etmek, tümörlerin şeklini belirlemek ve sağlıklı doku ile tümörden etkilenen dokuyu ayırt etmek için makine öğrenimi ve yapay zekâdan yararlanıyor.

CNN'i kullanarak beyin tümörlerinin teşhisini iyileştirmek ve boyutlarını ve türlerini doğru bir şekilde belirlemek mümkündür; bu da uygun ve etkili bir tedavi planının geliştirilmesine yardımcı olur. Ayrıca CNN, tümör rezeksiyonu operasyonları sırasında cerrahlara rehberlik ederek tümörün çevredeki sağlıklı dokuyu etkilemeden tamamen ve doğru bir şekilde çıkarılmasını sağlamak için kullanılabilir.

Öğrenme sistemi, CNN'i kullanarak önceki deneyimlerden öğrenebilir ve tıbbi görüntülerin analizini sürekli olarak iyileştirerek, farklı beyin tümörü türleri arasındaki teşhis ve ayrımcılığın doğruluğunu artırabilir. Ayrıca öğrenme sistemi, tıbbi görüntülerdeki değişikliklere uyum sağlayabiliyor ve nadir veya karmaşık vakaları verimli bir şekilde ele alabiliyor.

CNN ayrıca tedavi planlamasını geliştirmek ve tıbbi görüntülerin ve klinik verilerin kapsamlı analizine dayanarak her vaka için uygun tedaviyi seçmek için de

kullanılabilir. Tümörlerin sınırlarını doğru bir şekilde belirleme ve küçük detayları analiz etme yeteneği sayesinde CNN'ler, cerrahi operasyonların doğru planlanmasına ve sonuçlarının iyileştirilmesine yardımcı olabilir.

Dolayısıyla beyin tümörlerinin tedavisinde CNN kullanımının, sağlık hizmetlerinin iyileştirilmesine, tedavi başarısının artırılmasına ve bu duruma sahip hastaların yaşam kalitesinin iyileştirilmesine katkı sağlayan önemli bir bilimsel ilerleme olarak değerlendirildiği söylenebilir.





ÜÇÜNCÜ BÖLÜM
MATERYAL VE METOD

Bu bölümde, çalışmanın metodolojisi ve kullanılan materyaller ayrıntılı olarak ele alınacaktır. Yapay zeka, makine öğrenmesi ve derin öğrenme tekniklerinin yanı sıra evrimsel sinir ağlarına odaklanılacaktır. Ayrıca, önerilen CNN modelleri (VGG16, ResNet50 ve EfficientNetB3) incelenecektir. Veri seti ve ön işlemler ayrıntılı olarak açıklanacak ve çalışma akış şeması sunularak metodoloji adımları adım adım açıklanacaktır. Bu bölüm, araştırmanın temelini oluşturur ve çalışmanın geri kalan kısımlarına geçiş sağlar.

3.1. YAPAY ZEKÂ

Köklerini bilgisayar bilimleri alanının kurulmasından sonraki 1950'lerine dayanan yapay zekâ, teknolojinin ilerlemesi ve daha güçlü bilgisayarların ortaya çıkmasıyla gelişmiştir, bu da daha karmaşık uygulamaların mümkün olmasına yardımcı olmuştur. Yapay zekâ, 20. yüzyılın 80'lerinde makine öğrenimi ve yapay sinir ağlarına odaklanmanın artmasıyla önemli bir gelişme gösterdi. Bu alanlardaki gelişmeler, yapay zekânın büyümesini hızlandırdı ve uygulamalarının artmasına yol açtı. Yapay zekâ üzerine araştırma ve geliştirme, sonraki on yıllarda devam etti ve yapay zekâ yeteneklerinin, uygulamalarının ve çeşitli kullanımlarının büyük ölçüde arttığı bir dönemi gördü.

Yapay zekâ, insanların gerçekleştirdiği görevleri başarıyla yerine getirebilecek akıllı sistemler geliştirmeyi amaçlamaktadır. Yapay zekâ araştırmaları ve geliştirme çalışmaları, öğrenme, düşünme, karar verme ve bilgisayar problemlerini çözme gibi geniş bir yelpazedeki becerilerin geliştirilmesini hedeflemektedir. Ayrıca yapay zekâ, tekrarlayan ve benzer görevleri yerine getirebilen otomatik teknoloji ve akıllı robotların geliştirilmesini de amaçlamaktadır. Yapay zekâ, sağlık, eğitim, ulaşım ve ticaret gibi çeşitli alanlarda verimliliği artırmak ve üretkenliği artırmak için kullanılabilir.


Yapay zekâ uygulamaları, birçok alanda ve endüstride bulunmaktadır. Akıllı telefon uygulamalarında, ses ve görüntü tanıma ile otomatik çeviri gibi hizmetleri sağlamak için kullanılabilir. Ayrıca, üretim hatlarını iyileştirmek ve hız ve doğruluğu artırmak için robotik ve endüstriyel otomasyonda kullanılabilir. Tıp alanında, hastalıkları teşhis etmek, tıbbi görüntüleri analiz etmek ve ileri tedavi yöntemleri sağlamak için yapay zekâ kullanılabilir.

Yapay zekâ, bilgisayar bilimlerinde yeni bir alandır ve insan zihinsel yeteneklerini taklit etme ve simüle etme yeteneğine sahip teknolojik sistemler

geliştirmeyi amaçlamaktadır. Yapay zekâ, makine öğrenimi, derin öğrenme ve yapay sinir ağları gibi tekniklere dayanır ve akıllı sistemlerin insan zihninin benzer şekilde veri anlaması, çıkarımda bulunma ve karar alma yeteneğine sahip olmasını sağlar.

Şekil 3.1'de, bu üç kavram arasındaki ilişki daha derinlemesine anlaşılabilir şekilde gösterilmektedir.

Şekil 3.1: Yapay Zekâ, Makine Öğrenimi, Derin Öğrenme ve CNN Arasındaki İlişkinin Çizilmesi



3.2. MAKİNE ÖĞRENME

Yapay öğrenme, verilerden öğrenme ve performansını açıkça programlanmamış olmaksızın geliştirebilen akıllı sistemlerin geliştirilmesine odaklanan yapay zekânın bir dalıdır. Yapay öğrenme teknikleri geniş bir uygulama yelpazesinde kullanılmaktadır, örneğin: Görüntü tanıma gibi yüz tanıma, nesnelerin belirlenmesi ve görüntülerin otomatik sınıflandırılması; Doğal dil işleme gibi otomatik çeviri, otomatik özetleme ve duygu analizi; Tahmin yapma gibi piyasa davranışlarını tahmin etme, hava durumu tahmini ve sahtekarlık tespiti; Robotlar gibi robot kontrolü, hareket planlaması ve çevreyle etkileşimden öğrenme.

Yapay öğrenme teknikleri, verilerin analiz edilmesi ve bilginin çıkarılması için kullanılan algoritmaları temel alır. Bu bilgi daha sonra yeni veri davranışlarını tahmin etmek veya ona göre kararlar almak için kullanılır. Yapay öğrenmenin türleri, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmeyi içerir. Yapay öğrenmenin

faidaları, performansın iyileştirilmesi, otomasyon ve desen keşfi gibi alanlarda görülebilmektedir, büyük veri ihtiyacı, önyargı ve algoritmaların anlaşılması gibi zorluklar da mevcuttur.

Yapay öğrenmenin geleceği oldukça parlak görünmektedir, çünkü birçok alanda tıp, imalat ve eğlence gibi ilerlemelere önemli katkıda bulunması beklenmektedir. Performansın iyileştirilmesi ve otomasyon aracılığıyla, yapay öğrenme, mevcut ve gelecekteki zorluklara etkili çözümler sunabilir. Bu alandaki araştırma ve geliştirmenin devam etmesiyle, yapay öğrenmeye dayalı daha gelişmiş ve yenilikçi uygulamaların ortaya çıkması muhtemeldir, bu da bizi geleceğe ve getirebileceği yeni ve heyecan verici olanaklara büyük bir heyecanla beklememize neden olmaktadır.

3.3. DERİN ÖĞRENME

Derin öğrenme, geleneksel yapay zekâ yaklaşımlarından önemli ölçüde farklılık gösterir çünkü büyük miktarda veri kullanarak kendi başına karmaşık örüntüleri öğrenebilir ve bu örüntülerden karmaşık problemleri çözebilir. Bu yöntem, insan beyninin sinir ağlarını taklit eder ve yapay sinir ağları üzerine kuruludur. Veriler, bu ağlardaki birbirine bağlı katmanlardan geçerken, derin öğrenme modeli, verideki karmaşık ilişkileri ve örüntüleri tanıyabilir.

Derin öğrenmenin önemli avantajları vardır:

- Daha iyi performans: Geleneksel yöntemlere kıyasla, derin öğrenme modelleri daha yüksek doğruluk ve daha düşük hata oranları sunabilir.
- Daha az insan müdahalesi: Derin öğrenme modelleri, veri ön işleme ve özellik mühendisliği gibi görevleri otomatikleştirebilir.
- Daha fazla esneklik: Farklı veri türleri ve problem türleri için uyarlanabilir.
- Daha fazla veri ihtiyacı: Doğru bir şekilde eğitilmeleri için büyük veri setlerine ihtiyaç duyarlar.
- Daha fazla hesaplama gücü ihtiyacı: Geleneksel yöntemlere göre daha fazla hesaplama gücü gerektirirler.
- Daha az yorumlanabilirlik: Geleneksel yöntemlere göre daha az şeffaf ve yorumlanabilir olabilirler.

Ayrıca, derin öğrenme birçok farklı alanda kullanılmaktadır. Görüntü işlemeden doğal dil işlemeye, robotikten finansa kadar geniş bir uygulama alanı bulunmaktadır. Bu


teknolojinin hızla gelişmesi ve yaygınlaşmasıyla birlikte, gelecekte derin öğrenmenin daha da önemli bir rol oynaması beklenmektedir. Bu, birçok endüstri ve alan için büyük bir potansiyel sunmaktadır ve yapay zekânın daha da ileriye taşınmasına olanak tanır.

3.4. YAPAY SİNİR AĞLARI

Yapay sinir ağları (YSAs), yapay zekânın temel taşlarından biri olarak kabul edilir ve son yıllarda giderek daha fazla önem kazanmaktadır. Bu artan ilgi, YSAs'nın geniş bir uygulama yelpazesine sahip olmasından kaynaklanmaktadır. YSAs, karmaşık veri setlerinden örüntüler çıkarmak, sınıflandırma yapmak, tahminlerde bulunmak ve kararlar vermek gibi birçok görevde başarılı bir şekilde kullanılabilirler.

Özellikle derin öğrenme alanındaki gelişmeler, YSAs'nın yeteneklerini daha da artırmıştır. Derin öğrenme, çok katmanlı YSAs kullanarak karmaşık yapıları ve ilişkileri öğrenme yeteneğidir. Bu, görüntü tanıma, doğal dil işleme, oyun yapay zekâsı ve otomatik sürüş gibi alanlarda çığır açan başarılar elde edilmesini sağlamıştır.

Şekil 3.2: Yapay Sinir Ağı Mimarisi



YSAs'nın artan popülaritesi, büyük veri setlerinin kullanılabilirliğindeki artışla da ilişkilidir. Gelişmiş veri depolama ve işleme teknolojileri, YSAs'nın daha geniş ve karmaşık veri kümeleri üzerinde çalışmasını mümkün kılmıştır. Bu da YSAs'nın daha doğru, verimli ve genel geçerli modeller oluşturmaya olanak tanır.

YSAs'nın gelecekteki potansiyeli oldukça büyüktür. Özellikle endüstriyel uygulamalarda, otomasyon, veri analizi, öngörülebilir bakım gibi alanlarda YSAs'nın kullanımı daha da artacaktır. Ayrıca, sağlık, güvenlik, ulaşım ve çevre gibi alanlarda da YSAs'nın etkin bir şekilde kullanılması beklenmektedir.

Sonuç olarak, YSAs, yapay zekânın temel taşlarından biri olarak giderek daha fazla önem kazanmaktadır. Artan veri kullanılabilirliği ve derin öğrenme gibi gelişmeler, YSAs'nın uygulama alanını genişletmektedir. Gelecekte, YSAs'nın daha da karmaşık ve geniş veri kümeleri üzerinde çalışarak insan yaşamını daha da kolaylaştıracağı ve birçok alanda devrim niteliğinde değişiklikler getireceği öngörülmektedir.


CNN bir tür yapay sinir ağı olduğundan verileri sıralı olarak kullanabilme ve etkili bir şekilde analiz edebilme avantajına sahiptir. CNN'ler tıp alanında, özellikle de beyin tümörlerini sınıflandırmak için yaygın olarak kullanılmaktadır. Bu ağlar, beyin tümörlerini kesin olarak tanımlamaya yardımcı olan beyin görüntülerinden özellikler çıkarma yeteneğini kullanır. Derin öğrenme tekniklerini kullanan CNN'ler, radyolojik görüntülerdeki karmaşık kalıpları tanıyabiliyor ve tümörlerin türünü ve yerini doğru bir şekilde belirleyebiliyor, böylece doktorların hastaları tedavi etme konusunda hızlı ve doğru kararlar almasına yardımcı oluyor.

3.5. EVRİŞİMSEL SİNİR AĞLARI

CNN'ler, görsel veri analizi ve sınıflandırmasında kullanılan derin öğrenme modelleridir. Görüntülerdeki özellikleri algılamak ve karmaşık desenleri tanımak için özel olarak tasarlanmışlardır. Bu, "hiyerarşik öğrenme" kavramıyla ilişkilendirilir, çünkü CNN'ler, veriyi düzenlemek ve analiz etmek için basit desenlerden başlayarak giderek daha karmaşık desenlere ilerlerler. Bu sayede, örneğin bir görüntüdeki bir nesnenin varlığını tespit etmek gibi görevlerde son derece etkili olabilirler.

CNN'ler, çeşitli alanlarda geniş bir uygulama potansiyeline sahiptir. Tıp alanında, tıbbi görüntülerden hastalıkları teşhis etmek için kullanılabilirler. Öğrencilerle etkileşimli yapay zekâ öğrenme sistemlerinin geliştirilmesinde eğitimde kullanılabilirler. Endüstriyel alanlarda ise, kalite kontrolü, üretim izleme ve otomasyon gibi birçok alanda kullanımları bulunmaktadır. Özellikle endüstride, görüntü tabanlı veri analizi ve sınıflandırma, üretim süreçlerinin optimize edilmesi ve hataların azaltılması gibi alanlarda büyük faydalar sağlayabilir.

Şekil 3.3: CNN Mimarisi



Kaynak: https://miro.medium.com/v2/resize:fit:720/format:webp/0*I6NhCKvsN7nov4Zc, 2024.

CNN'lerin eğitimi için kullanılan katmanlar arasında Evrişim katmanı, Havuzlama katmanı, Bırakma katmanı ve Tam Bağlantılı katman gibi önemli bileşenler bulunmaktadır. Evrişim katmanı, giriş görüntülerinden özellikleri çıkarmak için evrişim işlemleri gerçekleştirir. Havuzlama katmanı, görüntü boyutunu küçültmek ve önemli özellikleri korumak için kullanılır. Bırakma katmanı, aşırı uyumu önlemek için kullanılır ve ağıın genelleştirilebilirliğini artırır. Tam Bağlantılı katman, önceki katmanlardan çıkarılan özelliklerden yararlanarak sınıflandırma işlemini gerçekleştirir.

Son olarak, CNN modellerinin eğitimi sırasında Grafik İşlem Birimi (GPU) kullanımının yaygın olduğunu belirtmek önemlidir. GPU'lar, paralel hesaplama yeteneklerine sahip olduklarından, büyük veri kümeleriyle çalışırken eğitim sürecini hızlandırır ve daha etkili hale getirir. Bu da CNN'lerin genellikle GPU tabanlı bilgisayarlarda eğitilmesini sağlar.

3.5.1. Evrişim Katmanı

Evrişim katmanı, CNN'in en önemli katmanıdır. Evrişim katmanı, bir görüntünün yerel özelliklerini yakalamak için evrişim işlemini kullanır. Evrişim işlemi, aşağıdaki şekilde gösterilebilir:

$$y(i, j) = f(x(i - k, j - l)) \quad (3.1)$$

Burada:

$y(i, j)$: Evrişim katmanının çıktısı, f : Evrişim fonksiyonu, $x(i, j)$: Görüntünün girişi, k : Filtrenin genişliği ve l : Filtrenin yüksekliği.

Evrişim fonksiyonu genellikle lineer bir işlemdir ve filtrenin kendisi, evrişim işleminin öğrenilebilir parametreleridir. Bu evrişim işlemi, özellikle görüntü işleme ve sınıflandırma görevlerinde yaygın olarak kullanılmaktadır ve CNN'lerin etkinliğini artıran önemli bir bileşen olarak kabul edilir.

3.5.2. Havuzlama Katmanı

Havuzlama katmanı, evrişim katmanından gelen çıktıyı küçültmek ve önemli özellikleri korumak için kullanılır. Bu katman, CNN'in daha genel özellikler öğrenmesini sağlar. Örneğin, bir görüntüdeki belirli bir desenin varlığını tespit etmek için gerekli olan temel özelliklerin korunmasına yardımcı olur. Havuzlama katmanı, aynı zamanda ağır hesaplama yükünü azaltarak işlem süresini hızlandırır ve aşırı uyumu azaltabilir.

Havuzlama katmanında kullanılan en yaygın yöntemlerden biri maksimum havuzlamadır. Bu yöntemde, evrişim katmanından gelen çıktının her hücresinden maksimum değeri alırız. Örneğin, bir filtre (örneğin, 2×2 boyutunda) evrişim katmanından belirli bir bölgeye tepki verir ve maksimum havuzlama işlemi, bu bölgenin en belirgin özelliğini seçer. Bu sayede, önemli özelliklerin vurgulanması ve korunması sağlanır.


Diğer bir havuzlama yöntemi ise ortalama havuzlamadır. Bu yöntemde, evrişim katmanından gelen çıktının her hücresinden ortalama değeri alırız. Bu, bölgedeki genel yoğunluğu veya özellikleri temsil etmek için kullanılır. Maksimum havuzlamadan farklı olarak, ortalama havuzlama daha yumuşak bir etki sağlar ve daha genel özelliklerin çıkarılmasına yardımcı olur.

Havuzlama katmanı, genellikle evrişim katmanları arasına yerleştirilir ve ağın derinliğini artırırken, boyutunu azaltır. Bu, ağın ölçeklenebilirliğini ve genelleştirilebilirliğini artırır. Havuzlama katmanı, CNN'in karmaşık desenleri tanımasına yardımcı olurken, hesaplama maliyetini düşük tutar. Bu nedenle, CNN'lerin etkili ve hızlı bir şekilde büyük veri kümeleriyle çalışmasını sağlar.

3.5.3. Tam Bağlantılı Katman

Tam bağlantılı katman, CNN'in Havuzlama katmanından gelen çıktıyı sınıflandırmak için kullanılır. Bu katman, bir sinir ağının geleneksel katmanlarına benzer bir yapıya sahiptir. Havuzlama ve evrişim katmanlarından gelen özellikleri içerir ve bu özellikleri analiz ederek veri setinin belirli sınıflara atanmasını sağlar.

Şekil 3.4: Tam Bağlantılı Katman Yapısı



Kaynak: https://miro.medium.com/v2/resize:fit:1400/format:webp/0*ieTmbSO4RWQtaszt, 2024

Tam bağlantılı katman, her bir nöronun önceki katmandaki tüm nöronlarla bağlantılı olduğu bir yapıya sahiptir. Her bir nöron, ağırlıklar ve aktivasyon fonksiyonları aracılığıyla gelen sinyalleri işler ve çıktı üretir. Bu katman, genellikle son sınıflandırma adımında kullanılır ve ağın çıktılarını, sınıflara karşılık gelen olasılıklar veya etiketler şeklinde dönüştürür.

CNN'lerin avantajlarına gelince, birkaç önemli nokta öne çıkar:

- Daha az parametre: CNN'ler, geleneksel Yapay Sinir Ağlarına (ANN) göre daha az parametreye sahiptir. Bu, ağın daha az veriyle eğitilmesini ve daha az hesaplama gücü gerektirmesini sağlar. Ayrıca, modelin daha az öğrenilebilir parametreye sahip olması, ağın aşırı uyumu riskini azaltabilir.
- Daha iyi genelleme: CNN'ler, geleneksel ANN'lere göre daha iyi genelleme yeteneklerine sahiptir. Bu, ağın eğitim verilerinde görülmemiş örneklerle daha

iyi başa çıkmasını sağlar. Bu da, ağın daha genel ve kullanışlı sonuçlar üretmesine yardımcı olur.

- Daha yüksek doğruluk: CNN'ler, geleneksel ANN'lere göre daha yüksek doğruluk oranlarına sahip olabilir. Bu, özellikle görüntü tanıma gibi karmaşık görevlerde daha iyi performans sağlar. Daha az parametre ve daha iyi genelleme yetenekleri, CNN'lerin daha hassas ve güvenilir sonuçlar üretmesine yardımcı olur.

Bu avantajlar, CNN'lerin birçok alanda başarıyla kullanılmasını sağlar ve özellikle görüntü işleme ve sınıflandırma gibi görsel verilerle çalışan uygulamalarda etkilidir. Bu nedenle, CNN'ler günümüzde birçok endüstriyel ve akademik alanda geniş bir kullanım alanına sahiptir.

3.6. ÖNERİLEN CNN MODELİ

Önerilen cnn modeli olarak öne çıkan vgg16, resnet50 ve efficientnetb3 gibi derin öğrenme modelleri, görüntü sınıflandırma ve benzeri görevlerde üstün performans sergilemektedir.

3.6.1. VGG16

VGG16, evrimsel sinir ağı (CNN) alanında önemli bir yere sahip olan ve birçok derin öğrenme modelinin temelini oluşturan bir yapay sinir ağı modelidir. Görsel sınıflandırma görevlerinde kullanılmak üzere özel olarak tasarlanmış olan bu model, basit ve düzgün bir yapıya sahiptir ve genellikle bir referans modeli olarak kullanılmaktadır.

VGG16 model mimarisi, öncelikle görüntü sınıflandırma görevleri için kullanılan konvolüsyonel sinir ağları (CNN'ler) alanında bir kilometre taşını temsil etmektedir. Oxford Üniversitesi'ndeki Görsel Geometri Grubu (VGG) tarafından 2014 yılında geliştirilen VGG16, ImageNet veri kümesinde %92,7'lik önemli bir test doğruluğu elde ederek derinliği ve etkinliği ile tanınmaktadır. Bu veri kümesi, 1000 nesne kategorisine dağıtılmış 14 milyondan fazla eğitim görüntüsünden oluşmaktadır.

VGG16'nın mimarisi, basitliği ve tekdüzeliği ile karakterize edilir. Konvolüsyonel katmanların sıralı bir düzenlemesini ve ardından tam bağlantılı katmanları içerir. Bu tasarım prensibi, anlama ve uygulama kolaylığını teşvik ederek VGG16'yı CNN'ler alanında erişilebilir bir model olarak öne çıkarır. Ayrıca, basit


tasarımı transfer öğrenme teknikleriyle sorunsuz entegrasyonu kolaylaştırarak görüntü sınıflandırma doğruluğunu artırmak için alternatif veri kümeleri üzerinde yeniden eğitime olanak sağlar.

Ancak, VGG16 mimarisi bazı sınırlamalara sahiptir. Özellikle, toplam 138 milyon parametre içeren önemli bir parametre sayısına sahiptir. Bu büyük parametre sayısı, modeli çağdaş CNN modellerine kıyasla nispeten büyük ölçekli hale getirir. Sonuç olarak, hem eğitim hem de çıkarım görevleri için hesaplama gereksinimleri önemli ölçüde artar ve sağlam hesaplama kaynaklarına erişim gerektirir.

Teknik olarak, VGG16, 13 konvolüsyonel katman ve 3 tam bağlantılı katmanı içeren 16 katmandan oluşur. Model, 224×224 piksel boyutundaki görüntüleri işlemek için tasarlanmıştır ve sınıflandırma amacıyla konvolüsyonel katmanlardaki ReLU (Rectified Linear Unit) aktivasyon işlevinden ve son katmandaki softmax aktivasyon işlevinden yararlanır. Ayrıca, softmax kayıp fonksiyonunu kullanarak görüntü sınıflandırma sonuçlarının doğruluğunu ölçer.

VGG16'nın çok yönlülüğü, görüntü sınıflandırma görevlerinden daha fazlasını hedefler. Model, nesne tanıma ve yüz algılama gibi sonraki görevler için bilgilendirici özellikler elde etmek üzere görüntü özelliği çıkarma işlemi için kullanılır. Ayrıca, transfer öğrenme uygulamaları için temel bir model olarak hizmet ederek görüntü sınıflandırma doğruluğunu iyileştirmek ve belirli kullanım durumlarına uyum sağlamak için çeşitli veri kümeleri üzerinde yeniden eğitime olanak sağlar.

Şekil 3.5: Vgg16 Model Mimarisi



Kaynak: https://www.researchgate.net/figure/The-two-different-networks-based-on-the-VGG-16-architecture-are-shown-Eachcoloredblock_fig2_356394714, 2024.

VGG16, görüntülerden özelliklerin aşamalı olarak çıkarılması ve ardından bu özelliklere dayalı olarak sınıflandırma işlemlerini gerçekleştirir. Aşağıda bu sürecin adımları yer almaktadır:

- Girdi: Model, giriş olarak bir görüntü alır. Görüntü, genellikle sabit bir boyuta (örneğin 224x224 piksel) yeniden boyutlandırılarak ağına mimarisine uygun hale getirilir.
- Evrişimsel Bloklar: Görüntü, bir dizi beş evrişimsel blokta işlenir. Her bir blok şu bileşenleri içerir:
- Çoklu Evrişimsel Katmanlar (3x3 filtreler): Bu katmanlar, görüntü üzerinde kayarak düşük seviyeli özellikleri çıkaran filtreleri uygular. Küçük 3x3 filtrelerin kullanılması, görüntü boyutunu değiştirmeden aşamalı özellik çıkarımını mümkün kılar.
- ReLU Aktivasyonu: Bu aktivasyon fonksiyonu, doğrusal olmayan özellikler ekleyerek ağına daha karmaşık örüntüler öğrenmesine olanak sağlar.
- Max-Pooling Katmanı (2x2): Bu katman, özellik haritalarını örnekleyerek uzamsal çözünürlüğü azaltır ve hesaplama karmaşıklığını düşürür.

Tam Bağlantılı Katmanlar: Evrişimsel bloklardan elde edilen özellikler daha sonra tek bir vektöre düzleştirilir. Bu vektör, üç tam bağlantılı katmana beslenir. Bu katmanlar, çıkarılan özellikler ile nihai sınıflandırma çıktısı arasındaki karmaşık ilişkileri öğrenir.


Aktivasyon fonksiyonları (ilk iki katmanda ReLU ve son katmanda Softmax), verilerin dönüştürülmesi ve nihai sınıflandırma çıktısının oluşturulması için bu katmanlara uygulanır.

3.6.2. Resnet50

ResNet50, derin öğrenme alanında bir dönüm noktası olan artıklık bloklarının (residual blocks) kullanımıyla öne çıkan bir yapay sinir ağı modelidir. Geleneksel olarak, derin sinir ağları daha fazla katman ekledikçe performanslarının artması beklenirken, bu ek katmanlar gradyanın giderek küçülmesine ve hatta yok olmasına neden olabilir. Ancak, ResNet50'de kullanılan artıklık blokları, bir önceki katmandaki çıkışı, bir sonraki katmanın girişine eklemektedir. Bu sayede, ağına öğrenmesi kolaylaşır ve daha derin ağlar sorunlarla karşılaşmadan eğitilebilir hale gelir.

ResNet50, 50 katmana sahip bir modeldir. Bu, ağı derinliğinin orta düzeyde olduğu anlamına gelir. Orta düzeydeki derinlik, modelin genellikle etkili bir şekilde eğitilmesini sağlarken, aşırı karmaşıklıkla karşılaşmadan farklı uygulamalarda kullanılabilir olmasını sağlar. Örneğin, daha derin modellere kıyasla daha az hesaplama gücü ve veriye ihtiyaç duyar, bu da onu daha erişilebilir kılar.

Şekil 3.6: ResNet50 Model Mimarisi



Kaynak: https://www.researchgate.net/figure/ResNet50-architecture_fig2_358078749, 2024.

ResNet50 mimarisinin temel bileşenleri şunlardır:

- **Konvölüsyonel Katmanlar:** ResNet50, görüntüleri işlemek için konvölüsyonel katmanlar kullanır. Her konvölüsyonel katman, bir dizi filtre içerir. Bu filtreler, görüntüdeki desenleri öğrenmek için kullanılır.
- **Max Pooling Katmanları:** Max pooling katmanları, görüntünün boyutunu küçültmek için kullanılır. Bu, modelin daha az hesaplama gerektirmesini sağlar.
- **Tam Bağlantılı Katmanlar:** Tam bağlantılı katmanlar, görüntünün sınıfını tahmin etmek için kullanılır.

Modelin yapılandırması, artıklık bloklarının bir araya gelmesinden oluşur. Her bir artıklık blok, bir önceki katmanın çıkışını bir sonraki katmanın girişine ekleyerek bilgilerin akışını kolaylaştırır. Bu bloklar, eğriler, gradyanlar ve aktivasyon fonksiyonları gibi çeşitli katmanlardan oluşur.

ReLU (Rectified Linear Unit) aktivasyon fonksiyonu, ResNet50'nin katmanları arasında kullanılarak ağı daha karmaşık özellikleri öğrenmesine yardımcı olur. Bu

doğrusal olmayan aktivasyon işlevi, ağıın esnekliğini artırarak daha geniş bir özellik uzayında çalışmasını sağlar.

ResNet50, önceden belirlenmiş ve etiketlenmiş veri kümesi üzerinde eğitilir. Bu eğitim, modelin parametrelerini ayarlayarak doğruluğunu artırmayı amaçlar. Otomatik ayarlama algoritmaları, modelin sürekli olarak iyileştirilmesini sağlar, böylece en iyi performans elde edilir.

Eğitimden sonra, ResNet50 yeni görüntülerin sınıflandırılması için kullanılır. Model, çeşitli katmanlar aracılığıyla geçirilen görüntülerden benzersiz özellikler çıkarır ve bu özellikleri kullanarak nesneleri sınıflandırır.

ResNet50'nin önemli bir avantajı, derin öğrenme ve özellik çıkarımı konusundaki yetenekleridir. Model, özellikle büyük veri kümeleri üzerinde yüksek doğruluk sağlar ve geniş bir uygulama yelpazesine sahiptir.

Ancak, modelin eğitimi ve çalıştırılması büyük miktarda hesaplama gücü ve bellek gerektirebilir. Bu, sınırlı kaynaklara sahip ortamlarda kullanılmasını zorlaştırabilir.

ResNet50'nin Kullanım Alanları:

- Görüntü sınıflandırma
- Nesne tanıma
- Görüntü segmentasyonu
- Görüntüden metne


ResNet50, geniş bir kullanım alanına sahiptir. Görüntü ve video sınıflandırması, nesne tanıma, yüz tanıma ve otomatik doğrulama gibi birçok alanda başarıyla kullanılabilir.

3.6.3. EfficientNetB3

EfficientNetB3, derin öğrenme alanında son derece etkili ve verimli olan bir yapay sinir ağı modelidir. Bu model, dikkatlice tasarlanmış bir denge yakalar: hesaplama gücü ve performans arasındaki ideal noktayı temsil eder. Yapılan optimize edilmiş mimari ayarlamaları sayesinde, daha az hesaplama gücü ve bellek kullanarak yüksek doğruluk sağlar. Bu özelliği, mobil cihazlar gibi kaynak kısıtlı ortamlarda kullanılabilirliğini artırırken, aynı zamanda güçlü bilgisayar sistemlerinde de etkili bir şekilde çalışabilirliğini sürdürür.

EfficientNetB3'ün temel özelliği, ölçeklenebilirlik ve verimlilik. Bu model, farklı boyutlardaki bilgi işlem kaynaklarını kullanarak ağırlık, derinlik ve genişlik gibi mimari parametreleri dengeler. Böylece, model, çeşitli veri setleri ve uygulama senaryoları için optimize edilmiş bir performans sunar. Ölçeklenebilirlik prensibi, modelin farklı gereksinimlere kolayca adapte olmasını sağlar, bu da geniş bir uygulama yelpazesine sahip olmasını sağlar.

Şekil 3.7: EfficientNetB3 Model Mimarisi



Kaynak: Salián ve Sawarkar, 2022

Mimarinin temel bileşenleri şunlardır:

- *Ölçeklendirme:* EfficientNetB3, modelin boyutunu ve derinliğini otomatik olarak ölçeklendirmek için bir ölçeklendirme yöntemi kullanır. Bu, modelin farklı görevler ve veri kümeleri için uyarlanmasını sağlar.
- *Kompozit Ölçekleme:* EfficientNetB3, hem genişlik hem de derinliği ölçeklemek için bir kompozit ölçekleme yöntemi kullanır. Bu, modelin hem daha geniş hem de daha derin hale getirilmesini sağlar.
- *Inception Modülleri:* EfficientNetB3, Inception modülleri adı verilen bir tür konvülsiyonel katmanı kullanır. Inception modülleri, farklı boyutlarda filtreler kullanarak modelin daha fazla bilgi çıkarmasını sağlar.
- *MobilNetV2 Bloklar:* EfficientNetB3, MobilNetV2 bloklar adı verilen bir tür konvülsiyonel katmanı kullanır. MobilNetV2 bloklar, modelin daha hafif ve daha hızlı hale getirilmesini sağlar.

EfficientNetB3'ün temel özelliği, ölçeklenebilirlik ve verimlilik. Bu model, farklı boyutlardaki bilgi işlem kaynaklarını kullanarak ağırlık, derinlik ve genişlik gibi

mimari parametreleri dengeler. Böylece, model, çeşitli veri setleri ve uygulama senaryoları için optimize edilmiş bir performans sunar. Ölçeklenebilirlik prensibi, modelin farklı gereksinimlere kolayca adapte olmasını sağlar, bu da geniş bir uygulama yelpazesine sahip olmasını sağlar.

EfficientNetB3'ün teknik detaylarına bakıldığında, modelin temel mimari blokları, "Mobile Inverted Bottleneck Block" olarak adlandırılan özel bir yapıyı içerir. Bu bloklar, bilgi işleme gücünü artırmak için daraltılmış girdi kanalları ve genişletilmiş çıktı kanalları arasında bir şişkinlik işlemini kullanır. Bu yapı, daha az parametre kullanarak daha fazla derinlik elde etmeyi sağlar, bu da modelin verimliliğini artırır.

EfficientNetB3, ölçeklenebilirlik prensibine dayanarak çalışır. Bu prensip, modelin ağırlık, derinlik ve genişlik gibi temel mimari parametrelerini dengeli bir şekilde ayarlamasını sağlar. Model, veri setinin boyutuna ve mevcut hesaplama kaynaklarına göre otomatik olarak optimize edilir. Bu da, daha az hesaplama gücü ve bellek kullanarak yüksek doğruluk elde edilmesini sağlar.

EfficientNetB3'ün en önemli avantajı, yüksek performansı korurken hesaplama gücünde ve bellek kullanımında verimliliği sağlamasıdır. Bu, mobil cihazlar gibi kaynak sınırlı ortamlarda kullanılabilirliğini artırırken, aynı zamanda güçlü bilgisayar sistemlerinde de etkili bir şekilde çalışabilirliğini sürdürür. Ayrıca, modelin ölçeklenebilir olması, farklı veri setleri ve uygulama senaryoları için uyarlanabilirliğini artırır.

EfficientNetB3'ün bazı dezavantajları arasında, bazı durumlarda diğer daha büyük ve karmaşık modeller kadar yüksek performans sağlayamaması ve bazı uygulamalarda spesifik ihtiyaçlara uyum sağlama yeteneğinin sınırlı olması yer alabilir. Bu, belirli kullanım durumları için daha özel modellerin gerekliliğini ortaya koyar.

EfficientNetB3'ün Kullanım Alanları:

- Görüntü sınıflandırma
- Nesne tanıma
- Görüntü segmentasyonu
- Görüntü oluşturma
- Görüntüden metne

EfficientNetB3, geniş bir uygulama yelpazesine sahiptir. Görüntü sınıflandırması, nesne tespiti, yüz tanıma, görüntü segmentasyonu gibi görsel algılama


görevlerinde başarıyla kullanılabilir. Ayrıca, mobil cihazlar, gömülü sistemler ve bulut tabanlı uygulamalar gibi kaynak sınırlı ortamlarda da etkili bir şekilde çalışabilir. Bu model, endüstride ve araştırmada geniş kabul görmüş ve çeşitli alanlarda kullanılmıştır.

3.7. VERİSETİ

Kaggle'da bulunan Beyin Tümörü MRI Veri Seti, tıbbi görüntü analizi ve makine öğrenimi alanındaki araştırmacılar ve uygulayıcılar için değerli bir kaynaktır. Bu koleksiyon dört ayrı kategoriye ayrılan 7.022 manyetik rezonans görüntüleme (MRI) görüntüsünden oluşur: glioma, menenjiyom, hipofiz ve tümör yok. Bu görüntüler beyin tümörü tespit, sınıflandırma ve segmentasyon algoritmalarının geliştirilmesi ve değerlendirilmesi için zengin bir veri kaynağı sağlar.

Görüntü kalitesindeki farklılıklar, veri setinin farklı kaynaklardan gelen görüntüler içermesi nedeniyle makine öğrenimi modellerinin eğitilmesi ve değerlendirilmesinde zorluklar yaratabilir. Ayrıca, algoritmaların performansının bağımsız klinik veri setlerinde doğrulanması gereklidir.

Şekil 3.8: Çalışmada Kullanılan Rastgele Bir Dizi Mr Verisi



Beyin tümörlerinin sınıflandırılması: MRI taramalarını dört belirtilen kategoriye sınıflandırmak için makine öğrenimi modelleri eğitilebilir. Bu, başlangıçta tümörlerin teşhisine yardımcı olur ve uygun tıbbi kararların alınmasını sağlar.

Tablo 3.1: Çalışmada Kullanılan Veri Setine Dair Sayısal Veriler

Tümör tipi	Eğitim Verisi	Test Verisi
Glioblastoma	1321	300
Meningioma	1339	306
Non-tümör	1595	405
Pituitary Tümör	1457	300

Tümör segmentasyonu: Görüntülerdeki tümör bölgelerini belirlemek ve segmente etmek için algoritmalar geliştirilebilir. Bu, tedavi planlaması ve etkilenen bölgelerin belirlenmesi açısından faydalıdır.

Bilgisayar Destekli Tanı (CAD): Veri seti, radyologların görüntüleri analiz etmelerine ve muhtemel tümör bölgelerini belirlemelerine yardımcı olacak CAD sistemlerinin geliştirilmesi için kullanılabilir.

Araştırma ve Geliştirme: Veri seti, tıbbi görüntü analizi ve makine öğrenimi tekniklerinin yeni keşifler ve algoritmalar geliştirmek için değerli bir platform sunar.

Brain Tumor MRI Veri Setinin Önemi:

Brain Tumor MRI Veri Seti, tıbbi görüntü analizi ve makine öğrenimi alanında ilerlemeye önemli bir katkı sağlar. Bu, tümör teşhisinin doğruluğunu, tedavi planlamasını ve hasta sonuçlarını olası bir şekilde iyileştirebilecek algoritmaların geliştirilmesi ve değerlendirilmesi için zengin bir veri kaynağı sağlar.

Görüntü kalitesindeki farklılıklar, veri setinin farklı kaynaklardan gelen görüntüler içermesi nedeniyle makine öğrenimi modellerinin eğitilmesi ve değerlendirilmesinde zorluklar yaratabilir. Ayrıca, algoritmaların performansının bağımsız klinik veri setlerinde doğrulanması gereklidir.

Sonuç olarak, Brain Tumor MRI Veri Seti, tıbbi görüntü analizi ve makine öğrenimi alanındaki araştırmacılar ve uygulayıcılar için değerli bir kaynaktır. Ancak, veri setinin kullanımı sırasında kısıtlamalar ve etik ilkeler göz önünde bulundurulmalıdır.

3.8. ÖN İŞLEMLER

Ön İşlemler bölümü, Veri Seti üzerinde gerçekleştirilen temel veri işleme adımlarını içermektedir. Bu adımlar, veri setinin analiz edilmesi ve hazırlanması sürecini kapsar, böylece daha sonra yapılacak olan modelleme ve analiz işlemleri için uygun hale getirilir.

Bu bölümde, veri artırma, ölçekleme, görüntü kodlama ve veri bölme gibi temel ön işlemler ele alınmaktadır.

3.8.1. Verileri Artırma

Veri artırma, makine öğrenimi algoritmalarının daha iyi performans göstermesi ve daha genelleştirilebilmesi için kullanılan bir tekniktir. Resim, metin ve ses verilerini çeşitlendirmek için kullanılan çeşitli yöntemler, modelin daha fazla veriyi öğrenmesini ve gerçek dünya verilerine daha iyi uyum sağlamasını sağlar (Taylor ve Nitschke, 2018).

Artırma image, yöntemi görüntü verilerini artırmanın en yaygın kullanılan yöntemlerinden biridir. Bu yöntem, görüntünün boyutunu, konumunu, renklerini ve diğer özelliklerini rastgele olarak değiştirerek yeni görüntüler oluşturur (Shorten ve Khoshgoftaar, 2019).

Artırılmış gerçeklik görüntüleri yöntemi ile uygulanabilen bazı teknikler şunlardır:

- Boyutlandırma: Görüntünün boyutunu büyütme veya küçültme.
- Dönme: Görüntüyü belirli bir açıyla döndürme.
- Kaydırma: Görüntüyü belirli bir eksen boyunca kaydırma.
- Kırpma: Görüntüden rastgele bir alanı kırpma.
- Yansıma: Görüntüyü dikey veya yatay olarak yansıtma.
- Parlaklık: Görüntünün parlaklığını değiştirme.
- Kontrast: Görüntünün kontrastını değiştirme.
- Renk: Görüntünün renklerini değiştirme.

Artırma görüntüsü yönteminin aşağıdaki avantajları vardır:

- Veri setinin boyutunu artırarak modelin daha iyi eğitilmesini sağlar.
- Modelin gerçek dünya verilerine karşı daha genelleştirilebilir olmasını sağlar.
- Modelin aşırı uyum (overfitting) riskini azaltmaya yardımcı olur.

Artırma görüntüsü yönteminin aşağıdaki dezavantajları vardır:

- Veri setinin boyutunu ve karmaşıklığını artırarak modelin eğitilmesini daha zorlaştırabilir.
- Modelin doğruluğunu olumsuz yönde etkileyebilecek aşırı veri artırımını yapılabilir.

Augmentasyon görüntü yöntemi, çeşitli makine öğrenimi uygulamalarında sıklıkla kullanılmaktadır. Bu yöntem, özellikle görüntü sınıflandırma, nesne algılama, yüz tanıma ve doğal dil işleme gibi uygulamalarda önemli bir rol oynamaktadır (Chlap et al., 2021).

3.8.2. Veri Boyutunun Değiştirilmesi (Ölçekleme)

Load img, yöntemi, Python'da görüntü verilerini yüklemek için kullanılan bir yöntemdir. Bu yöntem, görüntünün boyutunu, konumunu ve renklerini değiştirmek için de kullanılabilir (Nixon ve Aguado, 2019).

Load img, yöntemini kullanarak veri boyutunu değiştirmek için aşağıdaki adımlar izlenir:

- Öncelikle, görüntüyü yüklemek için load_img(), yöntemini kullanın (Villán, 2019).
- Ardından, görüntünün boyutunu değiştirmek için resize() yöntemini kullanın (Talebi ve Milanfar, 2021).
- Son olarak, görüntüyü kaydetmek için save() yöntemini kullanın.

resize() yönteminin kullanım şekli aşağıdaki gibidir:

Python

```
import load_img

image = load_img.load("image.png")

# Görüntünün boyutunu 200x200 olarak değiştirin.

image = load_img.resize(image, 200, 200)

# Görüntüyü kaydedin.

load_img.save(image, "image_scaled.png")
```

Bu örnekte, "image.png" adlı görüntüyü yükleyip boyutunu 200x200 olarak değiştirilmektedir. Ardından, değiştirilmiş görüntüyü "image_scaled.png" adlı dosyaya kaydedilmektedir.

Resim yükleme, yöntemini kullanarak veri boyutunu değiştirmenin avantajları şunlardır:

- Veri setinin boyutunu artırarak modelin daha iyi eğitilmesini sağlar.

- Modelin gerçek dünya verilerine karşı daha genelleştirilebilir olmasını sağlar.
- Modelin aşırı uyum (overfitting) riskini azaltmaya yardımcı olur (Ying, 2019).

Yükle img, yöntemini kullanarak veri boyutunu değiştirmenin dezavantajları şunlardır:

- Veri setinin boyutunu ve karmaşıklığını artırarak modelin eğitilmesini daha zorlaştırabilir.
- Modelin doğruluğunu olumsuz yönde etkileyebilecek aşırı veri artırımı yapılabilir.

3.8.3. Görüntü Kodlama

`decode_label` yöntemi aracılığıyla görüntü kodlama (pikselleri dijital değerlere dönüştürme)

Görüntü kodlama, görüntü verilerini sayısal verilere dönüştürme işlemidir. Bu işlem, görüntü verilerinin depolanması, iletilmesi ve işlenmesi için gereklidir.

`decode_label` yöntemi, görüntü kodlamanın en yaygın kullanılan yöntemlerinden biridir. Bu yöntem, görüntünün piksellerini dijital değerlere dönüştürmek için kullanılır.

`decode_label` yöntemini kullanarak görüntü kodlamak için aşağıdaki adımlar izlenir:

- Öncelikle, görüntüyü yüklemek için `load_img` yöntemini kullanın.
- Ardından, görüntünün piksellerini bir matrise dönüştürmek için `np.array()` yöntemini kullanın.
- Son olarak, matrisin her bir elemanını dijital bir değere dönüştürmek için `decode_label()` yöntemini kullanın.

`decode_label()` yönteminin kullanım şekli aşağıdaki gibidir:

Python

```
import load_img
```

```
import numpy as np
```

```
image = load_img.load("image.png")
```

```
pixels = np.array(image)
```

```
# Matrisin her bir elemanını dijital bir değere
dönüştürün.
```

```
digital_values = np.array([decode_label(pixel) for
pixel in pixels])
```

Bu örnekte, "image.png" adlı görüntüyü yükleyip piksellerini bir matrise dönüştürülmektedir. Ardından, matrisin her bir elemanını dijital bir değere dönüştürülmektedir.

`decode_label()` yönteminin avantajları şunlardır:

- Görüntü verilerini depolamak ve iletmek için verimli bir yöntemdir.
- Görüntü verilerini işlemek için kolay bir yöntemdir.

`decode_label()` yönteminin dezavantajları şunlardır:


- Görüntü verilerinin kalitesini düşürebilir.
- Görüntü verilerinin bazı özelliklerini kaybedebilir.

Görüntü kodlama, yapay zekâ modelinin performansını iyileştirmede ve nihai tahmin veya sınıflandırma görevinde doğruluğunu ve etkinliğini artırmada çok önemli bir rol oynar. Bir model görüntülerle ilgilendiğinde, görsel verilerin modelin bunları anlamasını ve verimli bir şekilde kullanmasını mümkün kılacak şekilde temsil edilmesini gerektirir. Görüntü kodlama teknikleri, görüntüleri piksel formatından modelin tahmin veya sınıflandırma sürecinde etkili bir şekilde kullanabileceği bir dizi özellik veya özniteliğe dönüştürmeye dayanır. Sıfır dolgu, evrişim katmanları ve özellik çıkarma teknikleri gibi teknikler kullanılarak görüntü temsili iyileştirilebilir ve böylece yapay zekâ modelinin nihai görevindeki performansı artırılabilir.

3.9. ÇALIŞMA AKIŞ ŞEMASI

Şekil 3.9'da veri toplama ve hazırlama, önerilen modellerin eğitimi ve sonuçları karşılaştırmak için çıktılar gibi adımları gösteren bir iş akışı Şeması gösterilmektedir.

Şekil 3.9: Çalışma Akış Şeması



Bu bölümde, çalışmanın temel metodolojisi ve kullanılan materyaller ayrıntılı olarak ele alındı. Yapay zeka, makine öğrenmesi ve derin öğrenme teknikleri, özellikle evrimsel sinir ağları üzerinde duruldu. Ayrıca, VGG16, ResNet50 ve EfficientNetB3 gibi önerilen CNN modelleri incelendi. Veri seti ve ön işlemlerle ilgili detaylar sağlandı ve çalışma akış şeması sunularak metodoloji adımları adım adım açıklandı.

Gelecek bölümde, elde edilen sonuçların sunulacağı ve analiz edileceği sonuçlar bölümüne geçeceğiz. Bu bölümde, CNN modellerinin performansı ve önerilen metodolojinin etkinliği hakkında ayrıntılı bir değerlendirme sunulacak. Elde edilen

bulgular, araştırmanın ana hedeflerine ne kadar uygun olduğunu gösterecek ve çalışmanın genel sonuçlarına ışık tutacaktır. Bu şekilde, çalışmanın ilerleyen bölümlerinde sunulacak sonuçların değerlendirilmesine bir giriş yapılacaktır.






DÖRDÜNCÜ BÖLÜM
BULGULAR VE TARTIŞMA

Bu bölümde, çalışmanın temel sonuçları ve bu sonuçların anlamı üzerine derinlemesine bir değerlendirme sunulacaktır. İlk olarak, elde edilen bulgular detaylı bir şekilde sunulacak ve CNN modellerinin performansı üzerine bir analiz yapılacaktır. Daha sonra, bu bulguların literatürdeki mevcut bilgilerle nasıl uyumlu olduğu ve araştırmanın ana hipotezleriyle nasıl ilişkilendirildiği tartışılacaktır.

4.1. ResNet50 SONUÇLARI

Şekil 4.1’de önerilen ResNet50 modelinin katman ve parametre değerleri gösterilmiştir.

Şekil 4.1: ResNet50 Modeli Katmanları ve Parametreleri



ResNet50 modelinin katmanlarını gösteren bir diyagramdır. Diyagram, her katmanın türünü, bağlantısını ve işlevini göstermektedir.

1. Giriş Katmanı:

- Bu katman, giriş verilerini kabul eder.
- Giriş verilerinin boyutları (None, 128, 128, 3)'tür.
- Bu, verilerin 128x128 piksel boyutunda ve 3 kanallı (kırmızı, yeşil, mavi) renkli görüntüler olduğu anlamına gelir.

2. resnet50:

- Bu katman, ResNet-50 modelidir.
- Bu model, büyük bir resim veri kümesi üzerinde eğitilmiştir.
- Bu katman, (None, 2048) boyutlarında çıktı üretir.

3. batch_normalization:

- Bu katman, toplu normalleştirme tekniğini uygular.
- Bu teknik, öğrenme sürecini hızlandırmaya ve modelin doğruluğunu geliştirmeye yardımcı olur.
- Bu katman, (None, 2048) boyutlarında çıktı üretir.

4. Dense Katmanı:

- Bu katman, verileri 2048 noktadan 256 noktaya dönüştürür.
- Bu katman, verilerin boyutunu küçültmek için kullanılır.

5. Dropout Katmanı:

- Bu katman, terk etme tekniğini uygular.
- Bu teknik, modelin eğitim verilerine aşırı uyum sağlamasını önlemeye yardımcı olur.
- Bu katman, (None, 256) boyutlarında çıktı üretir.

6. dense_1 Katmanı:

- Bu katman, 4 çıkışa sahip tam bağlantılı bir katmandır.
- Bu katman, görüntüleri 4 kategoriye sınıflandırmak için kullanılır.

Kısacası, bu model, görüntüleri işlemek ve analiz etmek için çeşitli katmanları kullanır, veri boyutunu azaltır ve görüntüleri farklı kategorilere sınıflandırır, doğru ve etkili sonuçlar üretmeye yardımcı olur.

Tablo 4.1, ResNet50 modelinin mimarisini gösteren bir tablodur. Tablo, modelin her katmanının türünü, çıktı şeklini ve parametre sayısını göstermektedir.

Tablo 4.1: Resnet50 Modelinin Mimarisi

Katman (tür)	Çıkış Şekli	Parametre #
resnet50 (Functional)	(None, 2048)	23587712
batch_normalization (Batch Normalization)	(None, 2048)	8192
dense (Dense)	(None, 256)	524544
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 4)	1028

Tablo 4.1’de, sinir ağının her katmanı için aşağıdaki bilgileri gösterir:

- **Katman Adı:** Bu, "resnet50" veya "dense" gibi katmanın adıdır.
- **Katman Türü:** Bu, "Functional" veya "Dense" gibi katmanın türüdür.
- **Çıkış Şekli:** Bu, katmanın ürettiği çıktının boyut ve şeklidir. Örneğin, "(None, 2048)", katmanın keyfi bir toplu iş boyutu ve 2048 özellik içeren bir tensör çıkardığı anlamına gelir.
- **Parametre Sayısı:** Bu, katmandaki parametre sayısıdır. Parametre sayısı, katmanın karmaşıklığını ve öğrenme kapasitesini belirler.

İlk birkaç katman için tablodaki bilgilerin dökümü aşağıdadır:

- **Katman Adı:** resnet50 (Functional)
- **Katman Türü:** Functional
- **Çıkış Şekli:** (None, 2048)
- **Parametre Sayısı:** 23.587.712

Bu katman, ResNet-50 adı verilen önceden eğitilmiş bir evrimsel sinir ağı (CNN) gibi görünüyor. Görüntü tanıma görevleri için etkili olduğu gösterilen popüler bir CNN mimarisidir. Katman, keyfi boyutlu bir giriş alır ve 2048 özellik içeren bir tensör üretir. Büyük parametre sayısı (23 milyondan fazla), bu katmanın karmaşık olduğunu ve verilerdeki karmaşık örüntüleri öğrenme yeteneğine sahip olduğunu gösteriyor.

- **Katman Adı:** batch_normalization
- **Katman Türü:** Batch Normalization

- **Çıkış Şekli:** (None, 2048)
- **Parametre Sayısı:** 8.192

Bu katman bir toplu normalleştirme katmanıdır. Toplu normalleştirme, derin sinir ağlarında eğitim sürecinin istikrarını artırmak için sıklıkla kullanılan bir tekniktir. Katman, keyfi boyutlu bir giriş alır ve 2048 özellik içeren bir tensör üretir, bu da bir önceki katmanın çıktısıyla aynıdır. Ancak, bu katmandaki parametre sayısı (8.192), bir önceki katmandaki parametre sayısından (23.587.712) çok daha düşüktür.

Tablo 4.2, ResNet50 modelinin bir test veri seti üzerindeki performansını gösteren bir tablodur. Tablo, modelin doğruluk, hata oranı ve kayıp fonksiyonu gibi performans metriklerini göstermektedir.


Tablo 4.2: ResNet50 Modelinin Performans Değerlendirmesi

Eğitim Kaybı	0.149042
Eğitim Doğruluğu	0.99609375
Doğrulama Kaybı	0.157977864
Doğrulama Doğruluğu	0.9921875
Test Kaybı	0.192620084
Test Doğruluğu	0.984375

ResNet50'nin beyin MR görüntülerini sınıflandırarak yapay sinir ağları kullanarak beyin tümörü tespiti yeteneği oldukça yüksektir. Eğitim ve test aşamalarında yüksek doğruluk elde edilmiştir. Model, eğitim verilerine uyum sağlamakta iyi performans göstermiştir ancak test verilerinde biraz zorlanmıştır. Karmaşıklığın azaltılması ve daha fazla veri kullanımı, modelin performansını artırabilir. Özetle, ResNet50, beyin MR görüntülerini sınıflandırarak yapay sinir ağları kullanarak beyin tümörü tespiti için etkili bir modeldir, ancak daha derinlemesine analiz gerektirmektedir.

Şekil 4.2, ResNet50 modelinin bir test veri seti üzerindeki performansını gösteren bir karışıklık matrisidir. Matris, modelin her sınıf için doğru ve yanlış tahminlerinin sayısını göstermektedir.

Şekil 4.2: ResNet50 Modeli için Karışıklık Matrisi



Bu çalışmada, ResNet50 modelinin MR görüntülerinden beyin tümörlerini sınıflandırmadaki performansını değerlendirmek için karışıklık matrisi kullanılmıştır. Satırlar gerçek beyin tümörü türlerini temsil ederken, sütunlar model tarafından tahmin edilen türleri temsil etmektedir. Hücrelerin içindeki değerler, her bir kategoride sınıflandırılan görüntü sayısını ifade etmektedir. Analizde, ana köşegen üzerindeki hücreler doğru sınıflandırılan görüntü sayısını temsil ederken, ana köşegen dışındaki hücreler yanlış sınıflandırılan görüntü sayısını temsil etmektedir.

Buna göre modelin doğruluğu, ana köşegen üzerindeki değerlerin toplamının toplam görüntü sayısına bölünmesiyle hesaplanır. Bu durumda, modelin doğruluğu %98,44'tür. Detaylı analizde, çok sayıda görüntü doğru sınıflandırılmıştır, ancak gliom ve menenjiom gibi bazı türler arasında sınıflandırmada bazı hatalar olmuştur. Sonuç olarak, model beyin tümörü sınıflandırmasında yüksek doğrulukla mükemmel performans göstermektedir. Bununla birlikte, modelin doğruluğu daha fazla veri toplanarak ve farklı veri kümeleri üzerinde eğitilerek ve ayrıca görüntü işleme ve veri

iyileştirme gibi diğer teknikler kullanılarak geliştirilebilir. Karışıklık matrisi sonuçları, ResNet50 modelinin MR görüntülerinden beyin tümörlerini sınıflandırmak için güçlü bir araç olduğunu göstermektedir.

Tablo 4.3, ResNet50 modelinin bir test veri seti üzerindeki performansını gösteren bir sınıflandırma raporudur. Rapor, modelin her sınıf için hassasiyet, geri çağırma, f1 skoru ve destek gibi performans metriklerini göstermektedir.

Tablo 4.3: ResNet50 Modeli için Sınıflandırma Raporu

	hassasiyet	recall	f1-score	support
glioma	0.97	0.98	0.98	152
meningioma	0.98	0.96	0.97	142
notumor	1	1	1	213
pituitary	0.99	1	1	149
doğruluk			0.99	656
macro avg	0.99	0.98	0.98	656
weighted avg	0.99	0.99	0.99	656

Tablo'da, sınıflandırma raporu ResNet50 modelinin tümörlerin varlığını tespit etmek için beyin MR görüntülerini sınıflandırmadaki performansını göstermektedir. Model, her bir kategori için performansını göstermek üzere matrisin her bir hücresindeki sayıları kullanır ve her bir kategoriye atanan satır duyarlılık, geri çağırma ve F1 oranı gibi ölçütleri gösterir.

Sonuçlar ayrıntılı olarak şu şekildedir:


- Duyarlılık (sensitivity): Tüm sınıflarda çok yüksek değerler gösterir, %97 ile %100 arasında değişir. Bu, modelin tüm beyin tümörlerini doğru şekilde tespit etme yeteneğini gösterir.
- Geri Çağırma (recall): Tüm sınıflarda çok yüksek değerler gösterir, %96 ile %100 arasında değişir. Bu, modelin tüm beyin tümörlerini doğru şekilde sınıflandırma yeteneğini gösterir.
- F1 Skoru: Tüm sınıflarda çok yüksek değerler gösterir, %97 ile %99 arasında değişir. Bu, hassasiyet ve geri çağırma arasında bir denge sağlayarak modelin genel doğruluğunu temsil eder.
- Doğruluk (accuracy): Çok yüksek bir değer gösterir (%99). Bu, modelin tüm görüntüleri doğru şekilde sınıflandırma yeteneğini gösterir.

Bu sonuçlar, ResNet50'nin MRI görüntülerinden beyin tümörlerini sınıflandırmak için etkili olduğunu ve yüksek doğruluk sağladığını göstermektedir. Ancak, modelin tam performansını anlamak için daha derinlemesine bir analiz gereklidir.

Ayrıca, kullanılan veri türü, veri seti boyutu, değerlendirme kriterleri ve diğer faktörlerin dikkate alınması önemlidir. Ayrıca, modelin genelleme yeteneğini doğrulamak için başka veri kümelerinde test edilmesi önerilir. Sonuç olarak, ResNet50'nin MRI görüntülerinden beyin tümörlerini sınıflandırmak için büyük potansiyele sahip olduğu ve bu tür tümörlerin teşhis ve tedavisini geliştirmeye yardımcı olabileceği ortaya çıkmaktadır.

Şekil 4.3, ResNet50 modelinin eğitim aşamasında kayıp fonksiyonu ve doğruluk değerlerinin değişimini gösteren bir eğridir. Eğri, modelin her epoch'ta (dönem) ne kadar iyi performans gösterdiğini gösterir.

Şekil 4.3: ResNet50 Modelinin Eğitim Kaybı ve Doğruluk Eğrisi



ResNet50 modelinin eğitim süreci boyunca beyin tümörlerini manyetik rezonans görüntüleme (MRG) resimlerinden sınıflandırma için kayıp ve doğruluk değerlerinin değişimini gösteren grafik, her terim için değerleri gösterir. Eksenler, yatayda modelin eğitildiği dönem sayısını, dikeyde ise kayıp ve doğruluk değerlerini temsil eder. Eğitim kaybı 0.149042, doğrulama kaybı 0.157977864 ve test kaybı 0.192620084 olarak hesaplandı. Doğruluk değerleri ise sırasıyla eğitim için %99.61, doğrulama için %99.22 ve test için %98.44 olarak bulundu.


Kayıp eğrisi, eğitim süreci boyunca sürekli olarak azaldığını gösterir, bu da modelin etkili bir şekilde öğrendiğini gösterir. Doğruluk eğrisi ise, veri sınıflandırmasındaki gelişmeyi göstermek için eğitim süreci boyunca sürekli artar.

Kesişim bölgesi, modelin eğitim ve test verilerini sınıflandırmada daha doğru hale geldiği noktayı gösterir, bu da modelin yeni verilere iyi bir şekilde genelleme yapabilme yeteneğini gösterir.

4.2. EfficientNetB3 SONUÇLARI

Şekil 4.4'te önerilen EfficientNetB3 modelinin katman ve parametre değerleri gösterilmiştir.

Şekil 4.4: EfficientNetB3 Modeli Katmanları Ve Parametreleri



Şekilde bir toplu işleme sisteminin ayrıntılı bir diyagramı gösterilmektedir. Sistem üç ana katmandan oluşmaktadır:

1. Giriş Katmanı:

Bu katman, modeldeki verilerin giriş noktasıdır. Bu katman, hastaların manyetik rezonans görüntülerini giriş olarak alır. Bu katmanın giriş boyutu (None, 128, 128, 3) olup:

- None: Toplu boyutunun belirlenmemiş olduğunu belirtir.
- 128: Görüntünün yüksekliğini belirtir , 128: Görüntünün genişliğini belirtir.
- 3: Görüntüdeki kanal sayısını belirtir. Her kanal farklı bir renki temsil eder (kırmızı, yeşil, mavi).

2.EfficientNetB3 Katmanı:

Bu katman, modelin özüdür. Önceden eğitilmiş büyük bir görüntü veri kümesi üzerinde eğitilmiş derin bir sinir ağıdır. Bu katman, manyetik rezonans görüntülerinden özellikler çıkarır. Bu katmanın çıkış boyutu (None, 1536) olup:

- None: Toplu boyutunun belirlenmemiş olduğunu belirtir.
- 1536: Görüntüden çıkarılan özelliklerin sayısını belirtir.

3. BatchNormalization Katmanı:

Bu katman, giriş verilerinin dağılımlarını normalize eder. Bu, eğitim sürecini hızlandırmaya ve modelin doğruluğunu artırmaya yardımcı olur. Bu katmanın çıkış boyutu (None, 1536) olup:

- None: Toplu boyutunun belirlenmemiş olduğunu belirtir.

4. Dense Katmanı:

Bu katman, giriş verilerini bir değer dizisine dönüştürür. Bu katmanın giriş boyutu (None, 1536) ve çıkış boyutu (None, 256) olup:

- None: Toplu boyutunun belirlenmemiş olduğunu belirtir.
- 256: Çıkış boyutunu belirtir.

5. Dropout Katmanı:

Bu katman, ağdan bazı sinir hücrelerini rastgele çıkarır. Bu, aşırı uyumu önlemeye ve modelin genelleme yeteneğini artırmaya yardımcı olur. Bu katmanın giriş boyutu (None, 256) ve çıkış boyutu (None, 256) olup:

- None: Toplu boyutunun belirlenmemiş olduğunu belirtir.
- 256: Çıkış boyutunu belirtir.

6. Dense Katmanı:

Bu katman, giriş verilerini bir değer dizisine dönüştürür. Bu katmanın giriş boyutu (None, 256) ve çıkış boyutu (None, 4) olup:

- None: Toplu boyutunun belirlenmemiş olduğunu belirtir.
- 4: Sınıf sayısını belirtir. Her sınıf, sınıflandırma kategorilerinden biridir (tümör yok, iyi huylu tümör, kötü huylu tümör).

7. Çıkış Katmanı:

Bu katman, modelden verilerin çıkış noktasıdır. Bu katman, her hastada beyin tümörü olasılıklarını çıkarır. Bu katmanın çıkış boyutu (None, 4) olup:

- None: Toplu boyutunun belirlenmemiş olduğunu belirtir.
- 4: Sınıf sayısını belirtir. Her sınıf, sınıflandırma kategorilerinden biridir (tümör yok, hipofiz, gloima, menenjeyom).

Parametreler:

Her bloktaki toplama ve döndürme filtrelerinin sayısı:

- Bu parametre, görüntüden çıkarılan temsillerin karmaşıklığını belirler.
- Daha büyük değerler daha detaylı temsiller sağlar ancak daha fazla hesaplama gerektirir.

Toplama ve döndürme penceresi boyutu:

- Bu parametre, her adımda analiz edilen görüntü bölgesinin boyutunu kontrol eder.
- Daha küçük değerler daha küçük özelliklere odaklanırken, daha büyük değerler daha büyük özelliklere odaklanır.

Sızıntı oranı:

- Bu katsayı, sızıntı katmanındaki aktivasyonların düşürülme oranını belirler.
- Daha büyük değerler daha fazla agresif sızıntı sağlar, bu da genelleştirmeyi artırabilir ancak eğitim doğruluğunu azaltabilir.

Aktivasyon Fonksiyonu:

- Aktivasyon fonksiyonu, birim çıkışlarını yeni değerlere dönüştürme yöntemini belirler.

- Yaygın aktivasyon fonksiyonları ReLU, sigmoid ve tanh'dir.

Notlar:

Bu parametre değerleri, manyetik rezonans görüntüleriyle beyin tümörlerini sınıflandırmak için dikkatlice ayarlanmış bir veri kümesi kullanılarak mükemmel şekilde ayarlanmıştır. Bu değerlerin değiştirilmesi, modelin performansını belirli veri seti ve görevine bağlı olarak iyileştirebilir veya kötüleştirebilir. Modelin yapısı, katmanların eklenmesi veya çıkarılması veya sıralarının değiştirilmesi gibi değişikliklerle de ayarlanabilir. Bu, belirli görevler için modelin performansını artırabilir.

Tablo 4.4, EfficientNetB3 modelinin mimarisini gösteren bir tablodur. Tablo, modelin her katmanının türünü, çıktı şeklini ve parametre sayısını göstermektedir.

Tablo 4.4: EfficientNetB3 Modelinin Mimari Özeti

Katman (tür)	Çıkış Şekli	Parametre #
efficientnetb3 (Functional)	(None, 1536)	10783535
batch_normalization_4 (Batch Normalization)	(None, 1536)	6144
dense_12 (Dense)	(None, 256)	393472
dropout_6 (Dropout)	(None, 256)	0
dense_13 (Dense)	(None, 4)	1028

Tablo'da Giriş katmanı MR görüntülerini modele girdi olarak alır ve aynı anda birden fazla görüntü grubunu işleyebilir. Görüntü boyutları 128 piksel yüksekliğinde ve 128 piksel genişliğindedir ve 3 renk kanalından (RGB) oluşur. EfficientNetB3 katmanı MRI görüntülerinden karmaşık özellikler çıkarır ve çıktı boyutlarını görüntü başına 1536 özellikle sınırlar. Sıcak normalleştirme katmanı, eğitim sürecini hızlandırmak ve model doğruluğunu artırmak için giriş verilerinin dağılımlarını normalleştirir ve her katmanda aynı sayıda görüntüyü işler. Yoğunluk katmanı, çıkarılan özellikleri bir değerler vektörüne dönüştürür ve bu özellikler 1536'dan 256 değere sıkıştırılır. Bırakma katmanı, aşırı uyumu önlemek ve modelin genelleme yeteneğini geliştirmek için bazı sinirsel işlem birimlerini rastgele kaldırır. Son olarak, çıktı katmanı verileri bir olasılıklar vektörüne dönüştürür ve çıktı her görüntü için 4 değer olarak boyutlandırılır, burada her değer belirli bir sınıftan bir beyin tümörüne sahip olma olasılığını temsil eder.

Tablo 4.5, EfficientNetB3 modelinin farklı veri setleri üzerindeki performansını göstermektedir. Tablo, modelin doğruluk, hata oranı ve kayıp fonksiyonu gibi performans metriklerini göstermektedir.

Tablo 4.5: EfficientNetB3 Modelinin Doğruluk Sonuçları


Eğitim Kaybı	0.151839
Eğitim Doğruluğu	1
Doğrulama Kaybı	0.160897791
Doğrulama Doğruluğu	0.9921875
Test Kaybı	0.163254336
Test Doğruluğu	0.99609375

Tablo, EfficientNetB3 modelinin MR görüntülerini kullanarak beyin tümörlerini sınıflandırmadaki performansını göstermektedir; burada performans beş ana göstergeye ayrılmıştır: eğitim kaybı ve eğitim doğruluğu, doğrulama kaybı ve doğrulama doğruluğu ve test kaybı ve test doğruluğu. Ortalama eğitim kaybı ve eğitim doğruluğu modelin eğitim aşamasındaki performansının göstergeleri, doğrulama kaybı ve doğrulama doğruluğu modelin eğitilmediği veriler üzerinde etkili bir şekilde çalışabilme yeteneğini yansıtmaktadır. Test kaybı ve test doğruluğuna gelince, bunlar modelin daha önce kendisine sunulmamış tamamen yeni verilerle başa çıkmadaki etkinliğini göstermektedir.

Tabloda gösterilen sonuçlar, EfficientNetB3 modelinin beyin tümörlerini sınıflandırmadaki gücünü ve etkinliğini yansıtmaktadır. Model %100'lük bir eğitim doğruluğuna ulaşmıştır, bu da eğitim verilerindeki tüm örnekleri doğru bir şekilde sınıflandırabildiği anlamına gelmektedir. Ayrıca %99,21 gibi yüksek bir doğrulama doğruluğu elde etmiştir, bu da modelin doğrulama verilerindeki örneklerin çoğunu doğru bir şekilde sınıflandırabildiği anlamına gelmektedir. Son olarak, %99,61'lik bir test doğruluğu elde etmiştir, bu da test verilerini çok etkili bir şekilde işleme yeteneğini göstermektedir. Bu sonuçlar, modelin büyük bir genelleme kabiliyetine sahip olduğunu ve bu nedenle MR görüntülerini kullanarak beyin tümörlerini başarılı bir şekilde sınıflandırmak için güçlü bir aday olduğunu göstermektedir.

Şekil 4.5, EfficientNetB3 modelinin bir test veri seti üzerindeki performansını gösteren bir karışıklık matrisidir. Matris, modelin her sınıf için doğru ve yanlış tahminlerinin sayısını göstermektedir.

Şekil 4.5: EfficientNetB3 Modeli için Karışıklık Matrisi



Şekilde EfficientNetB3 modelinin MR görüntülerini kullanarak beyin tümörlerini sınıflandırmadaki performansı gösterilmektedir. Matris dört satır ve dört sütundan oluşmaktadır. Satırlar gerçek tümör tipi kategorilerini temsil ederken, sütunlar model tarafından yapılan tahminleri temsil etmektedir. Satırlarda her kategori hipofiz, tümör yok, meningioma ve diğer beyin tümörü gibi farklı bir tümör türünü temsil etmektedir. Sütunlar, modelin her bir kategori için doğru ya da yanlış tahminlerini göstermektedir.

Matris analizi, EfficientNetB3 modelinin beyin tümörü sınıflandırmasında genel olarak iyi performans gösterdiğini ortaya koymaktadır. Örneklerin çoğu doğru sınıflandırılmıştır, ancak bazı hatalar da olmuştur. Örneğin, örneklerin büyük bir kısmı hipofiz ve tümör yok olarak doğru bir şekilde sınıflandırılmıştır, ancak örneklerin menenjiyom ve diğer beyin tümörleri olarak sınıflandırılmasında bazı hatalar olmuştur.

Genel olarak, EfficientNetB3 modeli MRG kullanarak beyin tümörlerini iyi bir şekilde sınıflandırabiliyor gibi görünmektedir, ancak bazı sınıflandırma hataları dikkate alınmalıdır.

Tablo 4.6, EfficientNetB3 modelinin bir test veri seti üzerindeki performansını gösteren bir sınıflandırma raporudur. Rapor, modelin her sınıf için hassasiyet, geri çağırma, f1 skoru ve destek gibi performans metriklerini göstermektedir.

Tablo 4.6: EfficientNetB3 Modeli için Sınıflandırma Raporu

	precision	recall	f1-score	support
glioma	0.99	0.97	0.98	152
meningioma	0.98	0.99	0.98	158
notumor	1	1	1	197
pituitary	1	1	1	149
accuracy			0.98	656
macro avg	0.98	0.98	0.98	656
weighted avg	0.98	0.98	0.98	656

Tablo 4.6'da EfficientNetB3 modelinin MRI görüntülerini kullanarak beyin tümörlerini sınıflandırmadaki etkinliği gösterilmektedir. Bazı önemli noktaları gözden geçirelim:

1. Kesinlik:

Modelin pozitif örnekleri ne ölçüde doğru tanımlayabildiğini gösterir. Bu bağlamda, doğruluk değerleri tüm tümör tipleri için yüksektir, bu da modelin farklı kategoriler arasında doğru bir şekilde ayrım yapabildiği anlamına gelir.

2. Geri Çağırma:

Modelin mevcut tüm pozitif örnekleri tespit etme kabiliyetini ölçer. Bu bağlamda, geri çağırma sonuçları da yüksektir, bu da modelin tümörleri kapsamlı bir şekilde tespit etme yeteneğini gösterir.

3. F1-Skoru:

Kesinlik ve geri çağırma arasında dengeli bir ölçü olarak kabul edilir. Tüm sınıflar için ortalama 0,98 F-Skoru ile model, hassasiyet ve geri çağırma arasında bir denge sağlama konusunda yüksek bir yetenek göstermektedir.

4. Destek:

Her kategoride kullanılan örnek sayısını ifade eder. Her sınıf için yüksek destek, modelin çok çeşitli örnekler üzerinde eğitildiğini gösterir.


5. Genel Doğruluk:

Modelin 0,98 olan genel doğruluğunu gösterir; bu da modelin %98 oranında doğru sınıflandırma yapabildiği anlamına gelir.

Genel olarak tablo, EfficientNetB3 modelinin MR görüntülerini kullanarak beyin tümörlerini sınıflandırmada mükemmel performans elde edebildiğini ve bu koşulları doğru ve etkili bir şekilde teşhis etmek için güçlü bir araç haline geldiğini göstermektedir.

Şekil 4.6, EfficientNetB3 modelinin eğitim aşamasında kayıp fonksiyonu ve doğruluk değerlerinin değişimini gösteren bir eğridir. Eğri, modelin her epoch'ta (dönem) ne kadar iyi performans göstermektedir.

Şekil 4.6: EfficientNetB3 Modelinin Eğitim Kaybı ve Doğruluk Eğrisi



Şekilde EfficientNetB3 modelinin MRI görüntülerini kullanarak beyin tümörlerini sınıflandırmak üzere eğitilirken elde ettiği çıktı gösterilmektedir. Soldaki grafik, modelin eğitim sırasında yaşadığı kaybı temsil eden ve 0 ile 2,5 arasında değişen değerlere sahip "kayıp" dikey eksenini göstermektedir. Bu grafikte, eğitim epoklarının sayısı arttıkça kaybın azaldığı ve modelin performansının giderek iyileştiği görülmektedir.


Sağdaki grafik, değerleri 0 ile 0,9 arasında değişen ve modelin elde ettiği sınıflandırma doğruluğunu temsil eden "doğruluk" dikey eksenini göstermektedir. Bu grafikte, eğitim süreci ilerledikçe doğrulukta bir artış görebiliriz, bu da modelin görüntüleri daha yüksek doğrulukla sınıflandırma yeteneğini gösterir.

EfficientNetB3'ü MR görüntülerini kullanarak beyin tümörü sınıflandırmasında kullanan model, eğitim epoklarının sayısı arttıkça performansında sürekli bir iyileşme göstererek yüksek sınıflandırma doğruluğu elde etme ve eğitim sırasında kaybı azaltma yeteneğini yansıtmaktadır.

4.3. VVG16 SONUÇLARI

Şekil 4.7, VGG16 modelinin katmanlarını gösteren bir diyagramdır. Diyagram, her katmanın türünü, bağlantısını ve işlevini göstermektedir.

Şekil 4.7: VVG16 Modeli Katmanları ve Parametreleri



Şekil 4.7, AlexNet tarafından geliştirilen derin sinir ağı modeli olan VGG16'nın önerilen algoritmasının bir akış diyagramını göstermektedir. Bu model, ImageNet veri kümesinde önceden eğitilmiş olup, görüntülerden özellikler çıkarmada başarılıdır. Bu çalışmada, VGG16 modeli, beyin tümörlerinin manyetik rezonans görüntülerinden özellikler çıkarmak için kullanılmaktadır. Algoritma, üç ana gruba ayrılabilen 15 katmandan oluşur:

1. Özellik çıkarma katmanları:

- Giriş katmanı (vgg16_input): Bu katman, $128 \times 128 \times 3$ boyutunda manyetik rezonans görüntüsünü alır.
- VGG16 Katmanı: Bu katman, önceden eğitilmiş VGG16 modelini kullanarak manyetik rezonans görüntüsünden özellikler çıkarır. VGG16, genel görüntü sınıflandırma görevi üzerinde eğitilmiş olduğundan, çeşitli görüntülerden faydalı özellikler çıkarabilir, bu da manyetik rezonans görüntülerini içerir.

2. Özellik işleme katmanları:

- Fonksiyonel katman: Bu katman, VGG16 çıkışlarını $4 \times 4 \times 512$ boyutunda dört boyutlu bir diziye yeniden şekillendirir.
- Düzleştirme katmanı (flatten 3): Fonksiyonel katman çıkışlarını 8192 boyutunda tek boyutlu bir diziye düzleştirir.
- Düzleştirme katmanı (Flatten): Önceki katmanın çıkışlarını aynı adla yeniden adlandırır.
- Yoğun katmanlar (dense 11-15): Önceki katmanların çıkışlarına farklı sayıda birimlerle yoğun aktivasyon işlevleri uygulanır (256, 128, 64, 32).
- Bırakma katmanları (dropout_8-11): Yoğun katman çıkışlarına %50 oranında bırakma uygulanır.
- Özellik işleme katmanları, VGG16'dan çıkarılan manyetik rezonans görüntüsü özelliklerini daha belirgin bir temsil haline dönüştürmeyi amaçlar.

3. Çıkış katmanı:

- Yoğun 15. katman (dense_15): Önceki katmanın çıkışlarına 4 birimli yoğun bir aktivasyon işlevi uygulanır.
- Bu katman, manyetik rezonans görüntüsünü iki sınıftan birine (sağlam veya tümör içeren) sınıflandırmak için kullanılır.

Parametreler

- Algoritma, birkaç parametreye sahiptir, en önemlileri:
- Her yoğun katmandaki birim sayısı: Bu parametreler, her yoğun katmandaki nöron sayısını belirler.
- Bırakma oranı: Bu parametreler, her yoğun katmandaki rastgele düşürülen nöronların oranını belirler.
- Aktivasyon fonksiyonu: Bu parametreler, her yoğun katman çıkışlarına uygulanan işlevi belirler.

Tablo 4.7, VGG16 modelinin mimarisini göstermektedir. Tablo, modelin her katmanının türünü, çıktı şeklini ve parametre sayısını göstermektedir.

Tablo 4.7: VGG16 Modelinin Mimari Özeti

Katman (tür)	Çıkış Şekli	Parametre #
vgg16 (Functional)	(None, 4, 4, 512)	14714688
flatten_3 (Flatten)	(None, 8192)	0
dense_11 (Dense)	(None, 256)	2097408
dropout_8 (Dropout)	(None, 256)	0
dense_12 (Dense)	(None, 128)	32896
dropout_9 (Dropout)	(None, 128)	0
dense_13 (Dense)	(None, 64)	8256
dropout_10 (Dropout)	(None, 64)	0
dense_14 (Dense)	(None, 32)	2080
dropout_11 (Dropout)	(None, 32)	0
dense_15 (Dense)	(None, 4)	132

Tablo'da, beyin manyetik rezonans görüntülerinin sınıflandırılması için kullanılan VGG16 modelinin katmanlarının özetini sunmaktadır. Her katmanın türü, çıkış biçimi, parametre sayısı, kullanılan aktivasyon fonksiyonu, giriş ve çıkış boyutları ile çekirdek parametre sayısı gibi temel bilgileri içermektedir.

Katmanlar, temel olarak üç ana kategoriye ayrılabilir:

1. Özellik çıkarma katmanları: Verilerden özellikler çıkarır, örneğin, VGG16 katmanı beyin manyetik rezonans görüntülerinden özellikler çıkarır.
2. Özellik işleme katmanları: Çıkarılan özellikleri görev için daha belirgin bir temsile dönüştürür, örneğin, düzleştirme ve yoğun katmanlar özellik çıkarma katmanlarının ardından gelir.
3. Çıkış katmanı: Son tahmini üretir, modelin son yoğun katmanını içerir.

Bu bilgiler, tabloda VGG16 modelinin yapısını ve beyin tümörlerinin sınıflandırılmasında nasıl çalıştığını temel bir anlayış sağlar.

Tablo 4.8, VGG16 modelinin farklı veri setleri üzerindeki performansını göstermektedir. Tablo, modelin doğruluk, hata oranı ve kayıp fonksiyonu gibi performans metriklerini göstermektedir.


Tablo 4.8: VGG16 Modelinin Performans Değerlendirmesi

Eğitm Kaybı	0.182992
Eğitm Doğruluğu	0.95703125
Doğrulama Kaybı	0.278595299
Doğrulama Doğruluğu	0.9140625
Test Kaybı	0.247841284
Test Doğruluğu	0.92578125

Bu çalışmada, VGG16 modelinin birden fazla veri kümesini adlandırmadaki etkinliği değerlendirilmiştir. Model bir dizi görüntü üzerinde eğitilmiş ve eğitim, doğrulama ve test için ayrı veri kümeleri kullanılarak değerlendirilmiştir. Çalışmanın sonuçları, VGG16 modelinin birden fazla veri kümesi desenini sınıflandırmada iyi performans gösterdiğini ortaya koymuştur; eğitim, doğrulama ve test sonuçları aşağıdaki gibidir: eğitim kaybı: 0.182992, eğitim doğruluğu: 0.95703125, doğrulama kaybı: 0.278595299, doğrulama doğruluğu: 0.9140625, test kaybı: 0.247841284 Test doğruluğu: 0.92578125. Sonuçların analizi, kayıp, doğrulama kaybı ve test kaybından çok daha düşük olduğu ve eğitim doğruluğu yüksek olduğu için modelin veri setleriyle etkili bir şekilde başa çıkabildiğini göstermektedir, bu da eğitim verilerinden iyi öğrenme yeteneğini gösterir ve doğrulama ve test doğruluğu da yüksektir, bu da yeni verilere genelleme yeteneğini gösterir. Bu sonuçlar, VGG16 modelinin birden fazla veri kümesi örüntüsünü adlandırmadaki etkinliği için güçlü kanıtlar sağlamaktadır.

Şekil 4.8, VGG16 modelinin meningioma, notumor, pituitary ve glioma içeren bir test veri seti üzerindeki performansını gösteren bir karışıklık matrisidir. Matris, modelin her sınıf için doğru ve yanlış tahminlerinin sayısını göstermektedir.

Şekil 4.8: VGG16 Modeli için Karışıklık Matrisi



Şekilde, MR görüntü sınıflandırması yoluyla beyin tümörlerini tespit etmek için kullanılan VGG16 modelinin karışıklık matrisi gösterilmektedir. Matris, her hücrenin doğru veya yanlış sınıflandırılan görüntü sayısını temsil ettiği 5 satır ve 5 sütundan oluşmaktadır.

Beş satır beyin görüntüsünün gerçek kategorisini göstermektedir: "tümör yok", "hipofiz tümörü", "meningeal tümör" ve "glioma tümörü".

Sütunlar, VGG16 modeli tarafından beyin görüntüsü için öngörülen sınıfı temsil eder ve gerçek sınıflara karşılık gelir.

Hücrelerdeki sayılar, her bir kategori içinde doğru veya yanlış sınıflandırılan görüntü sayısını temsil etmektedir. Örneğin, gerçek kategori "Tümör yok" ise, ilk satırdaki ve ilk sütundaki hücre kaç görüntünün doğru sınıflandırıldığını gösterir ve bu böyle devam eder.

Analiz, modelin beyin MR görüntülerini yüksek doğrulukla sınıflandırabildiğini, ancak bazı sınıflandırma hataları olduğunu göstermektedir. Örneğin, bazı görüntüler "hipofiz tümörü" yerine "tümör yok" olarak yanlış sınıflandırılmıştır.

VGG16 modeli, yüksek doğruluğa sahip olduğundan ve beyin tümörü vakalarının belirlenmesine yardımcı olmak için bir teşhis aracı olarak kullanılabileceğinden, MRG sınıflandırması yoluyla beyin tümörlerini tespit etmek için etkili bir araçtır.

Tablo 4.9, VGG16 modelinin bir test veri seti üzerindeki performansını gösteren bir sınıflandırma raporudur. Rapor, modelin her sınıf için hassasiyet, geri çağırma, f1 skoru ve destek gibi performans metriklerini göstermektedir.

Tablo 4.9: VGG16 Modeli için Sınıflandırma Raporu

	kesinlik	recall	f1- skor	Destek
glioma	0.9	0.88	0.89	152
meningioma	0.85	0.82	0.84	142
notumor	0.96	0.99	0.97	213
pituitary	0.95	0.95	0.95	149
accuracy			0.92	656
macro avg	0.91	0.91	0.91	656
weighted avg	0.92	0.92	0.92	656


Tablo'da, sınıflandırma raporu VGG16 modelinin tümörlerin varlığını tespit etmek için beyin MR görüntülerini sınıflandırmadaki performansını göstermektedir. Model, her bir kategori için performansını göstermek üzere matrisin her bir hücreindeki sayıları kullanır ve her bir kategoriye atanan satır duyarlılık, geri çağırma ve F1 oranı gibi ölçütleri gösterir.

Örneğin, "glioma" ile ilişkili satır, modelin glioblastoma tümör sınıflandırması için 0,90 duyarlılık, 0,88 geri çağırma ve 0,89 F1 oranı elde ettiğini gösterir. Buna ek olarak, "doğruluk" satırı modelin genel doğruluğunun 0,92 olduğunu, yani vakaların %92'sini doğru sınıflandırdığını göstermektedir.

VGG16 modelinin sınıflandırmada iyi performans gösterdiğini ve neredeyse tüm sınıflar için yüksek duyarlılık ve geri çağırma elde ettiğini göstermektedir. Bu, çoğu gerçek pozitif vakayı tanımlayabildiği ve negatif vakaları yanlış tanımlamaktan kaçındığı anlamına gelir. Güçlü yönler arasında modelin tüm tümör tipleri için elde ettiği yüksek hassasiyet yer almaktadır ve bu da modelin çoğu gerçek pozitif vakayı belirleme kabiliyetini yansıtmaktadır. Modelin elde ettiği yüksek doğruluk, beyin tümörü olan

hastalar ile beyin tümörü olmayan hastalar arasında güvenilir bir ayırım yapabildiğini göstermektedir.

Şekil 4.9: VGG16 Modelinin Eğitim Kaybı ve Doğruluk Eğrisi



Şekil 4.9, VGG16 modelinin eğitim aşamasında kayıp fonksiyonu ve doğruluk değerlerinin değişimini gösteren bir eğridir. Eğri, modelin her epoch'ta (dönem) ne kadar iyi performans gösterdiğini gösterir.

Detaylar:

- Model: VGG16
- Eğitim Kaybı (Training Loss): Modelin tahminleri ile gerçek değerler arasındaki hatayı gösterir.
- Eğitim Doğruluk (Training Accuracy): Modelin doğru şekilde sınıflandırdığı örneklerin oranını gösterir.
- Epoch: Eğitim verilerinin model üzerinde bir kez geçirilmesi.

Bu çalışma, derin öğrenme algoritmalarının kullanıldığı bir sınıflandırma prosedürüyle beyin MR görüntülerinde tespit edilen tümörleri araştırmıştır. Çalışmada, üç farklı derin sinir ağı (CNN) modeli değerlendirilmiştir: VGG16, EfficientNetB3 ve ResNet50. ResNet50, artan ağ derinliğinin performans düşüşüne neden olan sorunu ele alması açısından tercih edilmiştir. EfficientNetB3, yüksek hesaplama verimliliği ve üstün performansı nedeniyle seçilmiştir. VGG16, basitliği ve görsel özelliklerin etkili bir şekilde bilgi çıkarma yeteneği nedeniyle tercih edilmiştir. Çalışmada, EfficientNetB3 modeli en yüksek doğruluk oranını (%99.21) elde etmiş ve VGG16 ile ResNet50'yi geride

bırakmıştır. Bu sonuçlar, EfficientNetB3'ün hesaplama kaynaklarını verimli bir şekilde kullanma yeteneği, model doğruluğu ile hesaplama verimliliği arasında denge kurmak için kullandığı Compound Scaling teknolojisi ve verilerdeki ayırt edici özellikleri daha iyi öğrenme yeteneği ile bağlantılıdır. Bu çalışmanın sonuçları, derin öğrenme tekniklerinin beyin tümörlerini yüksek doğrulukla sınıflandırma potansiyelini vurgulamaktadır ve bu da beyin tümörlerinin teşhis ve tedavisinde önemli bir ilerleme potansiyeline işaret etmektedir.





BEŞİNCİ BÖLÜM
SONUÇ VE ÖNERİLER

5.1. SONUÇ VE ÖNERİLER

Beyin tümörleri, bazı vakalarda ölümcül olabilen sonuçlarıyla çok ciddi bir sağlık sorununu temsil etmekte ve hızlı tanı ve tedavi ihtiyacını kesinlikle gerekli kılmaktadır. Bu bağlamda, yeni teknolojiler bu karmaşık vakalara ilişkin anlayışımızı ve tedavimizi geliştirmede önemli bir rol oynamaktadır. Yapay zeka ve derin öğrenme gibi teknolojilerle, tıbbi verileri verimli ve doğru bir şekilde analiz etmek için bilgi işlem kullanılabilir.

Bu teknolojilerin başarısı, tıbbi görüntüleme görüntülerinde beyin tümörlerinin varlığını erken aşamalarında bile gösterebilecek belirli kalıpları tanıma yeteneklerine bağlıdır. Örneğin yapay zeka, beyin yapısındaki anormal değişikliklere işaret eden karakteristik kalıpları belirleyerek erken ve doğru teşhise yardımcı olabilir.

Kısacası, beyin tümörlerinin tıbbi görüntüleme görüntülerinin analizinde modern teknolojilerin kullanılması, sağlık hizmetlerinin iyileştirilmesi ve bu zor vakaların tedavisinde başarı şansının artırılması yönünde önemli bir adımı temsil etmektedir.

Bu çalışma, beyin tümörü teşhisi alanında derin öğrenme ve yapay zeka tekniklerinden yararlanarak teşhis doğruluğunu artırmaya ve tümörleri daha doğru bir şekilde ayırt etmeye odaklanmaktadır. Bu bağlamda, VGG16, EfficientNetB3 ve ResNet50 olmak üzere üç derin sinir ağı mimari modeli kullanılmıştır.

Bu modeller, beynin tıbbi görüntülerinden farklı özellikleri verimli bir şekilde çıkarma ve tümörler ile normal dokular arasındaki benzerlikleri ve farklılıkları yüksek doğrulukla tanıyabilen makine öğrenimi modelleri oluşturma yeteneğine sahiptir.


Bu çalışmadan elde ettiğimiz sonuçlar, bu modelleri kullanarak beyin tümörlerini tanımlamada dikkate değer bir verimlilik göstermiştir. Bu modeller, beyin tümörlerini sağlıklı dokulardan ayırt etmede olağanüstü performans sağlayarak teşhis süreçlerinin etkinliğini ve doğruluğunu artırmıştır.

Bu sonuçlar, beyin tümörü olan hastaların bakımının iyileştirilmesine yönelik önemli bir adım olarak değerlendirilmektedir; çünkü bu gelişmiş teknolojiler, bu durumların daha hızlı ve doğru bir şekilde tanımlanmasına yardımcı olarak doktorlara ve hastalara durumla etkileşime girme ve tedaviyi uygun ve etkili bir şekilde yönlendirme konusunda daha iyi fırsatlar sunabilir.

Tablo 5.1: Derin Öğrenme Modellerinin Beyin Tümörü Tanısındaki Doğruluğu

Model	Doğruluk
EfficientNetB3	0.99
ResNet50	0.98
VGG16	0.91

Yukarıdaki tablo, doğruluk ve verimlilik açısından görüntü tanımadaki farklı sinir ağı modellerini göstermektedir. EfficientNetB3 %99 ile en yüksek doğruluğu elde ederken, ResNet50 %98 ve VGG16 %91 doğruluk elde etmiştir. Verimlilik açısından, EfficientNetB3 işlemede hızlı olduğu ve daha az güç tükettiği için en yüksek seviyeye ulaşırken, ResNet50'nin verimliliği iyi ve VGG16 için ortalama idi. Tablodan, EfficientNetB3'ün doğruluk ve verimlilik açısından görüntü tanıma için en iyi model olduğu sonucuna varılmıştır. Modellerin doğruluğu ve verimliliğinin eğitim için kullanılan veri türüne bağlı olarak değişebileceği ve verimliliklerinin de onları çalıştırmak için kullanılan cihaza bağlı olarak değişebileceği unutulmamalıdır.

Şekil 5.1: Derin Öğrenme Modellerinin Beyin Tümörü Tanısındaki Doğruluğu

Üç sinir ağı modelinin doğruluğu ve verimliliği üzerine yapılan bir çalışmadan elde edilen grafik gösterilmektedir: Görüntü tanıma VGG16, ResNet50 ve EfficientNetB3. Yatay eksen çalışmada kullanılan modelleri temsil ederken, dikey eksen her bir modelin her bir tümör türünü tanımlamadaki doğruluk yüzdesini temsil etmektedir. Grafik, EfficientNetB3'ün görüntü tanıma doğruluğu açısından en iyi model olduğunu ve her üç tümör türünde de en yüksek doğruluğu elde ettiğini göstermektedir. Bu analiz, modellerin doğruluk ve verimliliğinin eğitim için kullanılan veri türüne ve bunları çalıştırmak için kullanılan cihaza bağlı olarak değişebileceği gözlemleriyle desteklenmektedir.

Derin öğrenme teknikleri kullanılarak modeller verileri daha iyi anlayacak şekilde eğitilebilir ve böylece teşhis doğrulukları artırılabilir. Örneğin, mevcut modeller derinlikleri ve karmaşıklıkları artırılarak veya eğitim yöntemleri geliştirilerek ve sinir ağlarında kullanılan ağırlıklar iyileştirilerek geliştirilebilir. Ayrıca bu modeller, modellerin tıbbi raporlar gibi karmaşık verileri daha iyi anlamasına yardımcı olan doğal dil işleme gibi diğer teknolojilerle birleştirilebilir.

Ayrıca, derin öğrenme alanında, sistemin doğrudan verideki önemli unsurlara odaklandığı ve özellikle beyin tümörü teşhisi gibi karmaşık vakalarla uğraşırken teşhiste daha fazla doğruluk ve etkinlik sağlayan dikkat tabanlı derin öğrenme gibi yeni teknikler keşfedilebilir. . Modellerin iyileştirilmesi ve yeni teknolojilerin keşfedilmesine yönelik bu sürekli çabalar, sağlık hizmetlerinin geliştirilmesine ve çeşitli hastalıkların tedavi sonuçlarının iyileştirilmesine katkıda bulunmaktadır.

Gelecek çalışmalar

- Farklı beyin tümörü türlerini tanımlamak için gelişmiş modeller geliştirmek: İyi huylu ve kötü huylu gibi farklı beyin tümörü türlerini ayırt edebilen modeller geliştirmek ve farklı kötü huylu tümör türlerini ayırt etmek için derin öğrenme teknikleri araştırılabilir.
- Kapsamlı verilerle tanısal doğruluğun artırılması: Derin öğrenme modellerinin doğruluğunu ve tahmin edilebilirliğini artırmak için MR ve BT verileri ve hastaların tıbbi geçmişleri de dahil olmak üzere daha büyük ve daha çeşitli beyin tümörü veri kümeleri toplanabilir.
- Yeni teknolojilerin entegrasyonu: Derin öğrenme alanında dikkat temelli derin öğrenme ve hızlı derin sinir ağları gibi yeni teknolojilerin araştırılması ve beyin tümörü teşhisinin doğruluğunu artırmak için bunların mevcut modellerle entegre edilmesi.
- Hızlı ve otomatik teşhiste yapay zeka uygulaması: Tıbbi görüntüler üzerinden beyin tümörlerine hızlı ve otomatik tanı koyabilen, uygun tedavinin daha hızlı sağlanmasına ve tedavi sonuçlarının iyileştirilmesine yardımcı olan yapay zeka sistemlerinin geliştirilmesi.
- Mobil uygulamalar ve tanı araçları geliştirilmesi: Beyin tümörlerinin teşhisine yardımcı olmak için makine öğrenimine dayalı mobil uygulamalar ve teşhis araçları geliştirmek, bunları hastalar ve doktorlar için daha etkili ve erişilebilir hale getirmek.

- Klinik uygulanabilirlik çalışması: Derin öğrenme modellerinin beyin tümörlerini tespit etmedeki etkinliğini değerlendirmek ve teşhis doğruluğunu artırma ve hastalığın ilerlemesini tahmin etme yeteneklerini belirlemek için bunları geleneksel teşhislerle karşılaştırmak için klinik çalışmalar yapılabilir.

Sonuç olarak, derin öğrenme modelleri beyin tümörü tespitinin verimliliğini ve doğruluğunu artırmak için heyecan verici fırsatlar sunmaktadır. Bu modeller, bu alandaki yeni teknolojileri keşfederek ve en iyi uygulamaları kullanarak etkili ve yenilikçi tanı araçlarının geliştirilmesine katkıda bulunabilir. Teknoloji geliştikçe ve mevcut veri miktarı arttıkça, beyin metastazlarını tespit etmek için derin öğrenme modellerini kullanmak, hasta bakımını iyileştirmenin ve daha doğru ve etkili tedaviler sağlamanın anahtarıdır.



KAYNAKÇA

- Ahmad, S., & Choudhury, P. K. (2022). On the performance of deep transfer learning networks for brain tumor detection using MR images. *IEEE Access*, 10, 59099-59114.
- Albashish, D., Al-Sayyed, R., Abdullah, A., Ryalat, M. H., & Almansour, N. A. (2021, 2 May). *Deep CNN model based on VGG16 for breast cancer classification*. Retrieved from: https://www.researchgate.net/publication/353491195_Deep_CNN_Model_based_on_VGG16_for_Breast_Cancer_Classification.
- Al-Zoghby, A. M., Al-Awadly, E. M. K., Moawad, A., Yehia, N., & Ebada, A. I. (2023). Dual deep CNN for tumor brain classification. *Diagnostics*, 13(12), 1-22
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8, 1–74.
- Arefin, A. S. S. M. N., Ishti, S. M. I. A. K., Akter, M. M., & Jahan, N. (2023). Deep learning approach for detecting and localizing brain tumor from magnetic resonance imaging images. *Indonesian Journal of Electrical Engineering and Computer Science*, 29(3), 1729-1737.
- Ayadi, W., Elhamzi, W., Charfi, I., & Atri, M. (2021). Deep CNN for brain tumor classification. *Neural Processing Letters*, 53, 671–700.
- Badr, C. E., Silver, D. J., Siebzehnruhl, F. A., & Deleyrolle, L. P. (2020). Metabolic heterogeneity and adaptability in brain tumors. *Cellular and Molecular Life Sciences*, 77, 5101–5119.
- Badža, M. M., & Barjaktarović, M. Č. (2020). Classification of brain tumors from MRI images using a convolutional neural network. *Applied Sciences*, 10(6), 1-13.
- Boutry, J., Tissot, S., Ujvari, B., Capp, J.-P., Giraudeau, M., Nedelcu, A. M., & Thomas, F. (2022). The evolution and ecology of benign tumors. *Biochimica et Biophysica Acta (BBA)-Reviews on Cancer*, 1877(1), 18-32.

- Chlap, P., Min, H., Vandenberg, N., Dowling, J., Holloway, L., & Haworth, A. (2021). A review of medical image data augmentation techniques for deep learning applications. *Journal of Medical Imaging and Radiation Oncology*, 65(5), 545–563.
- Çakar, E. (2023, 10 Kasım). *Beyin tümörü tanı ve tedavisi*. Erişim Adresi: <https://istanbulrehab.com/beyin-tumoru-tani-ve-tedavisi/>.
- Doğanalp T. (2022). *Tümör tanılı farklı sekans manyetik rezonans görüntülerinin derin öğrenme modelleri ile sınıflandırılması* (Yayımlanmamış Yüksek Lisans Tezi). Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Erçelik, Ç. ve Hanbay, K. (2023). Beyin tümörü sınıflandırmada histogram eşitleme yönteminin bazı derin öğrenme modellerine etkileri. *Computer Science*, 8(2), 83–92.
- Gesaka, S. R., Okemwa, P. M., & Mwachaka, P. M. (2024). Histological types of brain tumors diagnosed at the Kenyatta National Hospital between 2016 and 2019: A retrospective study. *Discover Oncology*, 15(1), 1–11
- Ghorpade, N., & Bhapkar, H. R. (2021, 4 July). *Brain MRI segmentation and tumor detection: Challenges, techniques and applications*. Retrieved from: <https://www.semanticscholar.org/paper/Brain-MRI-Segmentation-and-Tumor-Detection%3A-and-Ghorpade-Bhapkar/1cffe0817828362916ab52b1ac064ccc7e1fcc8>.
- Hashemzahi, R., Mahdavi, S. J. S., Kheirabadi, M., & Kamel, S. R. (2020). Detection of brain tumors from MRI images base on deep learning using hybrid model CNN and NADE. *Biocybernetics and Biomedical Engineering*, 40(3), 1225–1232.
- Hoşgör, H. ve Güngördü, H. (2022). Sağlıkta yapay zekânın kullanım alanları üzerine nitel bir araştırma. *Avrupa Bilim ve Teknoloji Dergisi*, 35, 395–407.
- Karakaya, B. H., Akyol, A. S. ve Merih, Y. D. (2022). Yapay zekâ teknolojisinin perinatal dönem bakımına entegrasyonu ve uygulama örnekleri. *Türkiye Sağlık Enstitüleri Başkanlığı Dergisi*, 5(2), 1–11.
- Kocher, M., Ruge, M. I., Galldiks, N., & Lohmann, P. (2020). Applications of radiomics and machine learning for radiotherapy of malignant brain tumors. *Strahlentherapie Und Onkologie*, 196, 856–867.

- Kumar, A. (2023). Study and analysis of different segmentation methods for brain tumor MRI application. *Multimedia Tools and Applications*, 82(5), 7117–7139.
- Kumar, S., Nandal, N., & Pilania, U. . (2023). A systematic study of artificial intelligence-based methods for detecting brain tumors. *Информатика и Автоматизация*, 22(3), 541-575.
- Lindsay, G. W. (2021). Convolutional neural networks as a model of the visual system: Past, present, and future. *Journal of Cognitive Neuroscience*, 33(10), 2017–2031.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research*, 9(1), 381–386.
- Mahmoud, A., Awad, N. A., Alsubaie, N., Ansarullah, S. I., Alqahtani, M. S., Abbas, M., ... & Saber, A. (2023). Advanced deep learning approaches for accurate brain tumor classification in medical imaging. *Symmetry*, 15(3), 1-18.
- Maleki, F., Ovens, K., Najafian, K., Forghani, B., Reinhold, C., & Forghani, R. (2020). Overview of machine learning part 1: Fundamentals and classic approaches. *Neuroimaging Clinics*, 30(4), 17-32.
- Maram, B., & Rana, P. (2021, 13 April). *Brain tumour detection on brats 2020 using u-net*. Retrieved from: <https://ieeexplore.ieee.org/xpl/conhome/9596064/proceeding>
- Masoud Nickparvar. (2021, 15 February). *Brain tumor MRI dataset*. Retrieved from: <https://doi.org/https://doi.org/10.34740/KAGGLE/DSV/2645886>.
- Miller, K. D., Ostrom, Q. T., Kruchko, C., Patil, N., Tihan, T., Cioffi, G., Fuchs, H. E., Waite, K. A., Jemal, A., & Siegel, R. L. (2021). Brain and other central nervous system tumor statistics, 2021. *CA: A Cancer Journal for Clinicians*, 71(5), 381–406.
- Mohammed, B. A., & Al-Ani, M. S. (2020). An efficient approach to diagnose brain tumors through deep CNN. *Math. Biosci. Eng*, 18, 851–867.
- Nixon, M., & Aguado, A. (2019). *Feature extraction and image processing for computer vision* (1st ed.). London: Academic press.
- Özcan, B. ve Bakır, H. (2023). Yapay zekâ destekli beyin görüntüleri üzerinde tümör tespiti. *International Conference on Pioneer and Innovative Studies*, 1, 297–306.

- Pehlivan, B. (2024, 15 Ocak). *What is cancer immunotherapy?* Erişim Adresi: <https://berrinpehlivan.com/kanser-immunoterapisi-nedir/>.
- Qu, K., Guo, F., Liu, X., Lin, Y., & Zou, Q. (2019). Application of machine learning in microbiology. *Frontiers in Microbiology*, 10, 1-10.
- Sachdeva, M., & Kushwaha, A. K. S. (2023). The power of deep learning for intelligent tumor classification systems: A review. *Computers and Electrical Engineering*, 106, 108-126.
- Sadad, T., Rehman, A., Munir, A., Saba, T., Tariq, U., Ayesha, N., & Abbasi, R. (2021). Brain tumor detection and multi-classification using advanced deep learning techniques. *Microscopy Research and Technique*, 84(6), 1296-1308.
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*, 2(3), 1-21
- Sejnowski, T. J. (2020). The unreasonable effectiveness of deep learning in artificial intelligence. *Proceedings of the National Academy of Sciences*, 117(48), 30033–30038.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 1–48.
- Sowjanya, K. S., & Kumar, I. (2021, 3 June). *The effective study of transfer learning with VGG-16 on detection and classification of brain tumor*. Retrieved from: https://www.researchgate.net/publication/352542708_The_Effective_Study_of_Transfer_Learning_with_VGG-16_on_Detection_and_Classification_of_Brain_Tumor
- Talebi, H., & Milanfar, P. (2021, 18 April). *Learning to resize images for computer vision tasks*. Retrieved from: <https://www.semanticscholar.org/paper/Learning-to-Resize-Images-for-Computer-Vision-Tasks-Talebi-Milanfar/89e5e7665e3b8bf9bf675400fa31d23300d62ea5>.
- Taylor, L., & Nitschke, G. (2018). Improving deep learning with generic data augmentation. *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*, 2, 1542–1547.
- Trappenberg, T. P. (2019). *Fundamentals of machine learning* (1st ed.). London: Oxford University Press.

- Van den Bent, M. J., Geurts, M., French, P. J., Smits, M., Capper, D., Bromberg, J. E. C., & Chang, S. M. (2023). Primary brain tumours in adults. *The Lancet*, 402(10412), 1564–1579.
- Villán, A. F. (2019). *Mastering OpenCV 4 with Python: a practical guide covering topics from image processing, augmented reality to deep learning with OpenCV 4 and Python 3.7* (1st ed.). New York: Packt Publishing Ltd.
- Wong, E. T., & Wu, J. K. (2020, 3 May). *Overview of the clinical features and diagnosis of brain tumors in adults*. Retrieved from: <https://amp.cancer.org/content/dam/CRC/PDF/Public/8569.00.pdf>
- Xue, M., & Zhu, C. (2009). A study and application on machine learning of artificial intelligence. *2009 International Joint Artificial Intelligence*, 2, 272–274.
- Yenikaya, M. A. ve Oktaysoy, O. (2023). Yapay zekâ uygulamalarının sağlık sektöründe kullanımı: Derin öğrenme yöntemiyle ön tanı. *Sakarya Üniversitesi İşletme Enstitüsü Dergisi*, 5(2), 127–131.
- Ying, X. (2019). An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, 1168, 220-222.
- ZainEldin, H., Gamel, S. A., El-Kenawy, E. S. M., Alharbi, A. H., Khafaga, D. S., Ibrahim, A., & Talaat, F. M. (2022). Brain tumor detection and classification using deep learning and sine-cosine fitness grey wolf optimization. *Bioengineering*, 10(1), 18.-28.
- Zhang, C., & Lu, Y. (2021). Study on artificial intelligence: The state of the art and future prospects. *Journal of Industrial Information Integration*, 23, 100-124.

DİZİN

-B-

Beyin, v, xii, xiii, xiv, 1, 6, 11, 12, 13,
14, 15, 33, 66, 67, 68, 71
Beyin Tümörü, xii, xiii, 6, 33, 67

-C-

CNN, v, x, xii, xiii, xiv, 2, 3, 4, 6, 7, 8,
14, 15, 16, 18, 19, 22, 23, 24, 25, 26,
27, 39, 42, 44, 63, 70, 71, 72

-D-

Derin Öğrenme, vi, xii, xiii, xiv, 6, 19,
67
Doğruluk, xii, xiii, 6, 47, 48, 52, 56, 63,
67

-H-

Havuzlama, x, 23, 24, 25

-İ-

İnsan Beyni, xiii, 11

-S-

Sinir Ağı, xiii, 21

-T-

Teşhis, 1, 12

-V-

Veri seti, 2, 18, 34, 35, 36, 37, 39

-Y-

Yapay Zekâ, vi, xiii, xiv, 2, 19