

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME MODELLERİ KULLANILARAK
BEYİN TÜMÖRLERİNİN SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Kaya DAĞLI

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Osman EROĞUL

OCAK 2021

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Kaya DAĞLI

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME MODELLERİ KULLANILARAK BEYİN TÜMÖRLERİNİN SINIFLANDIRILMASI

Kaya Dağlı

TOBB Ekonomi ve Teknoloji Üniversitesi
Fen Bilimleri Enstitüsü
Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Osman Eroğul

Tarih: Ocak 2021

Beyin tümörleri insan sağlığını önemli derecede etkileyebilmektedir. Bu tümörlerin yanlış teşhisi durumunda, müdahale için alınacak olan kararlar ve bireyin sağlık durumu verimli şekilde belirlenmemektedir. Manyetik rezonans görüntülerinin bir hekim tarafından incelenmesi, beyin tümörlerinin belirlenmesinde en yaygın kullanılan yöntemdir. Beyin tümörlerinin çeşitliliğinden ve hekimlerin incelemesi gereken birçok görüntü olduğundan ötürü, bu yöntem hem insan hatalarına yatkındır hem de fazla zaman harcanmasına neden olmaktadır. Bu çalışmada, en yaygın görülen üç beyin tümörü çeşidi olan; Gliom, Meninjiyom ve Hipofiz bezi tümörlerinin derin öğrenme modelleri kullanılarak sınıflandırılması üzerine çalışılmıştır. Çalışmada doğruluk oranının yüksek olmasına önem verilirken, modellerin eğitimi için harcanan zaman da incelenmiştir. Bu sınıflandırma çalışması ile hekimlere yardımcı olabilecek bir sistem yaratmak amaçlanmıştır. Doğruluk oranı %90'a varan bir sistem oluşturulmuştur.

Anahtar Kelimeler: Beyin tümörü, Derin öğrenme, Doğruluk, Eğitim için harcanan zaman, Manyetik rezonans görüntüleri, Sınıflandırma.

ABSTRACT

Master of Science

CLASSIFICATION OF BRAIN TUMORS VIA DEEP LEARNING MODELS

Kaya Dađlı

TOBB University of Economics and Technology
Institute of Natural and Applied Sciences
Biomedical Engineering Science Programme

Supervisor: Prof. Dr. Osman Erođul

Date: January 2021

Brain tumors threaten human health significantly. Misdiagnosis of these tumors decrease effectiveness of decisions for intervention and patient's state of health. The conventional method to differentiate brain tumors is by the inspection of magnetic resonance images by clinicians. Since there are various types of brain tumors and there are many images that clinicians should examine, this method is both prone to human errors and causes excessive time consumption. In this study, the most common brain tumor types; Glioma, Meningioma and Pituitary are classified using deep learning models. While the main objective of this study is to have a high rate of accuracy, the time spent is also examined. The aim of this study is to ease clinicians work load and have a time efficient classification system. The system which has been built has an accuracy up to 90%.

Keywords: Brain tumor, Deep learning, Accuracy, Time consumption during training, Magnetic resonance images, Classification.

TEŐEKKÖR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren hocam Prof. Dr. Osman EROĐUL'a, kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Biyomedikal Mühendisliği Bölümü öğretim üyelerine ve destekleriyle her zaman yanımda olan öncelikle anneme ve aileme, arkadaşlarıma ve yol arkadaşım Zehra Ballı'ya teşekkürlerimi sunarım.

İÇİNDEKİLER

Sayfa

ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİL LİSTESİ	ix
ÇİZELGE LİSTESİ	xi
KISALTMALAR	xii
SEMBOL LİSTESİ	xiii
RESİM LİSTESİ	xiv
1. GİRİŞ	1
1.1 Tezin Amacı	2
1.2 Literatür Araştırması	2
2. BEYİN TÜMÖRLERİ	5
2.1 Tanımı	5
2.2 Çeşitleri	6
2.2.1 Birincil beyin tümörleri	6
2.2.1.1 Gliom.....	7
2.2.1.2 Meninjiyom	8
2.2.1.3 Hipofiz bezi tümörleri	9
2.2.2 İkincil beyin tümörleri.....	9
2.3 Beyin Tümörlerinin Oluşma Nedenleri.....	10
2.4 Beyin Tümörlerinin Semptomları	10
2.5 Beyin Tümörlerinin Teşhisi	11
3. MANYETİK REZONANS GÖRÜNTÜLEME	13
3.1 MRI Cihazının Çalışma Prensibi.....	14
3.2 Görüntü Oluşumu	14
4. DERİN ÖĞRENME	17
4.1 Nedir ve Neden Önemlidir?	17
4.2 Evrişimli Sinir Ağları	18
4.2.1 Katmanlar	19
4.2.1.1 Evrişim	19
4.2.1.2 Dolgu	20
4.2.1.3 Ortaklama	21
4.2.1.4 Düzleştirme	22
4.2.1.5 Tamamen bağlı katman	22
4.2.2 Aktivasyon fonksiyonu	23
4.2.3 Kayıp fonksiyonu	25
4.2.4 Optimizasyon algoritması	26
5. YÖNTEM	29
5.1 Veri Seti.....	29
5.2 Görüntülerin Ön İşlenmesi	31

5.2.1 Veri çeşitlendirme	31
5.3 Modellerin Özellikleri	32
5.3.1 İletim sönümü.....	32
5.3.2 Transfer öğrenme.....	33
5.4 Modeller	33
5.4.1 Model 1.....	34
5.4.2 Model 2.....	35
5.4.3 Model 3.....	36
5.4.4 Model 4.....	37
5.4.5 Model 5.....	38
5.4.6 Model 6.....	39
5.4.7 Model 7.....	40
5.5 Eğitim	42
5.6 Değerlendirme Kriterleri	44
6. BULGULAR	47
6.1 Modellerin İncelenmesi	47
6.2 Genel İnceleme.....	61
7. SONUÇLAR VE TARTIŞMA.....	65
KAYNAKLAR.....	67
ÖZGEÇMİŞ.....	71

ŞEKİL LİSTESİ

	Sayfa
Şekil 4.1 Evrişimli sinir ağı modeli.....	19
Şekil 4.2 Evrişim işlemi.....	20
Şekil 4.3 Dolgu işlemi.....	20
Şekil 4.4 Ortaklama katmanı çeşitleri (a) maksimum ortaklama, (b) ortalama ortaklama	21
Şekil 4.5 Düzleştirme işlemi.....	22
Şekil 4.6 Tamamen bağlı katmanın yapısı	23
Şekil 4.7 En yaygın kullanılan 3 aktivasyon fonksiyonunun grafikleri (a) sigmoid, (b) tanh, (c) ReLU	25
Şekil 4.8 Yığın, küçük yığın ve stokastik gradyan iniş algoritmaları	27
Şekil 5.1 Veri setinin eğitim, doğrulama ve test gruplarında bulunan tümör çeşitlerinin sayıları	30
Şekil 5.2 Evrişimli sinir ağı modelinin genel yapısı	32
Şekil 5.3 İletim sönümü kullanılan ve kullanılmayan bir sinir ağı arasındaki fark....	33
Şekil 5.4 Model 1'in yapısı	34
Şekil 5.5 Model 2'nin yapısı	35
Şekil 5.6 Model 3'ün yapısı	36
Şekil 5.7 Model 4'ün yapısı	37
Şekil 5.8 Model 5'in yapısı	38
Şekil 5.9 Model 6'nın yapısı	39
Şekil 5.10 Model 7'nin yapısı.....	40
Şekil 5.11 ReLU aktivasyon fonksiyonunun grafiği.....	41
Şekil 5.12 Hata matrisi	44
Şekil 6.1 Model 1'in hata matrisi	47
Şekil 6.2 Model 1'in eğitim ve doğrulama başarımı	48
Şekil 6.3 Model 1'in eğitim ve doğrulama kaybı.....	48
Şekil 6.4 Model 2'nin hata matrisi	49
Şekil 6.5 Model 2'nin eğitim ve doğrulama başarımı	50
Şekil 6.6 Model 2'nin eğitim ve doğrulama kaybı.....	50

Şekil 6.7 Model 3'ün hata matrisi	51
Şekil 6.8 Model 3'ün eğitim ve doğrulama başarımı	52
Şekil 6.9 Model 3'ün eğitim ve doğrulama kaybı	52
Şekil 6.10 Model 4'ün hata matrisi	53
Şekil 6.11 Model 4'ün eğitim ve doğrulama başarımı	54
Şekil 6.12 Model 4'ün eğitim ve doğrulama kaybı	54
Şekil 6.13 Model 5'in hata matrisi	55
Şekil 6.14 Model 5'in eğitim ve doğrulama başarımı	56
Şekil 6.15 Model 5'in eğitim ve doğrulama kaybı	56
Şekil 6.16 Model 6'nın hata matrisi	57
Şekil 6.17 Model 6'nın eğitim ve doğrulama başarımı	58
Şekil 6.18 Model 6'nın eğitim ve doğrulama kaybı	58
Şekil 6.19 Model 7'nin hata matrisi	59
Şekil 6.20 Model 7'nin eğitim ve doğrulama başarımı	60
Şekil 6.21 Model 7'nin eğitim ve doğrulama kaybı	60

ÇİZELGE LİSTESİ

Sayfa

Çizelge 4.1 Problem çeşidine en uygun aktivasyon ve kayıp fonksiyonları.....	26
Çizelge 6.1 Modellerin doğruluk, kesinlik ve duyarlılık değerleri... ..	61
Çizelge 6.2 Modellerin eğitimleri için harcanan süre	62



KISALTMALAR

MRI	: Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging)
BT	: Bilgisayarlı Tomografi (Computed Tomography)
PET	: Pozitron Emisyon Tomografisi (Positron Emission Tomography)
ADD	: Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform)
DSO	: Dünya Sağlık Örgütü (World Health Organization)
ESA	: Evrişimli Sinir Ağları (Convolutional Neural Networks)
DNA	: Deoksiribonükleik Asit (Deoxyribonucleic Acid)



SEMBOL LİSTESİ

Bu çalışmada kullanılmış olan simgeler açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
μ	Başlangıç öğrenme hızı
t	Zaman
g_t	t anındaki gradyan değeri
v_t	Gradyanların eksponansiyel ortalaması
s_t	Gradyanların karelerinin eksponansiyel ortalaması
\log	Logaritmik değer
β_1	Birinci derece üstel bozulma oranı (Adam)
ϵ	Parametre (Adam algoritması)
β_2	İkinci derece üstel bozulma oranı (Adam)

RESİM LİSTESİ

	Sayfa
Resim 2.1 Gliom tümörünün MRI görüntüsü	7
Resim 2.2 Meninjiyom tümörünün MRI görüntüsü.....	8
Resim 2.3 Hipofiz bezi tümörünün MRI görüntüsü.....	9
Resim 3.1 Manyetik rezonans görüntüleme cihazı	13
Resim 3.2 Beynin aynı kesitinden alınmış üç adet görüntü. Kontrastları ayarlanmış görüntüler (a) proton yoğunluklu, (b) T2 ağırlıklı, (c) T1 ağırlıklı.....	15
Resim 5.1 Veri setinde bulunan üç çeşit beyin tümörünün MRI görüntüleri (a) Gliom, (b) Meninjiyom, (c) Hipofiz.....	29

1. GİRİŞ

Dünya Sağlık Örgütü'nün (DSÖ) tanımlamasına göre beyin tümörü, merkezi sinir sistemini etkileyen tümörlerdir [1]. Tümörler genel olarak, düzensiz çoğalan hücreler olarak tanımlanırlar. Beynin diğer bölgelerine de zarar vererek beynin normal işleyişine engel olabilmektedirler. Bir beyin tümörü birincil veya ikincil olarak sınıflandırılabilir. Birincil beyin tümörü, beyinde ortaya çıkan ve beyindeki hipofiz bezi, beyin zarı gibi bölgeleri de etkisi altına alan türdür. İkincil beyin tümörü ise, akciğer, böbrek, göğüs gibi vücudun başka yerlerinden beyine yayılan tümör tipidir [2,3]. Birincil beyin tümörü, deoksiribonükleik asitte (DNA) meydana gelen mutasyonlar sonucu ortaya çıkmaktadır. Bu mutasyonların neden olduğu kontrolsüz hücre bölünmesi ile anormal hücrelerin sayısı artarken, normal hücreler ölmektedir. Bu durum beyin hasarı ve yaşamın sonlanması ile sonuçlanabilmektedir [1].

Beyinde gerçekleşen bu durumun detaylı incelenmesi için kullanılan ana görüntüleme tekniği manyetik rezonans görüntülemedir (MRI). MRI, insan vücudundaki organların ve özellikle yumuşak dokuların ayrıntılı görüntülerini oluşturmak için manyetik alan ve bilgisayar tarafından oluşturulan radyo dalgalarını kullanan tıbbi bir görüntüleme tekniğidir [4]. MRI cihazının oluşturduğu manyetik alan kullanılarak, görüntülenmesi hedeflenen insan vücut bölgesindeki su molekülleri geçici olarak yeniden hizalanır. Radyo dalgaları, bu hizalanmış moleküllerin kesitsel MRI görüntüleri oluşturmak için kullanılan zayıf sinyaller üretmesine neden olur.

Elde edilen MRI görüntülerinin bir hekim tarafından incelenmesi, beyin tümörlerinin belirlenmesindeki geleneksel ve en yaygın olarak kullanılan yöntemdir. Beyin tümörlerinin çeşitli olmasından ve hekimlerin incelemesi gereken birçok kesit görüntüsü olmasından dolayı, bu yöntem hem insan hatalarına yatkındır hem de fazla zaman harcanmasına neden olmaktadır. Günümüzde hızla gelişen teknoloji ve elde edilen verilerin gün geçtikçe artması nedeniyle, bilgisayarlar sağlık alanında önemli yer tutmaya başlamıştır. İnsanlar gibi düşünmek ve eylemlerini taklit etmek için programlanmış makinelerde, insan zekasının simülasyonu anlamına gelen yapay zeka, sağlık alanında hastalıkların teşhisi ve sınıflandırılması amacıyla kullanılmaktadır [5].

Bir makine öğrenmesi yöntemi olan derin öğrenme ile eğitilen yapay zeka, görüntülerin sınıflandırılmasını etkili bir şekilde yerine getirebilmektedir. Derin öğrenme sayesinde bilgisayarlar kendi deneyimlerinden yeni bilgiler edinebilmekte ve bunları bir araya getirip yeni sonuçlara ulaşabilmektedirler. Böylece bilgisayarı kullanan kişinin, her an yeni bir bilgi girdisi yapması gerekmemektedir. Beyin tümörlerinin sınıflandırılmasında kullanılan geleneksel yöntem yerine, derin öğrenme tercih edilerek hem tümörlerin tespitindeki hata ihtimalinin en aza indirilmesine katkı sağlanabilecek hem de hastanın durumunun belirlenmesinde harcanan zaman kontrol altında tutulabilecektir.

1.1 Tezin Amacı

Bu çalışmada en yaygın görülen üç beyin tümörü çeşidi olan; Gliom, Meninjiyom ve Hipofiz bezi tümörlerinin sınıflandırılmasında hekimlere yardımcı olabilecek ve zamanı verimli kullanan bir mekanizma üzerinde çalışılmıştır. Manyetik rezonans görüntüleme cihazı kullanılarak elde edilen beyin kesit görüntülerinin incelenmesi, hangi tür beyin tümörüne karşılık geldiğinin anlaşılması ve bu sayede hastanın durumunun doğru ve en kısa sürede teşhisi ile tedaviye en kısa zamanda başlanabilmesi amaçlanmıştır. Elde edilen sınıflandırma mekanizmasının, yüksek doğruluk oranına ve optimal çıktı süresine sahip olması ön planda tutulmuştur.

1.2 Literatür Araştırması

Literatürde derin öğrenme kullanarak beyin tümörü sınıflandırması yapılan birçok çalışma bulunmaktadır. Bu çalışmada kullanılan veri setinin de ilk defa kullanıldığı, Jun Cheng(2015) tarafından yapılan çalışmada, tümör bölgesi büyütme tekniği ile beyin tümörü sınıflandırması araştırılmıştır. Beyin MRI görüntüleri üzerinde belirlenen tümörlerin sınırları işaretlendikten sonra, halka şeklindeki bu alanlar büyütülerek incelenmiştir. Çalışmada, tümörün çevresindeki alanların da tümörün belirlenmesinde önemli bir etkisi olup olmadığı araştırılmıştır [6]. Çalışmanın sonucunda, sınıflandırma için geniş alanların dar alanlara kıyasla daha ayırt edici bilgiler içerdiği sonucuna varılmıştır. Sérgio Pereira(2016) yaptığı çalışmada ise, MRI cihazlarından çok sayıda veri edinilmesi ve el ile bölütlemenin fazla zaman kaybına neden olmasından ötürü, evrişimsel sinir ağlarını beyin tümörlerinin otomatik segmentasyonunda kullanmıştır [7]. Heba Mohsen (2018) ise beyin tümörü

sınıflandırma çalışmasında sırasıyla fuzzy c-means clustering (Bulanık c-merkezli öbekleme) tekniği ile segmentasyon, Ayrık Dalgacık Dönüşümü (ADD) ile öznelik çıkarımı yaptıktan sonra ise derin sinir ağı yöntemi ile de sınıflandırma yapmıştır. ADD kullanımının sınıflandırma sonucuna önemli etkileri olduğu gözlemlenmiştir [8]. Parnian Afshar (2018) yaptığı çalışmada ise beyin tümörü sınıflandırmasını kapsül ağları adı verilen yeni bir teknik ile yapmayı önermiştir. Evrişimli sinir ağları çok yüksek miktarda eğitim verisine ihtiyaç duyduğundan, Afshar bu duruma bir çözüm olarak kapsül ağları sunmuştur. Bu ağlar az sayıda eğitim verisi ile sınıflandırma görevini yerine getirebilmektedir [9]. Sunanda Das (2019) ve Ali Mohammed Alqudah (2019) çalışmalarında evrişimli sinir ağı kullanmadan önce görüntü ön işlemlerinde farklı teknikler üzerinde durmuşlardır. Sunanda görüntülere Gauss filtresi ve histogram eşitleme uygulamıştır [10]. Ali Mohammed ise çalışmasında MRI görüntülerini tümörlerin kırılmamış, kırılmış ve bölümlenmiş hallerinin sınıflandırma sonucuna etkisini incelemiştir. Kırılmamış yani orijinal görüntünün en iyi sonucu verdiği görülmüştür [11]. Arshia Rehman (2019) yaptığı çalışmada, transfer öğrenimi kullanarak beyin tümörü sınıflandırmasında sahip olunan doğruluk oranını arttırmayı amaçlamıştır. Çeşitli mimarileri denedikten sonra en iyi sonucu VGG16 mimarisinde edinmiştir. Afshar'ın 2018 yılında kapsül ağlar kullanarak yaptığı çalışmada elde ettiği sonuçtan daha iyi bir sonuca ulaşmıştır [12]. Muhammad Sajjad (2018) yaptığı araştırmada kısıtlı veri sayısının evrişimli sinir ağları için bir problem olduğunu belirterek, veri çeşitlendirmenin etkisi üzerine çalışmıştır. VGG19 mimarisini kullanarak veri sayısının çeşitlendirme olmadan ve çeşitlendirme ile doğruluk oranı üzerindeki etkisini incelemiştir [13]. B. Srinivas (2019) ise evrişimsel sinir ağları ile öznelik çıkarımını gerçekleştirip, K – en yakın komşu sınıflandırıcısı ile de tümörlerin tahminini yapan bir model geliştirmiştir. Sadece evrişimli sinir ağları (ESA) ile sınıflandırma yapmak yerine hibrit bir modelin daha faydalı sonuçlar verebileceğini göstermiştir [14].



2. BEYİN TÜMÖRLERİ

2.1 Tanımı

Beyin tümörleri, merkezi sinir sistemindeki hücrelerin düzensiz çoğalması olarak tanımlanırlar. Bu tümörler, iyi huylu veya kötü huylu olarak farklı özelliklere sahip olmalarının yanı sıra, beynin normal çalışma becerisini etkileyebilmektedirler. Bir tümörün iyi huylu veya kötü huylu olup olmadığı, hücre anormalliği düzeyine bağlıdır. Tümör normal görünümlü hücrelerden oluşuyorsa iyi huyludur; ancak hücreler anormal ise tümör kötü huyludur. İyi huylu olarak adlandırılan beyin tümörleri kanser kabul edilmemekte, fakat yaşam kalitesini etkileyen semptomlara neden olabildikleri için tedavi edilmeleri gerekebilmektedir. Kötü huylu beyin tümörleri kanserli hücre olarak tanımlanmaktadır. İyi huylu tümörlere kıyasla hızlı ve agresif bir şekilde büyürler. Yakınlarında bulunan diğer hücrelere de yayılarak insan sağlığını önemli ölçüde tehdit ederler.

Tümör derecelendirmesi, bir tümörü sınıflandırmanın en basit yoludur ve hekimlerin tümör hakkında daha net kararlar almasına, tedavi seçeneklerinin belirlenmesine ve tedavi sürecinde başarılı sonuçlar elde edilebilmesine yardımcı olur. Tümörler içerdikleri hücrelerin anormalliklerine göre, DSÖ tarafından dört aşamada sınıflandırmaktadır. Bir tümör birden fazla hücre derecesine sahip olabilmektedir. Bu durumda en yüksek ve en kötü huylu hücre derecesi baz alınarak bir sınıflandırma yapılmaktadır. 1. aşamadaki tümör hücreleri en az kötü huylu tümörlerdir, yavaş büyürler ve neredeyse normal bir hücreye benzerler. 2. aşamadaki hücreler yakındaki normal dokuya yayılabilir ve bazen daha yüksek dereceli bir tümör olarak tekrarlayabilir. 3. aşamadaki tümörler kötü huyludur. Ancak 2. aşamadaki hücrelerle aralarında büyük bir fark yoktur. Bu hücreler büyüyen anormal hücreleri aktif olarak normal beyin dokusunda üretir. 4. aşama ise en kötü huylu tümörlerden oluşmaktadır. Hızlı çoğalırlar, anormal bir görünüme sahiptirler ve normal beyin dokusunda kolayca büyüyebilirler. Bu tümörler, hızlı büyümelerini sürdürebilmek için yeni kan damarları oluştururlar. Aşamalar ilerledikçe tedavi süreci zorlaşacağından, tümörlerin erken

aşamada tespiti tedavi sürecinin ilerlemesi ve alınacak sonuçların olumlu olması açısından büyük önem taşımaktadır [15].

Yapılan bir incelemeye göre 2020 yılında, Amerika Birleşik Devletleri'nde tahmini 13590 erkek ve 10300 kadın olmak üzere toplam 23890 bireye kanserli beyin tümörü teşhisi konulacağı belirtilmiştir. Bir insanın yaşamında, vücudunun bu tür bir tümör geliştirme olasılığı %1'den azdır. 15 yaşın altında yaklaşık 3540 çocuğa da beyin tümörü teşhisi konulacaktır. Beyin ve diğer sinir sistemi kanserleri, insan ölümlerinin 10. sırada gelen nedenidir. 2020 yılında 10190 erkek ve 7830 kadın, toplamda 18020 bireyin birincil beyin kanserli beyin tümörlerinden öleceği tahmin edilmiştir [16,20].

2.2 Çeşitleri

Bir beyin tümörü, ortaya çıktığı vücut bölümüne göre birincil veya ikincil olarak sınıflandırılabilir. DNA'da meydana gelen mutasyonların neden olduğu beyin tümörleri, kontrolsüz bir şekilde bölünerek anormal hücrelerin sayısını artırmaktadırlar. Bu durum, kalıcı hasarlara ve kişinin yaşamının sonlanmasına neden olabilmektedir.

Çoğu beyin tümörü kanserdir. Örneğin, yetişkinlerde teşhis edilen tüm gliomaların yarısından fazlası çok agresif bir beyin kanseri türü olan glioblastomlardır. Ancak tüm beyin tümörleri kanserli değildir. Birçok meninjiyom, kraniofaringiyom ve hipofiz tümörü iyi huyludur. Bu nedenle, bir beyin tümörünün kapsamlı ve doğru teşhisi önem arz etmektedir. İyi huylu tümörler bile beyin dokusuna zarar verebilmekte ve baş ağrısı, görmede bozukluk gibi yan etkilere neden olabilmektedir.


2.2.1 Birincil beyin tümörleri

Beyinde ortaya çıkan ve beyindeki hipofiz bezi, beyin zarı gibi bölgeleri etkisi altına alan tür, birincil beyin tümörüdür. Genellikle düşük dereceli veya yüksek dereceli olarak tanımlanırlar. Düşük dereceli bir tümör genellikle yavaş büyür, ancak yüksek dereceli bir tümöre dönüşebilir. Yüksek dereceli bir tümörün ise daha hızlı büyümesi olasıdır. Birçok farklı tipte birincil beyin tümörü mevcuttur. Her biri adını ilgili hücre türünden alır.

2.2.1.1 Gliom

Gliomlar en yaygın gözlenen beyin tümörleridir. Beyinde destekleyici doku olarak görev yapan glial hücrelerden oluşurlar (Resim 2.1). Tüm beyin tümörlerinin yaklaşık olarak %30'unu oluştururlar ve çoğunlukla kötü huylu oldukları gözlemlenmiştir. Gliom çeşitlerinden bazıları; astrositom, oligodendrogliom, ependimom ve beyin sapı gliomudur. Farklı görevlere sahip hücrelerden meydana geldikleri için isimleri farklılık göstermektedir [17].

- Astrositom: En yaygın görülen gliom tipidir. Beyincikte bulunan glial hücrelerine benzerler. Yetişkinlere kıyasla çocuklarda daha yaygın gözlemlenirler.
- Oligodendrogliom: Oligodendrositler adı verilen glial hücrelere benzeyen bir tümör tipidir. Bu hücreler sinir hücrelerini saran ve iletim hızına etkisi olan miyelinin üretiminden sorumludur.
- Ependimom: Çoğunlukla beyin omurilik sıvısının üretildiği ve depolandığı geçiş yollarında başlar. Yetişkinlerde sıklıkla omurgada görülürler.
- Beyin sapı gliomu: Beyin sapındaki glial hücrelerde meydana gelirler.




Resim 2.1 Gliom tümörünün MRI görüntüsü [Url-1].

2.2.1.2 Meninjiyom

Meninjiyomlar, beynin ve omuriliği çevreleyen dış zar hücrelerinden meydana gelirler (Resim 2.2). Üç adet meningeal katman vardır. Bunlar; dura mater, araknoid ve pia materdir. Meninksler, diğer adıyla beyin zarının görevi beyni ve omuriliği korumak ve beyin omurilik sıvısının araknoid ve pia katmanları arasında dolaşımına yardımcı olmaktır. Tam olarak beyin tümörü olmamakla birlikte, intrakraniyal boşlukta oluştuklarından ve büyüdükçe beyine ve omuriliğe yaptıkları baskıdan ötürü nörolojik semptomlara neden olduklarından beyin tümörü olarak sınıflandırılırlar [18]. Bu tümör tipi, tüm tümörlerin yaklaşık %15'ini oluşturur. Çoğu iyi huyludur ve yavaş büyürler. Bazı meninjiyomlar acil tedaviye ihtiyaç duymayabilir ve yıllarca tespit edilemeyebilirler. Meninjiyom genellikle merkezi sinir sisteminde başladığı yere göre adlandırılır. Bunlardan bazıları:


- Falks ve parasagittal meninjiyom: Beynin sol ve sağ tarafları arasında bulunan bir zar olan falksın üst kısmında meydana gelir. Tüm meninjiyomların %25'ini oluşturur.
- Konveksite meninjiyomu: Beynin dış yüzeyinde ortaya çıkar ve meninjiyomların %20'sini oluşturur.
- Sfenoid meninjiyom: Sfenoidal çıkıntı olan gözlerin arkasında yer alır.



Resim 2.2 Meninjiyom tümörünün MRI görüntüsü [Url-1].

2.2.1.3 Hipofiz bezi tümörleri

Hipofiz tümörleri, kafatasının içinde, beynin altında bulunan ve küçük bir bez olan hipofizde oluşurlar (Resim 2.3). Hipofiz bezi, vücuttaki endokrin bezleri tarafından salgılanan hormonların kontrolünü sağlayan hormonlar üretir ve bu sayede temel vücut fonksiyonlarını ve hormonal sistemi kontrol etmede önemli rol oynar. Hipofiz bezi dört bölümden oluşur. Bunlar; ön lob, arka lob, orta alan ve hipofizi beyinle bağlayan saptır. Hipofiz tümörlerinin çoğu ön lobda görülür. Çok nadiren arka lobda oluşurlar. Bu tümör tipi, tüm tümörlerin %12'sini temsil eder [19]. Hipofiz tümörlerinin çoğu kafatasının ötesine yayılmayan iyi huylu tümörlerdir. Bu tümörler kanserli olarak nitelendirilmese de, beyine yakın yerde bulduklarından ve vücudun hormonal seviyesine etki edebileceklerinden, orada bırakılmaları sakıncalıdır.



Resim 2.3 Hipofiz bezi tümörünün MRI görüntüsü [Url-1].

2.2.2. İkincil beyin tümörleri

İkincil beyin tümörleri akciğer, böbrek, göğüs gibi vücudun başka bölümlerinde başlayıp beyine yayılan kanserli bir tümör tipidir [2,5]. İkincil bir beyin tümörü, metastatik kanser veya beyin metastazı olarak da adlandırılabilir. Yetişkinlerde, ikincil beyin tümörleri, birincil tümörlerden çok daha yaygındır. Kanser meninkslere ve beyin omurilik sıvısına yayılırsa, buna leptomeningeal metastaz veya neoplastik menenjit denir. Bu durum lösemi, lenfoma, meme kanseri veya akciğer kanseri olan kişilerde daha sık görülür.

2.3 Beyin Tümörlerinin Oluşma Nedenleri

Beyin tümörlerinin oluşum ihtimalini etkileyen her türlü duruma risk faktörü adı verilmiştir. Bunlar beyin tümörünün gelişimine neden olmakla birlikte, beyin tümörlerinin oluşumuna etkileri olmayabilir. Birkaç risk faktörüne sahip kişiler hiçbir zaman beyin tümörü geliştirmezken, hiçbir risk faktörü olmayan kişilerde beyin tümörü görülebilir. Sonuç olarak, risk faktörleri kesin bir sonuca varmayı sağlamazlar.

Çoğu zaman bir beyin tümörünün sebebi belli değildir ancak bazı durumlar insanda tümör oluşum riskini arttırabilmektedir:

- Yaş: Beyin tümörleri çocuklarda ve yaşlılarda daha fazla görülmektedir.
- Cinsiyet: Erkeklerde beyin tümörü geliştirme olasılığı kadınlara göre daha fazladır. Meninjioma tümörü kadınlarda daha yaygındır.
- Genetik: Beyin tümörlerinin %5'i genetik faktörlerle bağlantılı göstermektedir. Turcot Sendromu, Li-Fraumeni Sendromu vb. ile bağlantı olabilirler.
- Maruz kalınan ortamlar: Çalışılan ortamda bulunan çözücüler, böcek ilaçları veya vinil klorürün, beyin tümörü geliştirme riskini arttırdığı düşünülmektedir, fakat bilimsel olarak kanıtlanmamıştır. Ayrıca Epstein-Barr adı verilen virüs çeşidi de beyin tümörü riskini arttırmaktadır.

2.4 Beyin Tümörlerinin Semptomları

Beyin tümörüne sahip bireyler çeşitli semptomlara sahip olabilirler. Bazı zamanlar, hiçbir belirti göstermeyebilirler veya bu semptomların nedeni, başka bir rahatsızlık olabilir. Beyin tümörü semptomları genel veya spesifik olabilir. Genel semptomlar, tümörün beyin veya omuriliğe yaptığı baskı sonucu ortaya çıkar. Genel semptomlar:

- Sabah saatlerinde yoğunlaşan baş ağrısı, mide bulantısı ve kusma,
- İstemsiz kas hareketlerine neden olan nöbetler,
- Koku ve tat alma duyularında meydana gelen değişiklikler,
- Kişilik değişmesi ve hafıza kayıpları olarak belirtilmiştir [21].

Spesifik semptomlar ise, tümörden ötürü beynin belli bir bölgesinin düzgün çalışmaması sonucu oluşur. Bunlar:

- Tümörün çevre bölgelerinde baş ağrısı,
- Denge kurmada zorluk,

- Karar verme yetisi kaybı,
- Görüşte kayıp ve çift görme,
- Yutkunmada zorluk,
- Yukarı bakamama gibi semptomlardır [21].

2.5 Beyin Tümörlerinin Teşhisi

Hekimler, beyin tümörlerinin ve çeşitlerinin tespiti için birçok yöntem kullanmaktadırlar. Genellikle, bir beyin tümörünün teşhisi için MRI tercih edilir. Beynin incelenmesinde bilgisayarlı tomografi (BT) yerine MRI yönteminin tercih edilmesinin nedeni, MRI'nın görüntüleri üretmek için x – ışınlarının yerine manyetik alanları kullanmasıdır. Ayrıca MRI sonucu elde edilen görüntüler BT'ye kıyasla daha ayrıntılıdır. Hekimler gerekli gördükleri durumlarda Pozitron Emisyon Tomografisi'ne (PET) başvurumaktadırlar.

MRI ile beyinde bir tümör olduğu anlaşılınca, tümör hakkında daha kesin bir kanıya varabilmek için, hekimler biyopsi adı verilen prosedür ile veya ameliyatla tümörün bir kısmını veya tamamını çıkarabilirler. Doktorun tanı koymasına yardımcı olmak için, laboratuvarında bu parça üzerinde testler yürütülür. Tanı koyulduktan sonra en kısa zamanda, tedavi işlemlerine başvurulabilir. Bu işlemlerin etkili bir şekilde gerçekleşmesinde, MRI cihazından elde edilecek olan görüntü önemli yer tutmaktadır.



3. MANYETİK REZONANS GÖRÜNTÜLEME

Medikal görüntüleme alanında en yaygın kullanılan tekniklerden biri olan MRI, insan vücudundaki çeşitli bölgelerin detaylı görüntüsünün oluşturulmasını sağlamaktadır [22]. Aynı BT gibi, MRI da yüksek çözünürlüğe ve kontrasta sahip kesit görüntüleri üretir. Aynı zamanda ultrason gibi MRI da iyonlaştırıcı radyasyon içermez. Yüksek kalitede görüntü üretimi ve risksiz görüntüleme özellikleri MRI'ı en çok kullanılan görüntüleme yöntemlerinden biri haline getirmiştir (Resim 3.1).



Resim 3.1 Manyetik rezonans görüntüleme cihazı [Url-2].

Klinik uygulamada, MRI esas olarak vücudun işlevselliğini incelemek yerine, anatomik durumunu incelemek için kullanılır. Anatomik yapıyı daha iyi ortaya çıkarabilmek amacıyla, sinyal vuruş dizisi değiştirilerek farklı doku kontrastlarına sahip görüntüler elde edebilir.

3.1 MRI Cihazının Çalışma Prensibi

Bir MRI cihazı, BT cihazına benzemekle birlikte, içinde hastanın yatabileceği tünel şeklindeki bir boşluğa sahip bir gantriden oluşmaktadır. Gantrinin içinde manyetik alanların ve radyo frekans dalgalarının oluşumunu sağlayan materyeller ve de ayrıca ham sinyal verilerinin alındığı alıcı bobinler yer almaktadır.

İnsan vücudunu oluşturan en küçük parçacık olan atomların bir çoğunun manyetik özelliği mevcuttur. Bu parçacıklardan manyetik rezonansa en duyarlı olan element olmasından ötürü hidrojen atomu manyetik rezonans görüntüleme tekniğinde kullanılmaktadır. Aynı zamanda hidrojen atomunun kullanılmasının bir diğer en önemli özelliği, insan vücudunun yaklaşık %60'ının su moleküllerinden (H_2O) oluşmasıdır [23].

Hidrojen atomlarının protonları rastgele dizilmişlerdir. Kendi eksenleri etrafında yaptıkları dönüş (spin) hareketinden meydana gelen küçük miktarda bir manyetik momentleri vardır. MRI cihazının yaptığı, çeşitli manyetik alanlar üreterek; ana manyetik alan, radyofrekans dalgaları ve doğrusal gradyan alanları, atomların dönüş hareketi ile bu alanların etkileşmesini sağlamaktır. Ana manyetik alanın uygulanması ile protonlar manyetik alan yönünde Larmor frekansında manyetik alan yönünde bir hizalanma durumuna geçerler [24]. Radyofrekans dalgasının uygulanmasıyla protonlar, bir salınım hareketi yapıp rotasyonlarını değiştirerek, manyetizasyon vektörünün yönünde değişiklik meydana getirirler. Dönen manyetizasyon vektörleri bir elektromotor kuvveti indükler ve sonrasında bu sinyal, radyofrekans dalgasını yayan bobinin görev değiştirip alıcı olarak görev yapması ile alınır. Buna indüksiyon azalması (free induction decay) adı verilir. Elde edilen bu veriler kaydedilip, işlenerek bir MRI görüntüsü oluşturulur.


3.2 Görüntü Oluşumu

MRI cihazında görüntü oluşumu sırasında bazı parametreler değiştirilerek dokuların kontrastları üzerinde değişiklikler yapılabilmektedir. Bu sayede incelenecek olan bölgedeki dokular daha rahat ayırt edilebilir.

MRI'da kontrast mekanizması için kullanılan 2 adet parametre vardır. Bunlar; yankı zamanı (T_E) ve tekrarlama zamanıdır (T_R). T_E , radyofrekans dalgası ile sinyal kaydı arasındaki süredir. T_R ise radyofrekans dalgaları arasındaki zaman olarak tanımlanır.

Bu deęerler ayarlanarak, T1 aęırlıklı, T2 aęırlıklı ve proton yoęunluklu grntler elde edilmektedir [25].

- T1 aęırlıklı grntler: Yksek yaę ierięine sahip dokular parlak grnrken, su ile dolu blgeler karanlık grnr. Bu nedenle, beyin omurilik sıvısı koyu renkli iken, beyaz madde parlak grnr ve gri maddeden daha aık renktedir. Bu grnt tipini anatomiye gstermek aısından kullanıřlıdır. Elde etmek iin T_E ve T_R deęerlerinin kısa tutulması gerekmektedir.
- T2 aęırlıklı grntler: Su ile dolu blgeler parlak grnrken, yksek yaę ierikli dokular karanlık grnr. Bu nedenle, beyin omurilik sıvısı aıkrenkli grnrken, beyaz madde karanlık grnr. Bu grnt tipi, patolojiyi gstermek iin idealdir. nk oęu doku bozukluęu su ierięinde artıř da barındırır. Elde etmek iin T_E ve T_R deęerlerinin uzun tutulması gerekmektedir.
- Proton yoęunluklu grntler: T_E kısa tutulurken, T_R deęeri uzun tutulmalıdır.



Resim 3.2 Beynin aynı kesitinden alınmıř 3 adet grnt. Kontrastları ayarlanmıř grntler (a) proton yoęunluklu, (b) T2 aęırlıklı, (c) T1 aęırlıklı [25].



4. DERİN ÖĞRENME

4.1 Nedir ve Neden Önemlidir?

Derin öğrenme, yapay zeka ve makine öğrenmesinin bir alt alanıdır. Bu konuyu detaylı bir şekilde anlayabilmek için yapay zeka ve makine öğrenmesi terimlerinin genel olarak neyi ifade ettikleri bilinmelidir.

Yapay zeka, normalde insanlar tarafından yerine getirilen düşünsel faaliyetleri otonom hale getirme olarak açıklanabilir [26]. 1950’li yıllarda, bilgisayar bilimciler tarafından “Bilgisayarlar da insanlar gibi düşünebilir mi?” sorusuna cevap aranması sonucu oluşmaya başlamıştır. Bir görevi yerine getirmesi için bilgisayarlar her bir kural ile tek tek kodlanmıştır. Satranç oynamak gibi problemlere etkili çözümler üretirken, görüntü sınıflandırma ve diller arası çeviri gibi karışık problemlerde etki gösterememiştir. Böylece ortaya bu tip problemleri çözmekte etkili makine öğrenmesi yaklaşımı çıkmıştır.

Makine öğrenmesinin yaratılmasındaki temel amaç, bilgisayarların bizim bilgi birikimimiz ve karar mekanizmamızın ötesine geçip, gerekli kararları kendi başlarına alabilmeleri ve yeni bilgiler öğrenebilmeleridir. Bu yaklaşım ile makine öğrenmesi, verileri ve bu verilerden elde edilmesi beklenen sonuçları kullanarak, yeni elde edilen verilere isabetli cevaplar üretebilecektir. Yapay zeka ile makine öğrenmesini ayıran en önemli özellik, yapay zekada bir makine insan davranışını sergilemek için programlanırken, makine öğrenmesinde makinenin otomatik olarak, ek bir programlamaya ihtiyaç duymadan eski verilerinden öğrenebilmesidir.

Derin öğrenme ise, birbiri ardına gelen katmanlardaki verilerin işlenmesi ile daha kullanışlı bilgiler elde edilmesine olanak verdiği için makine öğrenmesi yerine tercih edilmektedir. Derin öğrenme modelleri yüzlerce katmandan oluşabildiği için, derin öğrenme ismi ile tanımlanmıştır. Makine öğrenmesi ise genelde az sayıda katmandan oluşması sebebiyle sığ öğrenme adını almıştır. Birbirini takip eden bu katmanlı yapı, sinir ağı olarak adlandırılmaktadır. Katmanlar birbiri altındaki ve üstündeki katmanların ihtiyacına göre kendisini düzenleyebilmekte ve böylece beraber


öğrenmektedirler. Bu durum derin öğrenmeyi makine öğrenmesinin bir adım önüne koymaktadır.

Makine öğrenmesi 1950'li yıllarda keşfedildikten sonra yaygın olarak kullanılmıştır. Derin öğrenme yönteminin bulunması da 1960'lı yıllara dayanmaktadır. Fakat makine öğrenmesi kadar yaygın kullanılmamıştır. Kullanımının popülerleşmesinin 2010'ların başlarında olması üç temel nedene dayanmaktadır:

- Donanım: 1990 ile 2000 yılları arasında merkezi işlem birimleri 5000 kat hızlanmıştır [26]. Böylece eskiden hayal bile edilemeyen bir derin öğrenme modeli, artık yaygın bir şekilde bilgisayarlarda çalışabilir hale gelmiştir. Özellikle son 5 yıldır, Google tarafından derin öğrenme için özelleştirilmiş çekirdekleri olan sistemlere yatırımlar yapılmaktadır ve yeni projeler yürütülmektedir [27].
- Veri: 1980'lerden günümüze internetin yaygınlaşması ile büyük veri setlerinin toplanması ve iletilmesi mümkün hale gelmiştir. Bu sayede derin öğrenme modellerinin ihtiyaç duyduğu yüksek miktarda veri sayısına ulaşmak artık imkansız değildir.
- Algoritmalar: Sinir ağlarının eğitimi sırasında katman sayısının artması ile modelin çalışması sıkıntı yaratmaktaydı. 2009 – 2010 yıllarında daha uygun aktivasyon fonksiyonları, RMSProp ve Adam gibi yeni optimizasyon algoritmalarının keşfi ile modellerin daha etkili eğitimi mümkün kılınmıştır.

4.2 Evrişimli Sinir Ağları

Evrişimli sinir ağları, en yaygın kullanılan derin öğrenme mimarilerinden birisidir. Bir adet girdi görüntüsü alıp, görüntüdeki belirli şekillere ve dokulara ağırlık ve önyargılar atayarak ve bunları güncelleyerek, bir görüntüyü diğerinden ayırt edebilen bir sistemdir. Diğer sınıflandırma algoritmaları ile karşılaştırıldığında, evrişimli sinir ağlarının kullanımı için görüntülerin ön işlenmesi daha az önemlidir. Adında da bulundurduğu evrişim işlemini uygular. Evrişim, ortaklama ve tamamen bağlı katmanlar, evrişimli sinir ağlarının ana elemanlarıdır [30]. Şekil 4.1'de bir evrişimli sinir ağının genel yapısı gösterilmektedir.



Şekil 4.1 Evrişimli sinir ağı modeli [Url-3].

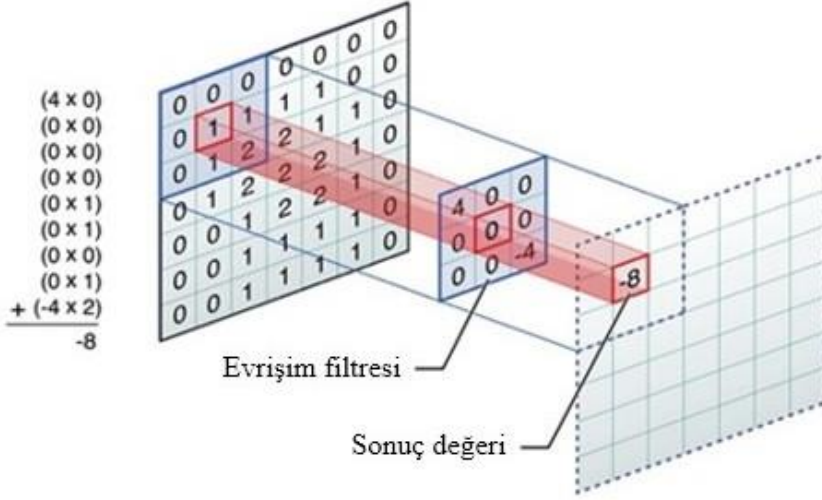
Evrişimli sinir ağlarının kullanımını yaygınlaştıran en önemli avantajları; görüntü tanıma problemlerinde çok yüksek doğruluk oranına ulaşabilmesi ve herhangi bir insan denetimi olmadan bu durumu gerçekleştirebilmesidir. Dezavantaj yaratan özelliği ise, çok fazla sayıda eğitim verisine ihtiyaç duymasıdır. Fazla sayıda eğitim verisine sahip olunmadığında, sistem aşırı uydurma gibi problemlerle karşılaşabilmektedir. Sistem öğrenmek yerine ezberlemeyerek sınıflandırmaya başlar. Bu durum veri çeşitlendirme gibi görüntü ön işleme yöntemleri kullanılarak giderilebilir.

4.2.1 Katmanlar

4.2.1.1 Evrişim

Bu katman ESA'ların yapı taşlarından birisidir. Amacı, giriş görüntüsünden yüksek seviye nitelikler çıkarmaktır. CNN bir adet evrişim katmanı ile sınırlı olmak zorunda değildir. Genellikle, ilk katmanın görevi düşük seviye özellikleri belirlemektir. Bunlar; kenarlar, renkler, gradyan yönü gibi özelliklerdir. Her bir evrişim katmanı eklendiğinde mimari yüksek seviye özelliklere ulaşmaya başlar, yeni bir özellik haritası oluşur ve böylece veri setindeki görüntülerin tümü hakkında bir anlayışa sahip olunur [31,32].

Evrişim işlemi bir filtrenin görüntü üzerinde kaydırılarak, filtre ile kapladığı bölgenin skaler çarpımı sonucu elde edilen değerlerden oluşur. Tüm görüntü üzerinde bu işlem sonlandırıldığında bir adet öznetelik haritası oluşturulmuş olur. Evrişim işlemi Şekil 4.2'de gösterilmiştir.




Şekil 4.2 Evrişim işlemi [Url-4].

Evrşim operasyonunun kaydırma adımı değeri, oluşacak olan özellik haritalarının boyutlarına etki eder. Bu değer her bir evrişim operasyonundan sonra filtrenin görüntü üzerinde ne kadar kaydırılacağı bilgisini taşır. Adım değeri ne kadar fazla olursa oluşacak olan özellik haritasının boyutu da o kadar küçülür.

4.2.1.2 Dolgu

Evrşim operasyonunun sonucunda elde edilen çıktı, girdi görüntüsü ile karşılaştırıldığında aynı boyutta olmayabilir. Bu durumun önüne geçmek için girdi görüntüsüne evrişim işlemi uygulanmadan önce, Şekil 4.3'teki gibi görüntüye eklenen piksel miktarını ifade eden terime dolgu adı verilmiştir. Örnek olarak 5x5 bir nitelik haritasına 3x3'lük bir evrişim penceresi uygularsak ve dolgu işlemi uygulamazsak, evrişimden sonra 3x3'lük bir nitelik haritası elde etmiş oluruz.

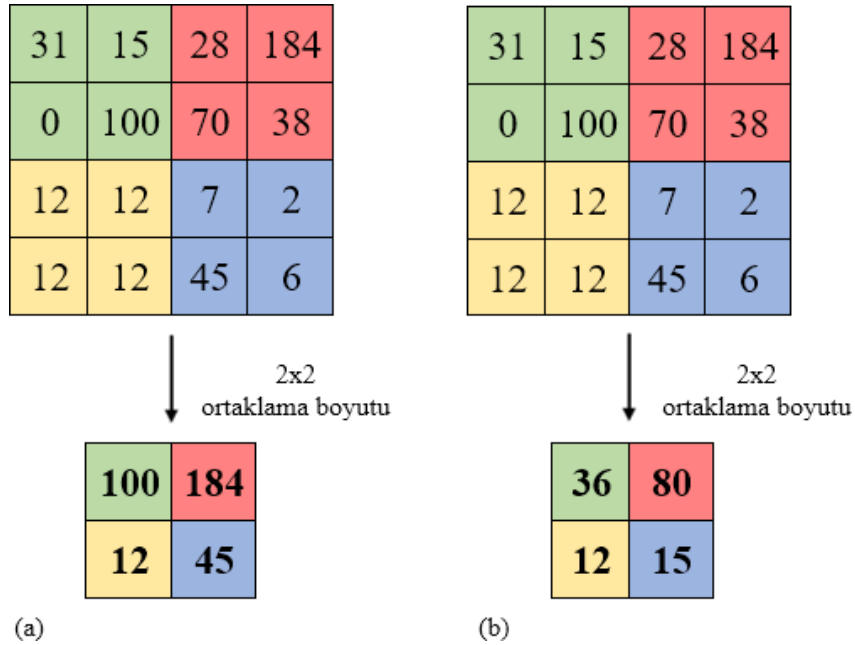


Şekil 4.3 Dolgu işlemi.

Dolgu, bir nitelik haritasının her tarafına yeterli miktarda satır ve sütun ekleyerek, tüm bölgelerde evrişim penceresini gezdirmeyi sağlar. Bu sayede evrişim işlemi sonrası oluşan çıktının boyutu korunmuş olur. Şekil 4.3'te evrişim işlemi öncesi satır ve sütunlara eklenen dolgu sayesinde, evrişim sonrası elde edilen çıktının boyutu (5x5), evrişim öncesi sahip olunan boyut (5x5) ile aynıdır, bir değişiklik gerçekleşmemiştir. Böylece görüntünün sahip olduğu bilgi de kaybedilmemiş olur.

4.2.1.3 Ortaklama

Evrişim katmanına benzer olarak, ortaklama katmanının görevi de verilerin boyutunu azaltarak, ihtiyaç duyulan veri işleme gücünü hafifletmektir [33]. Ayrıca, rotasyon ve konum gibi baskın özelliklerin çıkarılmasında etkilidir. İki çeşidi vardır. Bunlar maksimum ortaklama ve ortalama ortaklamadır. Maksimum ortaklama, filtrenin kapladığı bölgedeki maksimum değeri baz alır. Ortalama ortaklama ise, filtrenin içerisindeki değerlerin ortalamasını kullanır. Maksimum ortaklamanın bir diğer faydası gürültüyü baskılamasıdır. Görüntüde bulunan gürültü etkilerini tamamen ortadan kaldırır ve bu nedenle ortalama ortaklama ile karşılaştırıldığında daha etkili çalışır. Şekil 4.4'te, ortaklama boyutu 2x2 olarak seçilmiştir. Elde edilen çıktıda, 16 adet piksel, 4 adet piksel tarafından temsil edilmiştir.



Şekil 4.4 Ortaklama katmanı çeşitleri (a) maksimum ortaklama, (b) ortalama ortaklama.

4.2.1.4 Düzleştirme

Bu katmanın görevi, tamamen bağlı katman öncesinde verileri hazırlamaktır. Şekil 4.5'te görüldüğü gibi, düzleştirme ile veriler 1 boyutlu bir diziye dönüştürülmektedir. Tek bir uzun öznitelik vektörü oluşturmak için evrişimli katmanların çıktısı düzleştirilir ve tamamen bağlı katmanda kullanmak üzere hazır hale getirilir.




Şekil 4.5 Düzleştirme işlemi.

4.2.1.5 Tamamen bağlı katman

Düzleştirme katmanından sonra gelen bu katman, verilerin düzleştirilmiş vektörünü alır ve sinir ağı ile öğrenme işlemini gerçekleştirir. Önceki adımlarda algılanan özellikler bu vektörün içinde kodlanmıştır. Bu aşamaya gelindiğinde, sınıfları belirleme konusunda bir aşama kaydedilmiştir. Şekil 4.6'da görülen tamamen bağlı katman ile karmaşıklık ve hassasiyet bir üst düzeye çıkarılacaktır.

İlk girdi görüntüsü alındığından beri evrişim, ortaklama, düzleştirme operasyonları uygulanmıştır. Bu katmanın sonunda sinir ağları, tahminlerini ortaya koyar. Örnek olarak bir görüntünün %80 olasılıkla birinci gruba ait olduğunu belirtir. Fakat görüntü aslında ikinci gruba aitse, bu durumda bir hata hesaplanmalıdır. Yapay sinir ağları kapsamında, bu hesaplama bir maliyet fonksiyonu veya ortalama kare hatası olarak adlandırılır, ancak evrişimli sinir ağlarında bu durum genellikle kayıp fonksiyonu olarak isimlendirilir.

Kayıp fonksiyonu, yaratılan ağıın ne kadar doğru olduğunu belirtir ve sonrasında ağıın etkinliğini arttırmak için optimize edilmeyi sağlar. Her bir nöronu birbirine bağlayan ağırlıklar, kayıp fonksiyonunun deęiřimi de göz önünde tutularak optimize edilir. Bu süreçte, ağı istenen duruma ulařana kadar bilgi sürekli olarak ileri geri akmaya devam eder.



řekil 4.6 Tamamen baęlı katmanın yapısı [Url-5].

4.2.2 Aktivasyon fonksiyonu

Aktivasyon fonksiyonu, ağırlıklı toplamı hesaplayarak ve önyargı ekleyerek, bir nöronun aktive edilip edilmeyeceęine karar verir. Kullanılma amacı, bir nöronun çıktısına doğrusal olmama durumunu tanıtmaktır. Tamamen baęlı katmanda belirtildięi üzere, kayıp fonksiyonuna baęlı olarak nöronların ağırlıkları ve önyargıları güncellenir. Bu sürece geri yayılma adı verilir. Aktivasyon fonksiyonları, geri yayılmayı mümkün kılar. Aktivasyon fonksiyonu olmayan bir sinir ağıının doğrusal bir regresyon modelinden bir farkı bulunmamaktadır.

Bir aktivasyon fonksiyonun bulunmadığı bir modelde, ağıımız girdilerden sadece doğrusal dönüşümleri öğrenebilir. Böylece derin bir ağı kullanmanın avantajları elde edilemez.

Modelin daha karmařık görevleri öğrenebilmesi için doğrusal olmama durumları aktivasyon fonksiyonu ile modele eklenir. Çeřitli aktivasyon fonksiyonları vardır.

Bunlar:

- Doğrusal Fonksiyon: Doğrusaldır, bu nedenle fonksiyonun çıktıları herhangi bir aralık içerisinde sınırlanmayacaktır. Regresyon problemlerinde kullanılır. Bu fonksiyon Denklem 4.1’de gösterilmiştir.

$$y = a * x \quad (4.1)$$

Denklem 4.1’de bulunan y dikey eksene, x ise yatay eksene karşılık gelen değeri göstermektedir. Ayrıca, a değeri skaler bir sayıyı, $*$ operasyonu ise çarpma işlemini belirtmektedir.

- Sigmoid Fonksiyonu: Doğrusal olmayan bir fonksiyondur. Çıktıları 0 ile 1 arasında sınırlayan bir denkleme sahiptir (Denklem 4.2). Bu nedenle ikili sınıflandırma problemlerinde kullanılır. Eğer çıktı değeri 0,5’ten büyükse 1, 0,5’ten küçükse 0 olarak kolaylıkla sınıflandırılır (Şekil 4.7).

$$y = 1/(1 + e^{-x}) \quad (4.2)$$


- Tanh Fonksiyonu: Doğrusal olmayan bir fonksiyondur. -1 ile 1 arasında değerler alan bir denkleme sahiptir (Denklem 4.3). Çoğu zaman sigmoid fonksiyonundan daha kullanışlıdır. Genellikle gizli katmanlarda kullanılarak bir sonraki katmanın öğrenmesini kolaylaştırır (Şekil 4.7).

$$y = 2/(1 + e^{-2x}) - 1 \quad (4.3)$$

- ReLU (Rectified Linear Unit) Fonksiyonu: En sık kullanılan aktivasyon fonksiyonudur. Sigmoid ve tanh fonksiyonlarından daha hızlı çalışır (Şekil 4.7). Denklem aldıkları değer pozitifse, çıktı o değerdir. Eğer negatifse, çıktı her zaman 0 değerini alır (Denklem 4.4).

$$y = \max(0, x) \quad (4.4)$$

- Softmax Fonksiyonu: Genellikle modelin çıktı katmanında tercih edilir. Çok sınıflı sınıflandırma problemlerinde kullanılır.



Şekil 4.7 En yaygın kullanılan üç aktivasyon fonksiyonunun grafikleri (a) sigmoid, (b) tanh, (c) ReLU [26].

4.2.3 Kayıp fonksiyonu

Sinir ağlarının en önemli bileşenlerinden birisi de kayıp fonksiyonudur. Kayıp, kabaca ağdaki hatanın hesabıdır. Kayıp fonksiyonu ise bu hatanın hesaplanma yöntemini belirler. Sinir ağında bulunan her bir nöronun ağırlığı, kayıp fonksiyonundan elde edilen sonuca göre güncellenir. Böylece eğitim gerçekleştirilmiş olur. Çeşitli kayıp fonksiyonları mevcuttur. Bunlardan en yaygın kullanılanları:

- Ortalama Kare Hatası (Mean Squared Error): Regresyon problemlerinde kullanılır. Gerçek ve tahmin edilen değerler arasındaki farkların karesinin ortalamaları alınarak hesaplanır.
- İkili Çapraz Entropi (Binary Crossentropy): İkili sınıflandırma problemlerinde kullanılır. Bu kayıp fonksiyonu kullanılırken, bir adet çıkış noduna ihtiyaç vardır ve çıkış değeri sigmoid aktivasyon fonksiyonundan geçirilmelidir.
- Kategorik Çapraz Entropi (Categorical Crossentropy): Çok sınıflı bir sınıflandırma problemi olduğundan kullanılacak olan kayıp fonksiyonudur. Çıkış katmanında sınıf adedi kadar nod olmalıdır ve çıkış değeri softmax aktivasyon fonksiyonununundan geçirilmelidir.
- Seyrek Kategorik Çapraz Entropi (Sparse Categorical Crossentropy): Her bir veri sadece bir sınıfa ait ise kullanılır.

Problem çeşidine göre kullanılması en ideal son katman aktivasyon fonksiyonları ve kayıp fonksiyonları Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1 Problem çeşidine en uygun aktivasyon ve kayıp fonksiyonları.

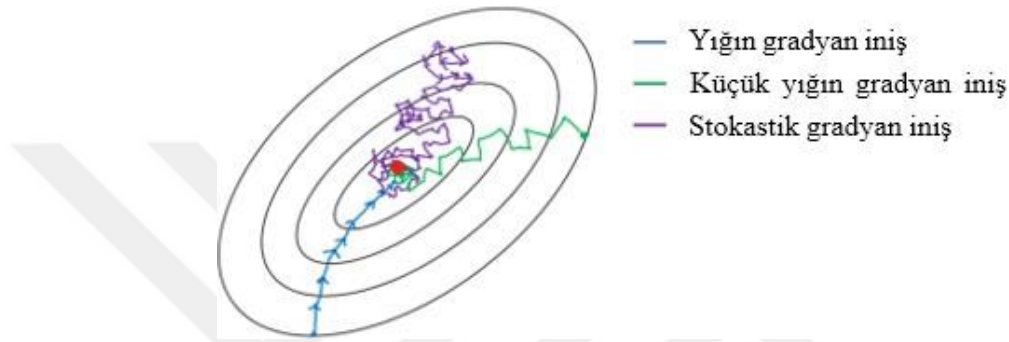
Problem Tipi	Son Katman Aktivasyon Fonksiyonu	Kayıp Fonksiyonu
İkili sınıflandırma	Sigmoid	İkili çapraz entropi
Tek etiketli çoklu sınıflandırma	Softmax	Kategorik çapraz entropi
Çok etiketli çoklu sınıflandırma	Sigmoid	İkili çapraz entropi
Herhangi bir değere bağlanım	-	Ortalama kare hatası
0 – 1 aralığına bağlanım	Sigmoid	Ortalama kare hatası ya da ikili çapraz entropi

4.2.4 Optimizasyon algoritması

İyileştiriciler; kayıpları azaltmak için sinir ağının ağırlık ve öğrenme hızı gibi özelliklerini değiştirmek ve modifiye etmek için kullanılan algoritmalarlardır. Bu sayede elde edilecek olan sonuçların olabileceği en isabetli sonuçlar olmasını sağlamaya çalışırlar. Çeşitli iyileştiriciler ve bunların avantajlı oldukları durumlar vardır:

- Gradyan iniş (Gradient descent): En temel ve en çok kullanılan optimizasyon algoritmasıdır. Lineer regresyon ve sınıflandırma problemlerinde kullanılır. Sinir ağlarında bulunan geri yayılım da bir gradyan iniş algoritmasıdır. Hesaplaması ve uygulaması kolay olmakla beraber lokal minimumda sıkışma durumu büyük bir dezavantaj yaratmaktadır.
- Yığın gradyan iniş (Batch gradient descent): Tüm eğitim setini taradıktan sonra parametreleri günceller. Global minimum değerine ulaşır ancak çalışma süresi çok uzundur. Sinir ağlarında kullanımı nadir görülür (Şekil 4.8).

- Stokastik gradyan iniş (Stochastic gradient descent): Modelin parametrelerini her bir eğitim verisinden sonra günceller. Bu durumla beraber parametrelerde yüksek varyans görülür ve global minimuma ulaşırken çok fazla dalgalanma gerçekleşir (Şekil 4.8).
- Küçük yığın gradyan iniş (Mini batch gradient descent): Yığın gradyan ve stokastik gradyanın avantajlı yönlerini kullanarak, parametrelerin güncellemesini her bir yığın parçasının gradyanı elde edildikten sonra yapar, fakat iyi bir yakınsamayı garantileyemediğinden yaygın kullanılmaz.



Şekil 4.8 Yığın, küçük yığın ve stokastik gradyan iniş algoritmaları [Url-6].

- Momentum: Stokastik gradyan inişin yarattığı yüksek varyans durumuna çözüm olarak keşfedilmiştir. Fakat modele momentum adında başka bir parametre eklemiştir. Modelin en iyi performansı verebilmesi için bu değer dikkatli ve isabetli bir şekilde seçilmelidir.
- Adagrad: Bütün eniyileştiricilerin dezavantajı olan öğrenme hızının sabit olması durumu, Adagrad sayesinde çözülebilmektedir. 2. dereceden bir optimizasyon algoritması olduğundan hesaplama zorlukları ile karşılaşmaktadır. Ayrıca öğrenme hızının gittikçe azalması ile eğitim bir süreden sonra durmaktadır.
- Adadelta: Adagrad'ın azalan öğrenme hızı problemini çözen bir algoritmadır.
- RMSprop: Momentumlu gradyan iniş algoritmasına benzer. RMSprop dikey yönde meydana gelen salınımları sınırlar. Bu nedenle, öğrenme hızı artırılarak algoritmanın daha hızlı yakınsaması sağlanabilir.
- Adam (Adaptive moment estimation): Adam algoritmasının yaklaşımı, global minimumun üzerinden atlama ihtimalini ortadan kaldırmak için öğrenme hızını düşürmek ve temkinli şekilde ilerlemektir. En iyi optimizasyon algoritması Sinir ağlarını kısa zamanda en etkili şekilde eğiten algoritmadır.




5. YÖNTEM

Bu bölümde, tez kapsamında kullanılan veri setinin detayları, veri setinde bulunan görüntülerin ön işlenmesi, oluşturulan evrişimli sinir ağı mimarilerinin özellikleri, modellerin eğitim aşamasındaki parametreleri ve etkileri, son olarak da belirlenen değerlendirme kriterlerinin incelenmesi üzerinde durulmuştur.

5.1 Veri Seti

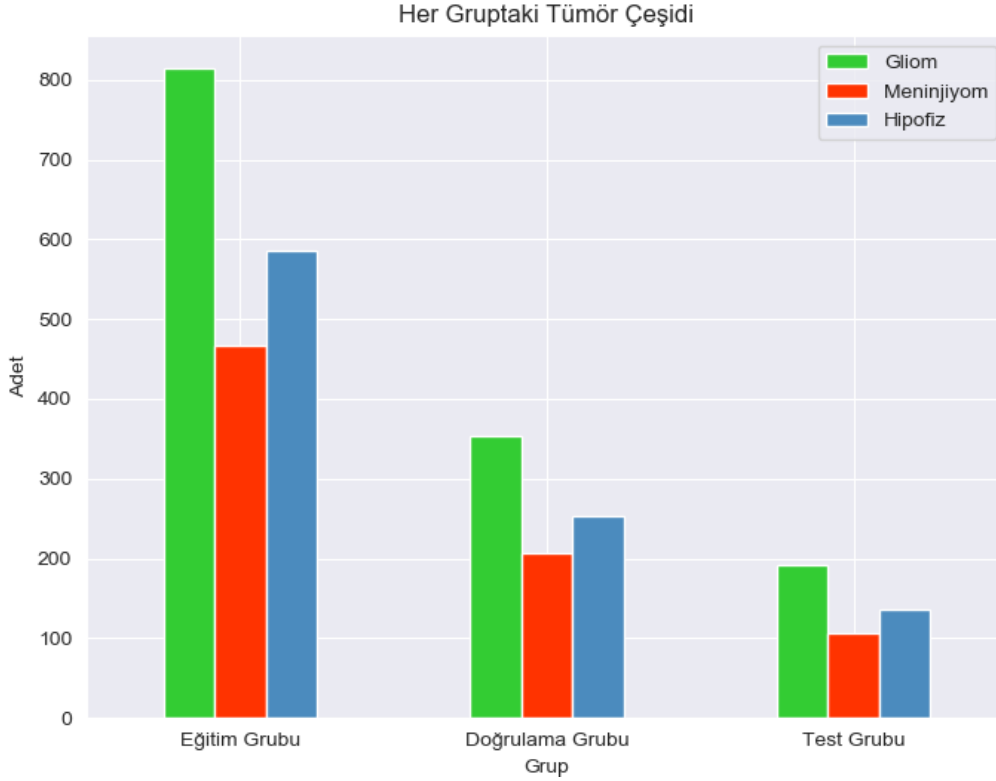
Bu tez çalışmasında, Jun Cheng'in oluşturduğu ve iki adet çalışmasında da kullandığı 3064 adet T1 ağırlıklı beyin MRI görüntüleri kullanılmıştır [6,34]. Bu veri seti, 3 adet tümör tipini içeren beyin görüntülerinden oluşmuştur. Bunlar; gliom, meninjiyom ve hipofiz tümörleridir (Resim 5.1). Görüntülerden 1426 adeti gliom, 708 adeti meninjiyom ve 930 adeti hipofiz tümör sınıfına aittir.



Resim 5.1 Veri setinde bulunan üç çeşit beyin tümörünün MRI görüntüleri (a) Gliom, (b) Meninjiyom, (c) Hipofiz [Url-1].

İlk olarak görüntüler etiketlerine göre gruplandırılarak, dosya tipleri .jpeg uzantılı olacak şekilde kaydedilmiştir. Bu sayede görüntülerin bit sayısı azaltılarak, yapılacak olan işlemlerin donanımsal kısıtlamalara takılmadan hızlı bir şekilde ilerlemesi amaçlanmıştır.

3064 adet T1 ağırlıklı beyin MRI görüntüsü evrişimli sinir ağlarını beslemek ve test etmek için eğitim, doğrulama ve test olacak şekilde üç gruba ayrılmıştır. Bu gruplarda bulunması planlanan görüntü sayısı, Şekil 5.1’de görüldüğü üzere, her bir beyin tümörü çeşidinde bulunan görüntü sayısının sırasıyla eğitim için %60, doğrulama için %26 ve test için %14’ü olarak belirlenmiştir. Bu değerler çeşitli değerler denendikten sonra daha iyi sonuç alındığı için tercih edilmiştir.



Şekil 5.1 Veri setinin eğitim, doğrulama ve test gruplarında bulunan tümör çeşitlerinin sayıları.

Yapılan çalışmada modelin eğitimi için harcanan zaman incelendiğinden ve sonuçlar kısmında değerlendirildiğinden, kullanılan bilgisayarın özellikleri önemli yer tutmaktadır. Özellikleri; i7-6700HQ, 2.60 GHz, 16 GB RAM, NVIDIA Geforce GTX 960M şeklindedir.

5.2 Görüntülerin Ön İşlenmesi

Beyin MRI görüntülerine, evrişimli sinir ağı modellerine girdi olarak verilmeden önce, daha isabetli ve çabuk sonuçlar alabilmek amacıyla ön işleme uygulanmıştır. Öncelikle görüntüler boyutlandırılarak 512x512 yerine 112x112 olarak yeniden ölçeklendirilmiş olup, bu sayede modellerin daha verimli eğitilmesi amaçlanmıştır.

5.2.1 Veri çeşitlendirme

Derin öğrenme modellerinin özellikle de evrişimli sinir ağlarının eğitimi için çok fazla sayıda eğitim verisi gerekmekte olup, modelleri eğitmek için kullanılacak olan veri sayısının çok fazla olmamasından ötürü veri çeşitlendirmeye başvurulmuştur. Yetersiz veri sayısından dolayı oluşabilecek aşırı uydurmanın (over fitting) da önüne geçilmesi hedeflenmiştir.

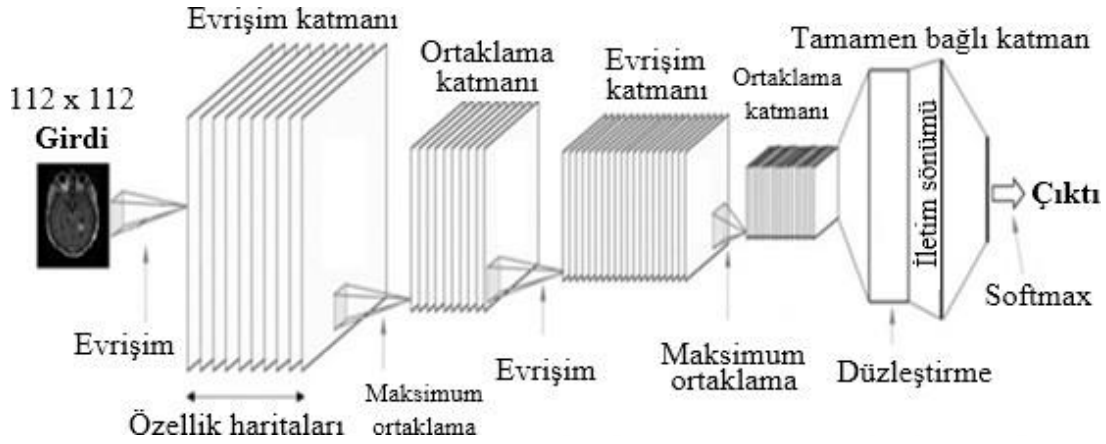
Veri çeşitlendirme, elde bulunan verilere birtakım dönüşümler uygulayarak gerçeğe yakın daha fazla veri oluşturur. Yeni görüntüler oluşturulurken çeşitli dönüşümler uygulanmıştır. Bu çalışmada eğitim veri seti üzerinde uygulanan işlemler şu şekildedir:

- Rescale = 1/255, yeniden boyutlandırma
- Rotation_range = 15, resimlerin rastgele döndürme açısı.
- Width_shift_range = 0.1, resimlerin yatayda kaydırma oranı (genişliğe oranla)
- Height_shift_Range = 0.1, resimlerin dikeyde kaydırma oranı (dikeye oranla)
- Shear range = 0.1, burkma işlemi
- Brightness range = [0,5, 1,5], parlaklık aralığı
- Vertical flip = True, yatayda resmi döndürme
- Horizontal Flip = True, dikeyde resmi döndürme
- Fill mode = 'nearest', kaydırma, döndürme gibi işlemler sonrası fazla miktarda bulunan görüntü noktalarını doldurma yöntemi

Yukarıda verilen dönüşümler ve parametreler kullanılarak veri çeşitlendirme işlemi yapılmıştır. Doğrulama ve test grubundaki görüntüler sabit tutulmuştur.

5.3 Modellerin Özellikleri

Çalışmada kullanılan evrişimli sinir ağı modelinin genel yapısı Şekil 5.2’de gösterilmiştir. İlk olarak girdi görüntüsüne evrişim işlemi uygulanmaktadır. Ardından ortaklama katmanı gelmektedir. Bu katmanların sayıları ve boyutları, modeller arasında değişiklik göstermektedir. Öznitelik öğrenme kısmı tamamlandıktan sonra, sinir ağının sınıflandırma kısmına geçilmiştir. Bu bölümde bulunan düzleştirme, iletim sönümü ve tamamen bağlı katmanlar çalışmada yaratılan bütün modellerde aynı sıradadır ve aynı değerlere sahiptir.



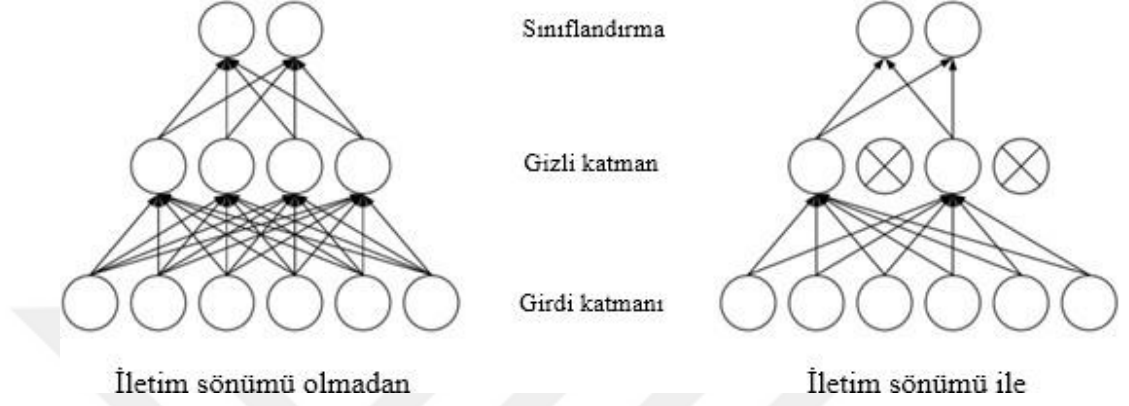
Şekil 5.2 Evrişimli sinir ağı modelinin genel yapısı [Url-7].

Bölüm 4 olan Derin Öğrenme kısmında, evrişimli sinir ağlarında bulunan en temel katmanlardan bahsedilmiştir. Bir evrişimli sinir ağında bulunabilecek opsiyonel özelliklerden olan iletim sönümü ve transfer öğrenmeye bu bölümde yer verilmiştir. Bu iki özellik de sinir ağının öğrenmesine etki edeceğinden, sınıflandırma performansını etkileyebilecek yöntemlerdir.

5.3.1 İletim sönümü

Sinir ağı derinleştikçe, parametre sayılarında artış meydana gelmekte ve model aşırı uydurmaya başlayabilmektedir. Bu durum modelin öğrenmekten çok hatırlayarak karar vermesine neden olmaktadır. İletim sönümü, aşırı uydurmanın önüne geçmek için kullanılan en yaygın tekniklerden birisidir [35]. Bu katman aldığı orana bağlı olarak, eğitim aşamasındaki nodların etkinliğini durdurur.

Örnek olarak 0,5 değerine sahip bir iletim sönümü, nodların yarısının öğrenmeye olan katkısını durdurur (Şekil 5.3). İletim sönümü evrişim katmanları arasında veya tamamen bağlı katmanda kullanılabilir. Bu çalışmada kullanılan iletim sönümleri sadece tamamen bağlı katmanda bulunmaktadır.



Şekil 5.3 İletim sönümü kullanılan ve kullanılmayan bir sinir ağı arasındaki fark.

5.3.2 Transfer öğrenme

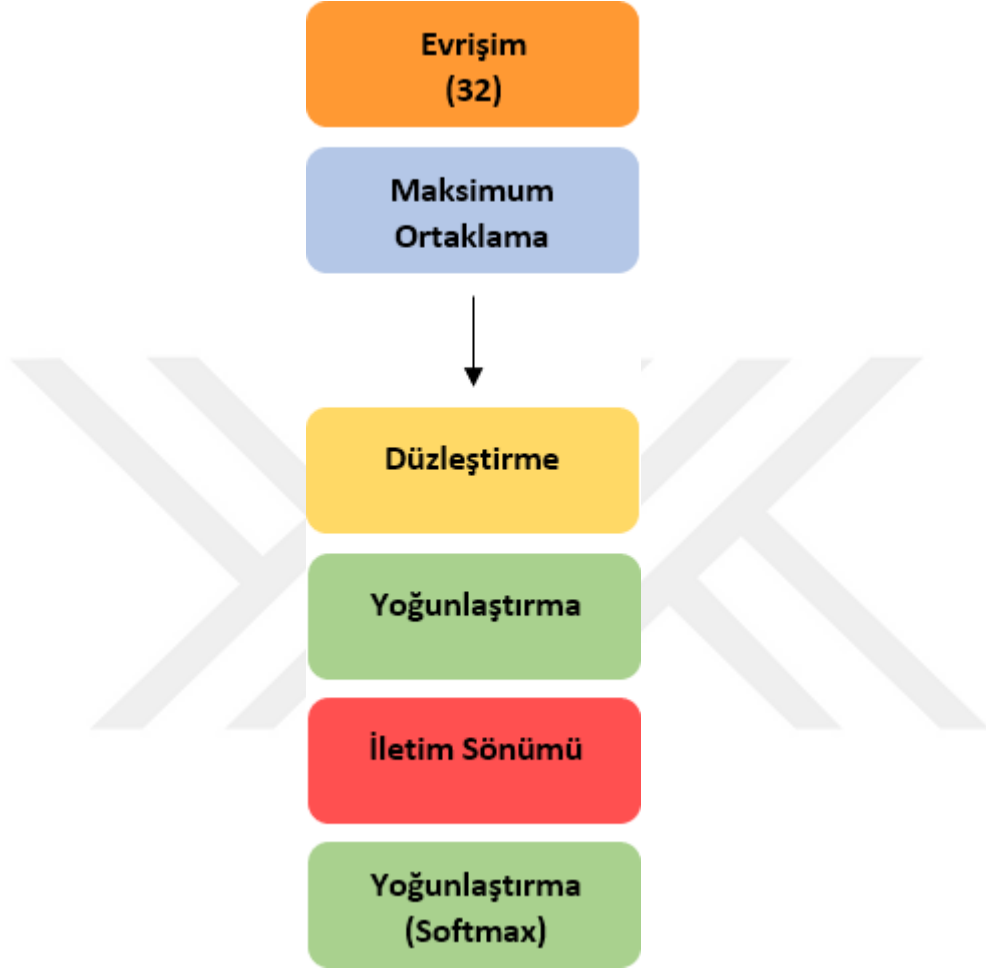
Modellerin eğitimi, modelin ne kadar karmaşık olduğuna ve veri setinin büyüklüğüne bağlıdır. Standart bilgisayarlarda gerçekleştirilmesi zor durumlarla karşılaşılabilir. Transfer öğrenme burada devreye girer. Günlerce süren eğitimlerin sonucunda elde edilen bu eğitilmiş modeller, başka problemleri çözmek için kullanılabilir. Transfer öğrenmenin temel mantığı, büyük bir veri seti ile eğitilmiş bir modelin elde ettiği bilgilerin daha küçük bir veri setine aktarılmasıdır. Örnek olarak, 15 milyon görüntüden oluşan veri seti ImageNet ile eğitilecek olan bir model, az veri sayısına sahip olunan durumlarda başvurulan en yaygın transfer öğrenme yöntemidir [36].

5.4 Modeller

Çalışma süresince farklı ağ yapılarındaki modeller denenmiş olup çalışmanın amacını en düzgün şekilde aktarabilmek için aralarından yedi adet model seçilmiştir. Bu modellerin birbirleri arasındaki en belirgin fark evrişim ve maksimum ortaklama katman sayılarıdır.

5.4.1 Model 1

Şekil 5.4'te yapısı verilen model 1; 3x3 boyuta sahip 32 filtrelik bir evrişim katmanına sahip olmakla beraber ReLu aktivasyon fonksiyonunu kullanmaktadır. Maksimum ortaklama katmanı 2x2 boyutundadır.

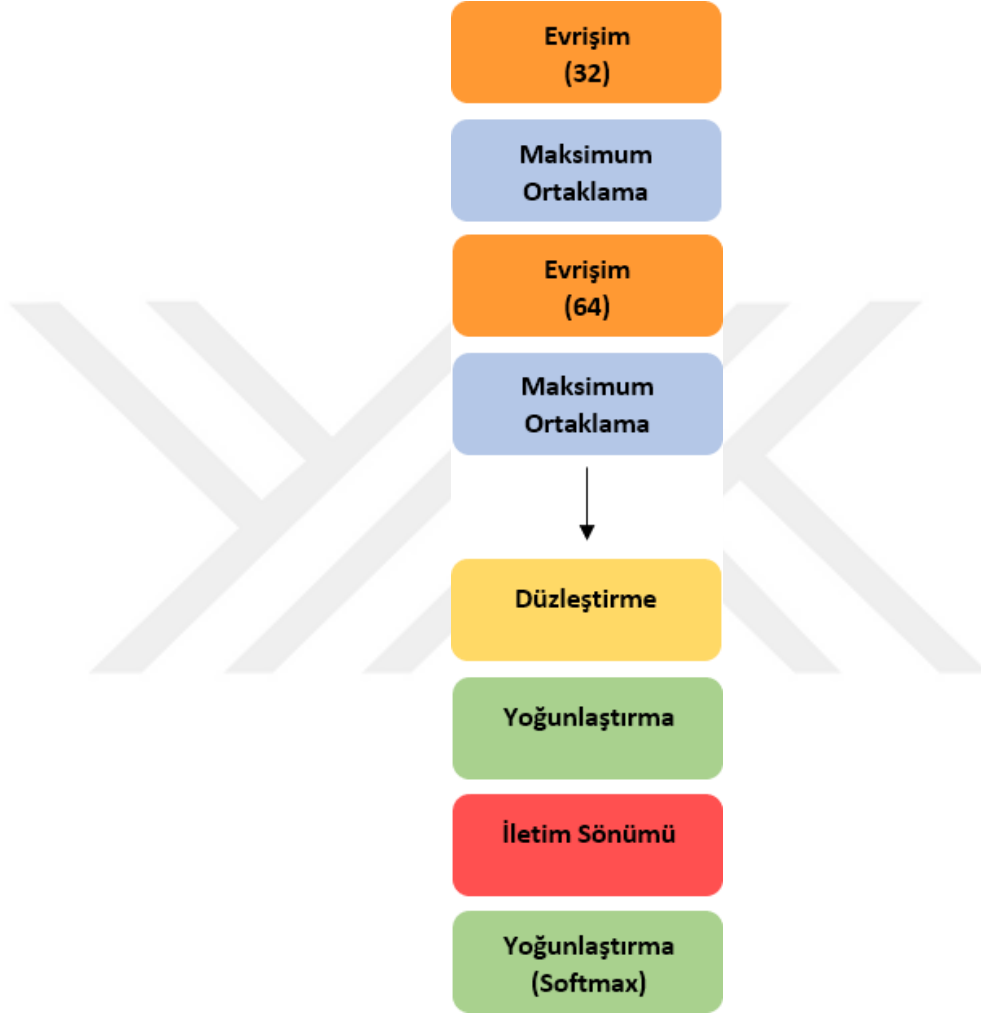


Şekil 5.4 Model 1'in yapısı.

Sonrasında elde edilen çıktıları bir boyutlu vektöre düzleştirmek için düzleştirme katmanı eklenmiştir. Tamamen bağlı katmanda ise 512 noda sahip yoğunlaştırma katmanı mevcuttur. Ayrıca 0,5 oranında iletim sönümü eklenerek aşırı öğrenmenin önüne geçilmesi hedeflenmiştir. En sondaki yoğunlaştırma katmanında ise 3 adet sınıf bulunduğundan softmax aktivasyon fonksiyonu kullanılmıştır.

5.4.2 Model 2

Şekil 5.5'te yapısı verilen model 2; model 1'deki evrişim ve maksimum ortaklama katmanlarına ek olarak 3x3 boyuta sahip 64 filtrelilik bir evrişim katmanı ile beraber ReLu aktivasyon fonksiyonunu kullanmaktadır. Sonrasında gelen maksimum ortaklama katmanı 2x2 boyutundadır.



Şekil 5.5 Model 2'nin yapısı.

Sonrasında elde edilen çıktıları bir boyutlu vektöre düzleştirmek için düzleştirme katmanı eklenmiştir. Tamamen bağlı katmanda ise 512 noda sahip yoğunlaştırma katmanı mevcuttur. Ayrıca 0,5 oranında iletim sönümü eklenerek aşırı öğrenmenin önüne geçilmesi hedeflenmiştir. En sondaki yoğunlaştırma katmanında ise 3 adet sınıf bulunduğundan softmax aktivasyon fonksiyonu kullanılmıştır.

5.4.3 Model 3

Şekil 5.6’da yapısı verilen model 3; model 2’deki evrişim ve maksimum ortaklama katmanlarına ek olarak 3x3 boyuta sahip 128 filtrelilik bir evrişim katmanı ile beraber ReLu aktivasyon fonksiyonunu kullanmaktadır. Sonrasında gelen maksimum ortaklama katmanı 2x2 boyutundadır.



Şekil 5.6 Model 3’ün yapısı.

Düzleştirme, iletim sönümü ve yoğunlaştırma katmanlarının tüm özellikleri, önceki modellerinki ile birebir aynıdır.

5.4.4 Model 4

Şekil 5.7’de yapısı verilen model 4; model 3’teki evrişim ve maksimum ortaklama katmanlarına ek olarak 3x3 boyutuna sahip 256 filtrelilik bir evrişim katmanı ile beraber ReLu aktivasyon fonksiyonunu kullanmaktadır. Sonrasında gelen maksimum ortaklama katmanı 2x2 boyutundadır.

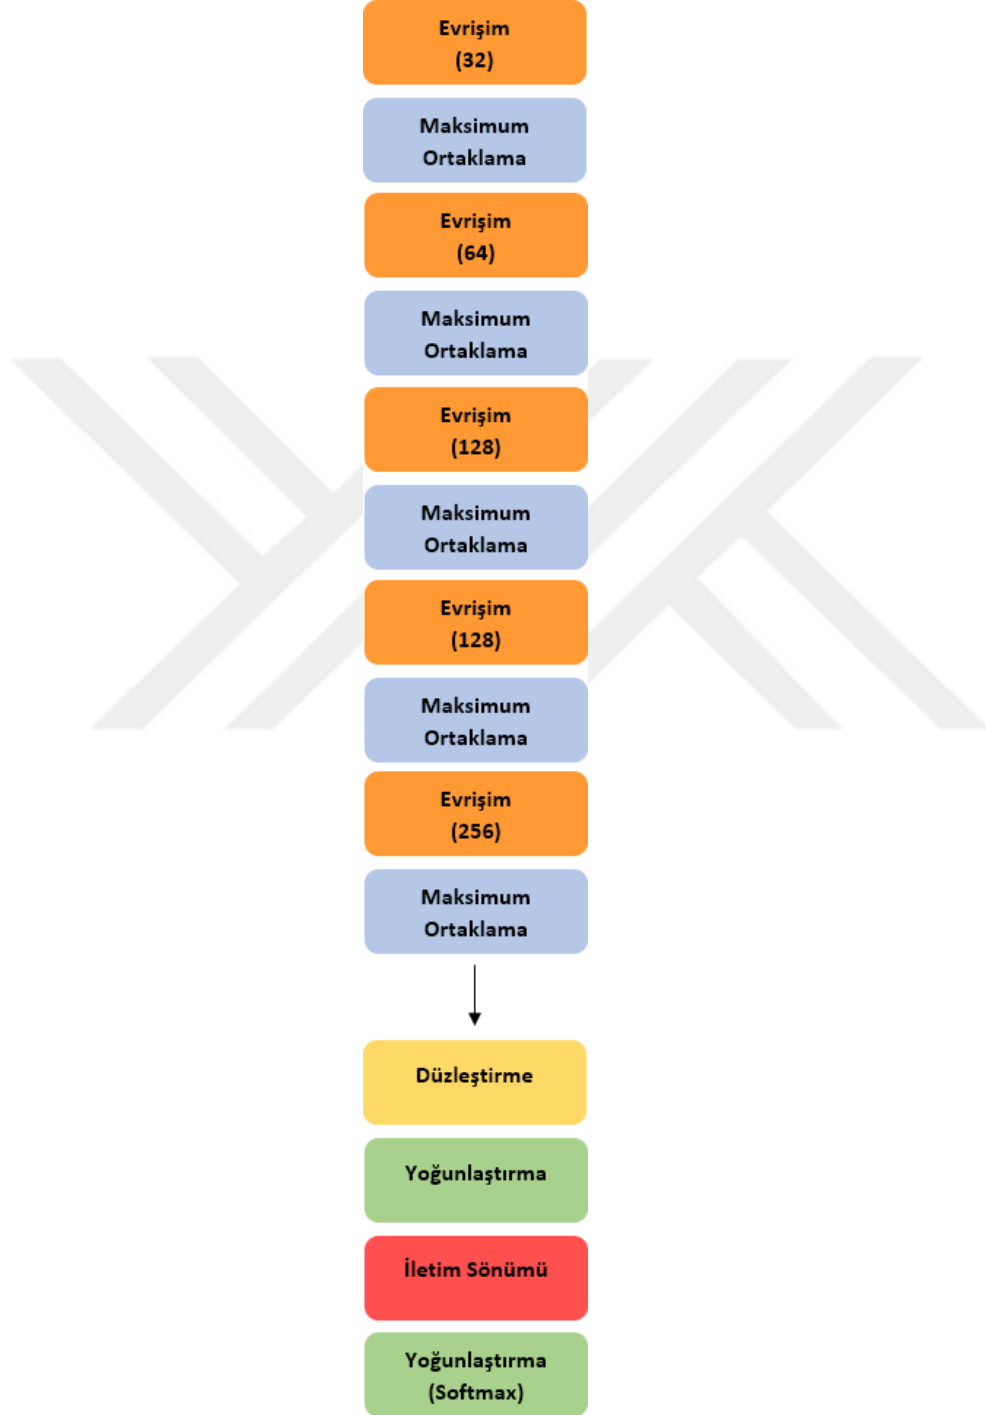


Şekil 5.7 Model 4’ün yapısı.

Düzleştirme, iletim sönümü ve yoğunlaştırma katmanlarının tüm özellikleri, önceki modellerinki ile birebir aynıdır.

5.4.5 Model 5

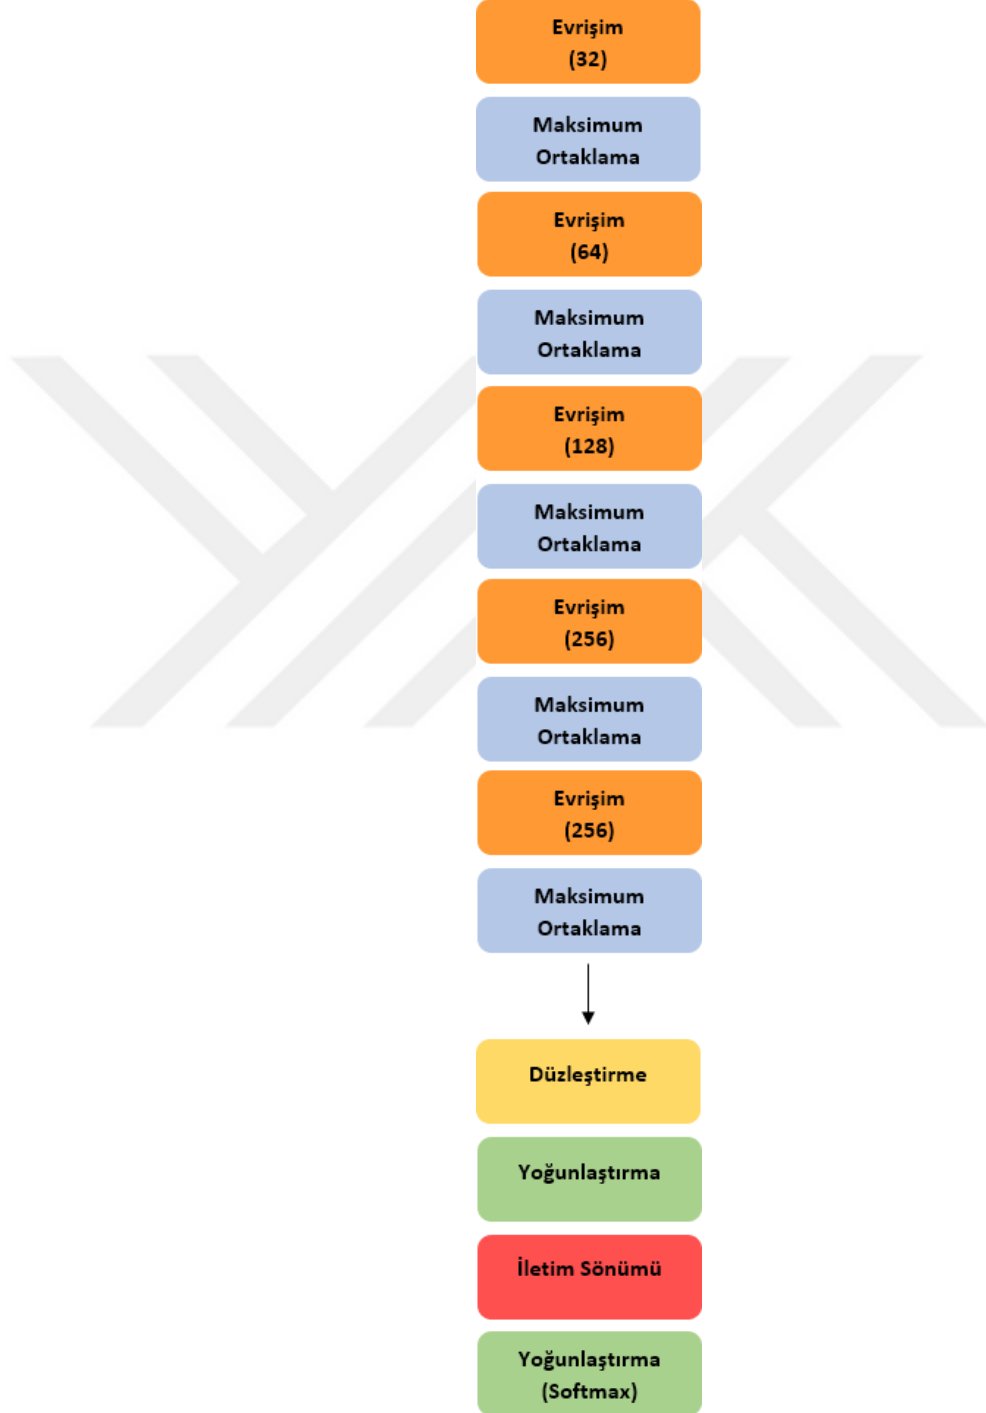
Şekil 5.8’de yapısı verilen model 5; model 4’teki 128 filtrelik evrişim ve ardından gelen maksimum ortaklama katmanlarından sonra bir adet daha bu ikiliden eklenmesi ile oluşturulmuştur.



Şekil 5.8 Model 5’in yapısı.

5.4.6 Model 6

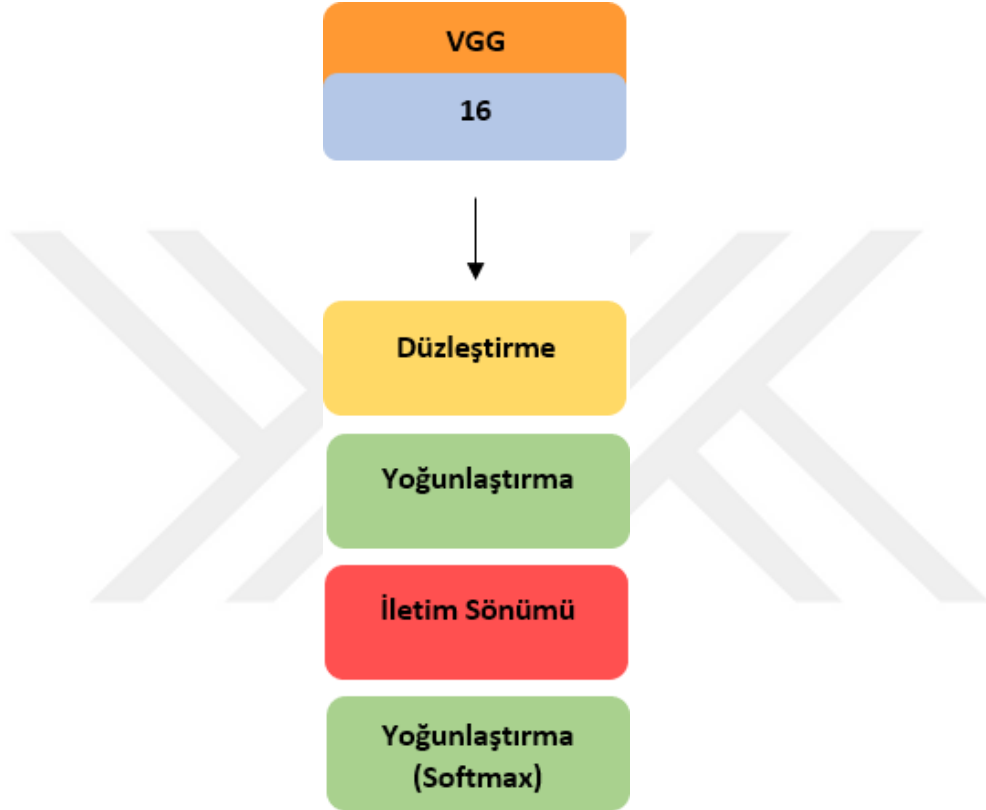
Şekil 5.9’da yapısı verilen model 6; model 4’teki 256 filtrelik evrişim ve ardından gelen maksimum ortaklama katmanlarından sonra bir adet daha bu ikiliden eklenmesi ile oluşturulmuştur.



Şekil 5.9 Model 6’nın yapısı.

5.4.7 Model 7


Şekil 5.10'da yapısı verilen model 7; VGG-16 sinir ağı mimarisi ile transfer öğrenme beraber kullanılarak oluşturulmuştur. ImageNet veri setinin ön eğitimi tercih edilmiştir. Modelde yer alan düzleştirme ve tamamen bağlı katmanlar, önceki modeller ile aynıdır.



Şekil 5.10 Model 7'nin yapısı.

Modellerde evrişim için 3×3 , maksimum ortaklama için 2×2 boyutunda filtrelerin kullanılmasının nedeni, deney aşamasında çeşitli filtre boyutlarının denenmiş olup, evrişim işlemi için 3×3 'ün, maksimum ortaklama için ise 2×2 'nin diğer boyutlara kıyasla daha iyi sonuçlar vermesidir.

Her evrişim katmanında, lineer olmama durumunu modele tanıtmak için ReLU aktivasyon fonksiyonu kullanılmıştır. ReLU'nun alacağı değerler Şekil 5.11'de görülmektedir.



Şekil 5.11 ReLU aktivasyon fonksiyonunun grafiği.

ReLU aktivasyon fonksiyonunun seçilmesinin nedeni, x ekseninde 0'dan küçük değerler için y ekseninde alınacak ek küçük değerlerin 0 olması, yani negatif değerler alamamasıdır. Ayrıca x ekseninde 0'dan büyük değerler için de doğrusal bir değerlendirme vardır (Denklem 5.1).

$$y = \max(0, x) \quad (5.1)$$

Tamamen bağlı katmanın sonunda aktivasyon fonksiyonu olarak softmax kullanılarak, her bir sınıfa ait olasılıkların hesaplanması sağlanmıştır. Sınıf sayısı iki adetten fazla olduğu için sigmoid yerine softmax kullanılmıştır (Denklem 5.2).

$$f(s)_i = \frac{e^{s_i}}{\sum_j^C e^{s_j}} \quad (5.2)$$

Denklem 5.2'de, s vektörünün her bir elemanı olan s_j için, eksponansiyel değerler hesaplanıyor, tüm eksponansiyellerin sayısı olan C tanesi toplanıp, normalize ediliyor.

Kategorik çapraz entropi fonksiyonu, modelin kayıp değerinin hesaplanmasında kullanılmıştır (Denklem 5.3).

$$CE = - \sum_i^C t_i \log(f(s)_i) \quad (5.3)$$

Denklem 5.3'te C eğitim verisetindeki sınıf sayısını, t_i doğru sınıfı, $f(s)_i$ ise softmax aktivasyon fonksiyonundan elde edilen olasılık değerini belirtir.

Optimizasyon algoritması olarak Adam tercih edilmiştir (Denklem 5.4).

$$\begin{aligned}v_t &= \beta_1 * v_{t-1} - (1 - \beta_1) * g_t \\s_t &= \beta_2 * s_{t-1} - (1 - \beta_2) * g_t^2 \\ \Delta\omega_t &= -\mu \frac{v_t}{\sqrt{s_t} + \epsilon} * g_t \\ \omega_{t+1} &= \omega_t + \Delta\omega_t\end{aligned}\tag{5.4}$$

Burada, μ başlangıç öğrenme hızını, g_t t anındaki gradyan değeri, v_t gradyanların eksponansiyel ortalamasını, s_t gradyanların karelerinin eksponansiyel ortalamasını, β_1, β_2 hiper parametreleri belirtmektedirler. β_1 parametresinin değeri çoğunlukla 0.9, β_2 parametresinin değeri ise 0.99 olarak seçilir. ϵ ise $1e^{-10}$ değerini alır.

Modeller, çeşitli aktivasyon fonksiyonları, kayıp fonksiyonları ve optimizasyon algoritmaları kullanılarak denendikten sonra, çalışma için en ideal sonuçların alınmasını sağlayan ve yukarıda belirtilen ReLu ve softmax aktivasyon fonksiyonları, kategorik çapraz entropi kayıp fonksiyonu ve Adam optimizasyon algoritması kullanılarak eğitilmiştir. Test veri setindeki görüntüler değerlendirme kısmında kullanılmak üzere ayrılmıştır.

5.5 Eğitim

Eğitim aşamasında, kayıp fonksiyonu ve optimizasyon algoritması belirlendikten sonra, eğitim için önem arz eden hiper parametreler ayarlanmıştır. Bu parametreler;

- **Öğrenme Hızı:** Modelin, eğitim veri setindeki örneklerden öğrenme hızıdır. Genellikle yüksek bir öğrenme hızı, modelin hızlı öğrenmesini sağlamakla beraber, global minimuma ulaşmayı mümkün kılmayabilir. Aynı şekilde, küçük bir öğrenme hızı ise optimal değere ulaşabilir ancak bu durum çok uzun süreler alabilir. Çalışmadaki modellerde bu değer 10^{-4} olarak seçilmiştir.
- **Epok Sayısı:** Bir modelin öğrenme algoritmasının, tüm veri setini gördüğü tekrar sayısı olarak tanımlanır. Bu çalışmada, çeşitli epok sayıları denendikten sonra, çalışmanın en ideal şekilde incelenmesi için epok sayısı 30 olan bir eğitim yapılmıştır.
- **Yığın sayısı (Batch Size):** Epok sayısı, eğitim veri seti üzerinden geçilme sayısı iken, yığın sayısı ise, model güncellenmeden önce incelenecek olan verisayısı

olarak adlandırılır. Tüm görüntüleri tek bir yığında incelemek zorluk yaratacağından, gruplar halinde incelemek tercih edilmiştir. Çalışmada yığın sayısı 32 olarak seçilmiştir.

- Epok başına adım (Steps per epoch): Bir epokluk eğitimin tamamlanması için seçilen yığın adedini belirtir. Örnek olarak; 50 adım değerine sahip bir modelde, bir epokun tamamlanması için 50 adet yığın üzerinden eğitilmesi gerekir. Bu çalışmada epok başına adım değeri 100'dür.
- Doğrulama adımı (Validation steps): Epok başına adımın, doğrulama veri setinde kullanılan halidir. Çalışmada bu değer 50 olarak belirlenmiştir.

Yukarıda bulunan hiperparametrelerin değerleri, çeşitli varyasyonlar denenerek bu veri seti için en etkili değerlerin elde edilebileceği şekilde ayarlanmıştır.

Modellerin eğitimi sırasında kontrol amaçlı ve olabildiğince iyi sonuca ulaşabilmek için, eğitim kaybı gözlemlenmiştir. Eğer 5 epokta bir, varolan kayıp değeri azalma göstermemekteyse, 0,5 oranında öğrenme hızı azaltma işlemi uygulanmıştır. Bu sayede ulaşılabilecek global minimum noktasının üzerinden yüksek öğrenme hızı nedeni ile atlanmanın önüne geçilmesi hedeflenmiştir. Ayrıca öğrenmenin durmaması için minimum öğrenme hızı değeri 10^{-7} olarak belirlenmiştir. Eğer bu değere ulaşırsa, sinir ağı öğrenmesi duracaktır.

Sinir ağı modellerinin eğitimleri bittikten sonra, eğitim başarımları ve eğitim kaybı değişim grafikleri artan epok sayısına göre oluşturulmuştur. Bu grafiklerin daha rahat incelenebilmesi için grafiklerin düzleştirilmiş, yumuşatılmış halleri de oluşturulmuştur.

Önceden ayrılmış olan test veri seti, modellerin değerlendirme kriterlerine bağlı olarak incelenmesi amacıyla kullanılmıştır. Test veri setinde yer alan görüntüler, eğitilen modeller kullanılarak sınıflandırılmıştır. Görüntülerin etiketleri ile aslında ait oldukları sınıf etiketleri karşılaştırılarak, bir hata matrisi oluşturulmuştur. Bu hata matrisi değerlendirme kriterleri kullanılarak ve kriterler hesaplanarak, sistemin verimliliğinin hesaplanması için kullanılmıştır.

Çalışmanın amacında da belirtildiği üzere, sistemin isabet oranı kadar eğitim için harcanan zaman da önemli yer tutmaktadır. Bu nedenle, her bir modelin eğitiminin ne kadar sürdüğü hesaplanmış ve Bölüm 6 olan Bulgular bölümünde incelenmiştir.

5.6 Değerlendirme Kriterleri

Evrişimli sinir ağı modellerinin verimlerinin incelenmesi ve modellerin birbirleri ile karşılaştırılması için kriter olarak doğruluk, kesinlik ve duyarlılık ölçütleri kullanılmıştır.

- Doğruluk (Accuracy): En sık kullanılan ve model hakkında genel bir yargıya varılmasına en kolay olanak veren ölçüttür. Toplam veri sayısından doğru sınıflandırılan miktarı belirtir.
- Kesinlik (Precision): Sınıflandırılmış olan bir verinin gerçekten o sınıfa ait olup olmadığını belirtir.
- Duyarlılık (Recall): Belli bir sınıfa ait verilerin, ne kadarının doğru sınıflandırıldığını gösterir.

Doğruluk, kesinlik ve duyarlılığın hesaplanabilmesi için gereken bütün değerler hata matrisi adı verilen ve modele verilen eğitim girdileri ile test verisetinin sınıflandırma sonuçları ile karşılaştıran, sınıflandırma probleminin başarısını gösteren belirteçte mevcuttur. Hata matrisinin elemanları:

- Gerçek Pozitif (True Positive): Pozitif olan orijinal verinin etiketi ile tahmin etiketinin aynı olması durumudur.
- Gerçek Negatif (True Negative): Negatif olan orijinal verinin etiketi ile tahmin etiketinin aynı olması durumudur.
- Yanlış Pozitif (False Positive): Negatif olan orijinal verinin, tahmin etiketinin pozitif olması durumudur.
- Yanlış Negatif (False Negative): Pozitif olan orijinal verinin, tahmin etiketinin negatif olması durumudur.

Yukarıdaki tanımlamalar iki adet sınıfa ait bir sınıflandırma probleminde kullanılmaya uygundur. Bu çalışmada üç adet sınıf bulunduğundan kullanılacak olan hata matrisi çalışmaya uygun olacak şekilde, 3x3'lük bir matrise evrilmiştir. Elde edilen matris Şekil 5.12'de gösterilmiştir.

		Hata Matrisi		
Gerçek Değerler	Gliom	A	B	C
	Meninjiyom	D	E	F
	Hipofiz	G	H	I
		Gliom	Meninjiyom	Hipofiz
		Tahmin Değerleri		

Şekil 5.12 Hata matrisi.

Doğruluk değeri, her sınıfta doğru sınıflandırılan görüntü sayısı toplanarak, toplam sınıflandırılan görüntü sayısına bölünerek bulunmuştur.

$$\text{Doğruluk: } \frac{(A + E + I)}{(A + B + C + D + E + F + G + H + I)}$$

Genel kesinlik değeri hesabı için, ilk olarak her bir sınıf için ayrı ayrı kesinlik değerleri hesaplanır. Sonrası bu değerlerin ortalaması alınarak modelin genel kesinlik değeri bulunur.

$$\text{Kesinlik Gliom (K}_G\text{): } \frac{A}{(A + D + G)}$$

$$\text{Kesinlik Meninjiyom (K}_M\text{): } \frac{E}{(B + E + H)}$$

$$\text{Kesinlik Hipofiz (K}_H\text{): } \frac{I}{(C + F + I)}$$

$$\text{Genel Kesinlik: } \frac{K_G + K_M + K_H}{3}$$

Genel duyarlılık değeri hesabı için, ilk olarak her bir sınıf için ayrı ayrı duyarlılık değerleri hesaplanır. Sonrası bu değerlerin ortalaması alınarak modelin genel duyarlılık değeri bulunur.

$$\text{Duyarlılık Gliom (D}_G\text{): } \frac{A}{(A+B+C)}$$

$$\text{Duyarlılık Meninjiyom (D}_M\text{): } \frac{E}{(D+E+F)}$$

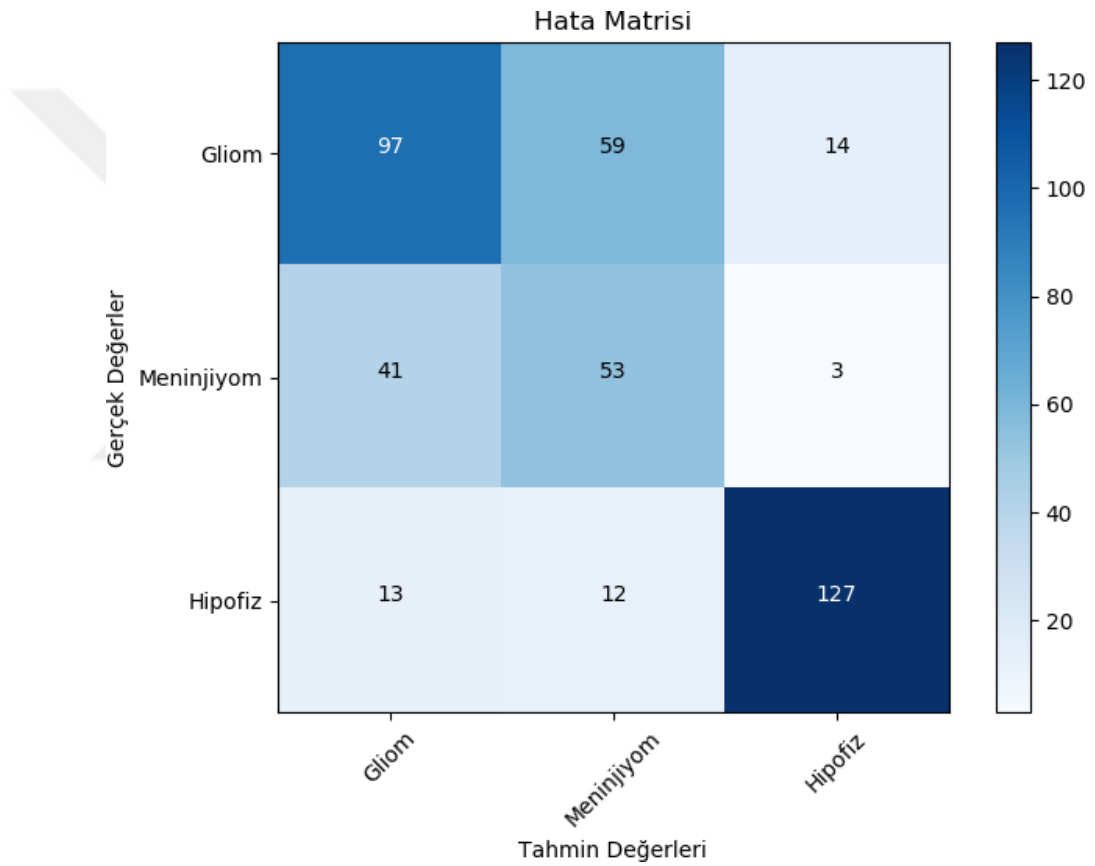
$$\text{Duyarlılık Hipofiz (D}_H\text{): } \frac{I}{(G+H+I)}$$

$$\text{Genel Duyarlılık: } \frac{D_G + D_M + D_H}{3}$$

6. BULGULAR

6.1 Modellerin İncelenmesi

Eđitilen model 1 ile test veri setinin sınıflandırılması sonucunda elde edilen hata matrisi Şekil 6.1’de verilmiştir.




Şekil 6.1 Model 1’in hata matrisi.

Değerlendirme kriterlerinin hata matrisi üzerinde uygulanması sonucu:


- Doğruluk: 0,66
- Kesinlik: 0,65
- Duyarlılık: 0,65

Hipofiz beyin tümörü sınıflandırması başarılı bir şekilde gerçekleştirilmiştir. Ancak gliom ve meninjiyom grubunun sınıflandırma başarısı düşüktür.

Şekil 6.2, modelin eğitim ve doğrulama veri setlerindeki başarımını, Şekil 6.3 ise eğitim ve doğrulama veri setlerindeki kaybını, artan epok sayısıyla göstermektedir.

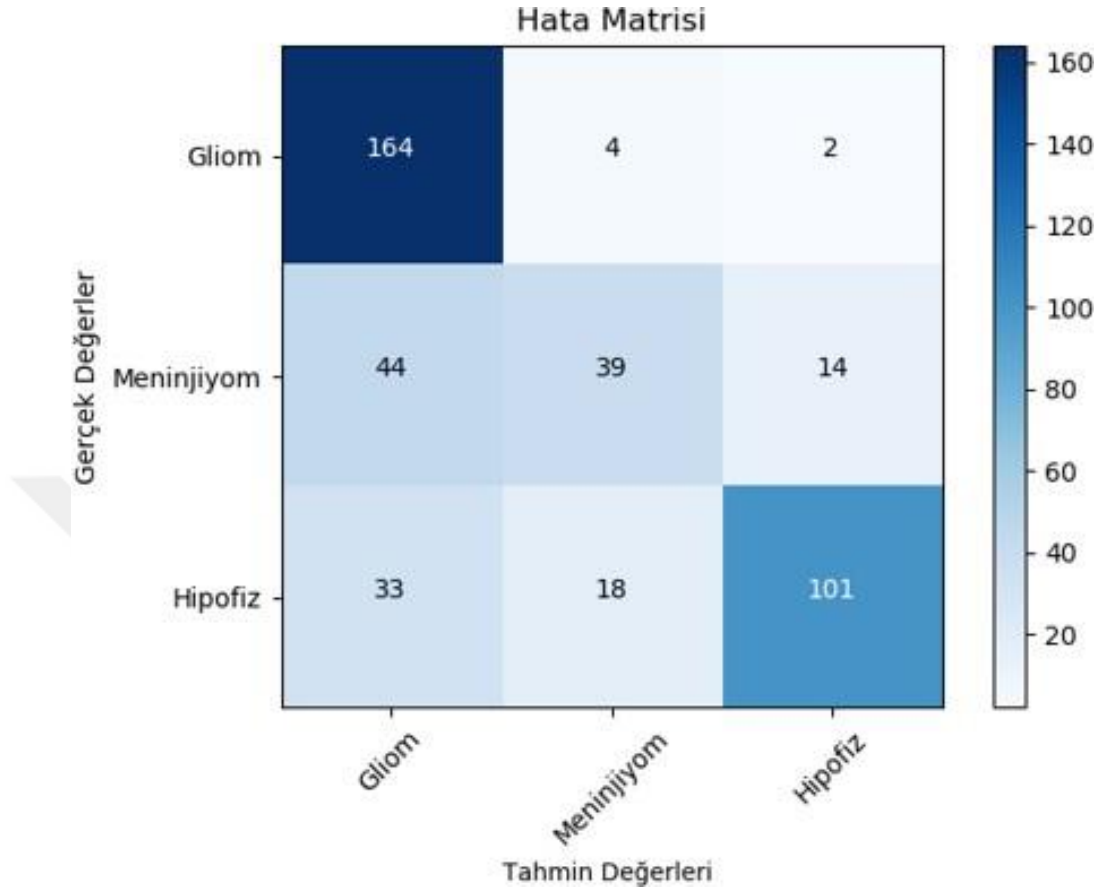


Şekil 6.2 Model 1'in eğitim ve doğrulama başarımı.



Şekil 6.3 Model 1'in eğitim ve doğrulama kaybı.

Eđitilen model 2 ile test veri setinin sınıflandırılması sonucunda elde edilen hata matrisi Őekil 6.4'te verilmiŐtir.




Őekil 6.4 Model 2'nin hata matrisi.

Deęerlendirme kriterlerinin hata matrisi üzerinde uygulanması sonucu:

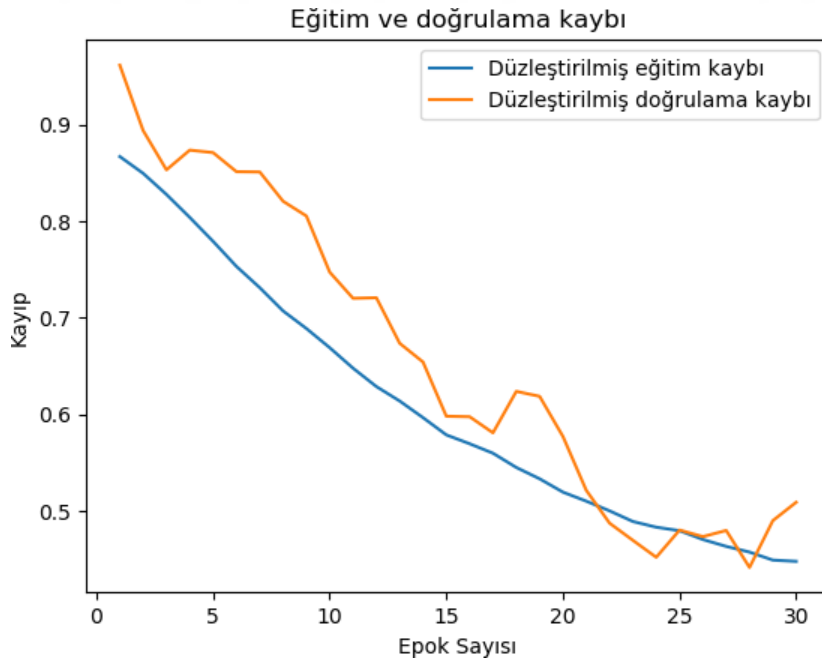
- Doğruluk: 0,73
- Kesinlik: 0,73
- Duyarlılık: 0,68

Hata matrisi incelendięinde, gliom ve hipofiz beyin tümörü test görüntülerinin yüksek bir doğruluk oranı ile sınıflandırıldıęı görölmüŐtür. Ancak meninjiyom beyin tümörü görüntülerinin büyük bir çoęunluęu yanlış bir Őekilde gliom beyin tümörü olarak sınıflandırılmıŐlardır. Bu durum modelin genel doğruluk oranını büyük oranda düşürmektedir.

Şekil 6.5, modelin eğitim ve doğrulama veri setlerindeki başarımını, Şekil 6.6 ise eğitim ve doğrulama veri setlerindeki kaybını, artan epok sayısıyla göstermektedir.




Şekil 6.5 Model 2'nin eğitim ve doğrulama başarımı.



Şekil 6.6 Model 2'nin eğitim ve doğrulama kaybı.

Eđitilen model 3 ile test veri setinin sınıflandırılması sonucunda elde edilen hata matrisi Şekil 6.7’de verilmiştir.




Şekil 6.7 Model 3’ün hata matrisi.

Deđerlendirme kriterlerinin hata matrisi üzerinde uygulanması sonucu:


- Doğruluk: 0,81
- Kesinlik: 0,81
- Duyarlılık: 0,76

Model 3’ün hata matrisi incelendiđinde, gliom ve hipofiz beyin tümörü test görüntülerinin Model 2’ye kıyasla daha yüksek bir doğruluk oranı ile sınıflandırıldıđı görülmüştür. Ancak meninjiyom beyin tümörü görüntülerinde bulunan yanlış sınıflandırma durumuna bu modelde de çözüm bulunamamıştır. Bu durum modelin genel doğruluk oranını düşürmektedir.

Şekil 6.8, modelin eğitim ve doğrulama veri setlerindeki başarımını, Şekil 6.9 ise eğitim ve doğrulama veri setlerindeki kaybını, artan epok sayısıyla göstermektedir.




Şekil 6.8 Model 3'ün eğitim ve doğrulama başarımı.



Şekil 6.9 Model 3'ün eğitim ve doğrulama kaybı.

Eđitilen model 4 ile test veri setinin sınıflandırılması sonucunda elde edilen hata matrisi Şekil 6.10'da verilmiştir.



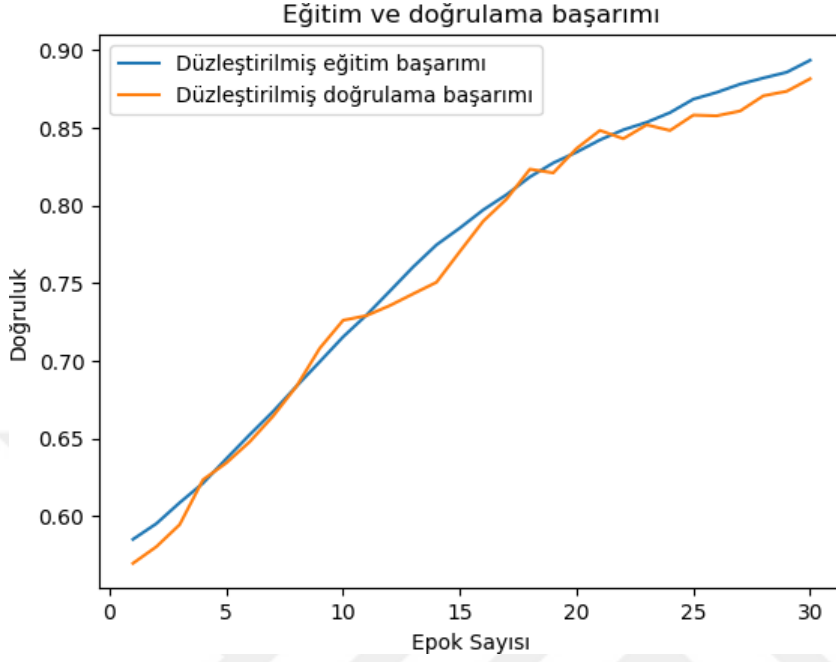
Şekil 6.10 Model 4'ün hata matrisi.

Değerlendirme kriterlerinin hata matrisi üzerinde uygulanması sonucu:


- Doğruluk: 0,91
- Kesinlik: 0,91
- Duyarlılık: 0,90

Model 4'ün hata matrisi incelendiğinde gliom, meninjiyom ve hipofiz beyin tümörü test görüntülerinin daha önceki modellere kıyasla daha yüksek bir doğruluk oranı ile sınıflandırıldığı görülmüştür. Meninjiyom beyin tümörü görüntülerinde bulunan yanlış sınıflandırma durumuna bu modelde çözüm bulunmuştur. Böylece 3 beyin tümör çeşidi de yüksek doğruluk oranları ile sınıflandırılmaktadır.

Şekil 6.11, modelin eğitim ve doğrulama veri setlerindeki başarımını, Şekil 6.12 ise eğitim ve doğrulama veri setlerindeki kaybını, artan epok sayısıyla göstermektedir.




Şekil 6.11 Model 4'ün eğitim ve doğrulama başarımı.



Şekil 6.12 Model 4'ün eğitim ve doğrulama kaybı.

Eđitilen model 5 ile test veri setinin sınıflandırılması sonucunda elde edilen hata matrisi Şekil 6.13'te verilmiştir.




Şekil 6.13 Model 5'in hata matrisi.

Değerlendirme kriterlerinin hata matrisi üzerinde uygulanması sonucu:


- Doğruluk: 0,90
- Kesinlik: 0,89
- Duyarlılık: 0,90

Model 5'in hata matrisi incelendiğinde gliom, meninjiyom ve hipofiz beyin tümörü test görüntülerinin Model 4'e yakın bir doğruluk oranı ile sınıflandırıldığı görülmüştür. Meninjiyom beyin tümörü görüntülerinde bulunan yanlış sınıflandırma durumuna bu modelde de çözüm bulunmuştur. Böylece 3 beyin tümör çeşidi de yüksek doğruluk oranları ile sınıflandırılmaktadır.

Şekil 6.14, modelin eğitim ve doğrulama veri setlerindeki başarımını, Şekil 6.15 ise eğitim ve doğrulama veri setlerindeki kaybını, artan epok sayısıyla göstermektedir.

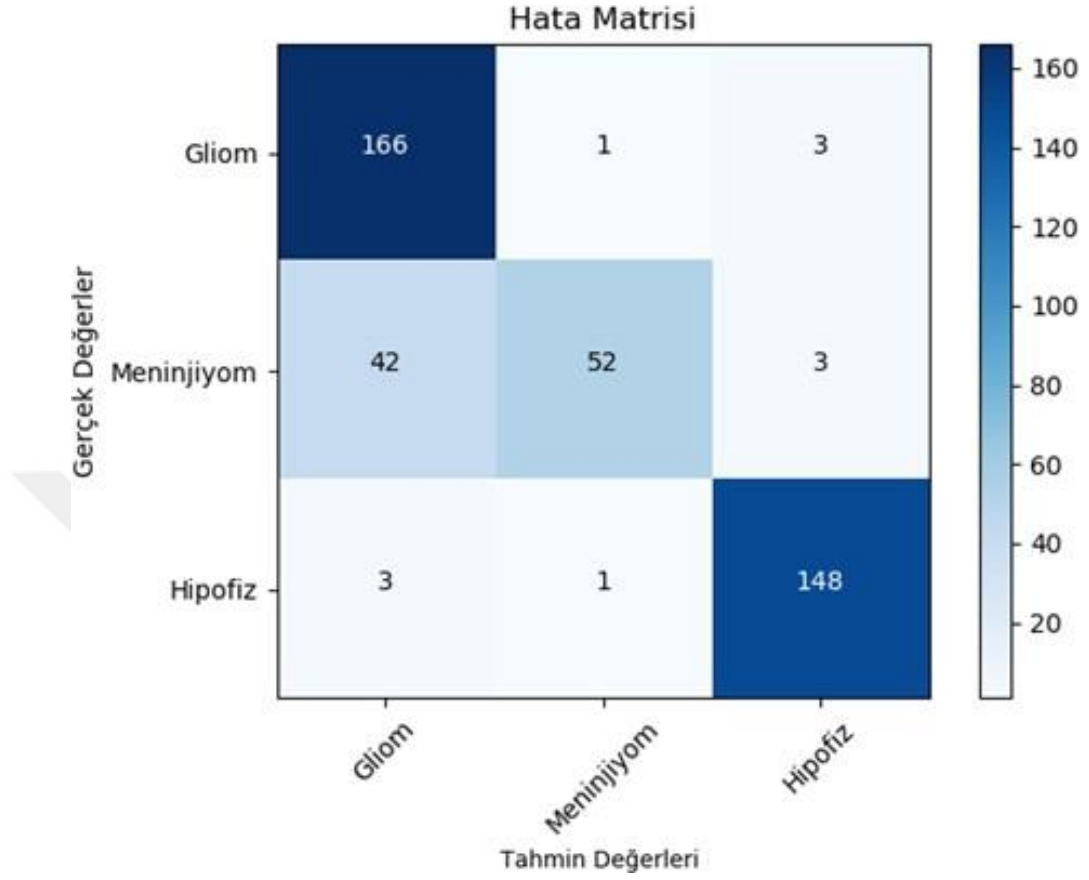


Şekil 6.14 Model 5'in eğitim ve doğrulama başarımı.



Şekil 6.15 Model 5'in eğitim ve doğrulama kaybı.

Eđitilen model 6 ile test veri setinin sınıflandırılması sonucunda elde edilen hata matrisi Şekil 6.16’da verilmiştir.




Şekil 6.16 Model 6’nın hata matrisi.

Değerlendirme kriterlerinin hata matrisi üzerinde uygulanması sonucu:


- Doğruluk: 0,87
- Kesinlik: 0,90
- Duyarlılık: 0,83

Model 6’nın hata matrisi incelendiğinde gliom ve hipofiz beyin tümörü test görüntülerinin daha önceki bütün modellere kıyasla daha yüksek bir doğruluk oranı ile sınıflandırıldığı görülmüştür. Ancak Meninjiyom beyin tümörü görüntüleri düzgün bir şekilde sınıflandırılmamıştır. Bu nedenle genel doğruluk oranı Model 4 ve Model 5’in gerisinde kalmıştır.

Şekil 6.17, modelin eğitim ve doğrulama veri setlerindeki başarımını, Şekil 6.18 ise eğitim ve doğrulama veri setlerindeki kaybını, artan epok sayısıyla göstermektedir.




Şekil 6.17 Model 6'nın eğitim ve doğrulama başarımı.



Şekil 6.18 Model 6'nın eğitim ve doğrulama kaybı.

Eđitilen model 7 ile test veri setinin sınıflandırılması sonucunda elde edilen hata matrisi Şekil 6.19’da verilmiştir.




Şekil 6.19 Model 7’nin hata matrisi.

Değerlendirme kriterlerinin hata matrisi üzerinde uygulanması sonucu:


- Doğruluk: 0,88
- Kesinlik: 0,90
- Duyarlılık: 0,85

Ön eğitimli bir şekilde eğitimli Model 7’nin hata matrisi incelendiğinde gliom ve hipofiz beyin tümörü test görüntülerinin yüksek bir doğruluk oranı ile sınıflandırıldığı görülmüştür. Ancak Meninjiyom beyin tümörü görüntülerinin doğru sınıflandırılma düzeyi Model 4 ve Model 5’in seviyesine ulaşamamıştır. Bu nedenle genel doğruluk oranı bu modellerin gerisinde kalmıştır.

Şekil 6.20, modelin eğitim ve doğrulama veri setlerindeki başarımını, Şekil 6.21 ise eğitim ve doğrulama veri setlerindeki kaybını, artan epok sayısıyla göstermektedir.



Şekil 6.20 Model 7'nin eğitim ve doğrulama başarımı.



Şekil 6.21 Model 7'nin eğitim ve doğrulama kaybı.

6.2 Genel İnceleme

Modellerin doğruluk, kesinlik ve duyarlılık değerlerini gösteren Çizelge 6.1'e bakıldığında; doğruluk değeri en yüksek olan Model 4'tür. Model 5 ile arasında 0,01 değerinde bir fark mevcuttur. Aynı şekilde kesinlik değeri en yüksek olan model yine model 4'tür. Ardından gelen model 6 ve model 7 0,01'lik farklarla, model 5 ise 0,02'lik farkla gerisinde kalmışlardır. Duyarlılık değeri incelendiğinde model 4 ve model 5'in eşit değerlere sahip olduğu görülmektedir.

Çizelge 6.1 Modellerin doğruluk, kesinlik ve duyarlılık değerleri

Modeller	Doğruluk	Kesinlik	Duyarlılık
Model 1	0,66	0,65	0,65
Model 2	0,73	0,73	0,68
Model 3	0,81	0,81	0,76
Model 4	0,91	0,91	0,90
Model 5	0,90	0,89	0,90
Model 6	0,87	0,90	0,83
Model 7	0,88	0,90	0,85

Modeller değerlendirme kriterleri ile incelendikten sonra, sınıflandırma için en ideal modelin belirlenmesindeki bir diğer kriter olan modellerin eğitimi için harcanan süre incelenmiştir. Sonuçlara bakıldığında model 5'in eğitiminin 24 dakika 18 saniyede tamamlanarak en kısa süreye sahip olduğu görülmektedir. Arkasından 25 dakika 32 saniyede eğitimi tamamlanan model 6 gelmektedir.

Modellerin genel performanslarının incelenmesinde Çizelge 6.1 ve Çizelge 6.2 kullanılmıştır. Değerlendirme kriterlerine bağlı olarak yapılan incelemelerde en etkili sonucu veren iki model, model 4 ve model 5'tir. Eğitim süresinde harcanan zaman açısından yapılan değerlendirmede ise modellerin aralarında az fark bulunmakla

birlikte, en ideal sonucu veren model 5'tir. Ardından model 6 gelmektedir. Bu iki kriter de değerlendirilip bir sonuca varılması ile tercih edilecek en ideal modelin model 5 olduğu sonucuna varılabilmektedir.

Çizelge 6.2 Modellerin eğitimleri için harcanan süre.

Modeller	Eğitim için Harcanan Süre
Model 1	38 dakika, 14 saniye
Model 2	30 dakika, 52 saniye
Model 3	28 dakika, 24 saniye
Model 4	26 dakika, 30 saniye
Model 5	24 dakika, 18 saniye
Model 6	25 dakika, 32 saniye
Model 7	85 dakika, 8 saniye

Çalışma süresince farklı epok sayılarına sahip eğitimler yapılmıştır. Epok sayısı azaltıldığında harcanan zaman üzerinde olumlu bir etkisi olmaktadır, ancak modellerin test veri seti kullanılarak hesaplanan doğruluk, kesinlik ve duyarlılık değerlerinde düşüşler meydana gelmektedir. Benzer şekilde, epok sayısı artırıldığında, modellerin eğitimi için harcanan zaman artmakla birlikte bazı değerlerde iyileşmeler gerçekleşmiştir. Çalışmanın amacında da belirtildiği üzere, hem doğruluk oranını yüksek tutup hem de eğitim için harcanan sürenin fazla olmaması için epok değerinin 30 alınması, modellerden en ideal sonucun alınmasını sağlamıştır.

Modeller arasındaki farklar incelendiğinde, model 1’den başlayarak model 4’e kadar her bir modelde konvolüsyon ve ortaklama katman sayıları birer adet artırılmıştır. Bu durumun elde edilen sınıflandırma sonucuna olumlu etkisi olduğu gözlemlenmiştir. Ayrıca eğitim için harcanan zamanın da azaldığı görülmüştür. Model 5 ve model 6, model 4’e birer adet farklı filtre sayılarına sahip konvolüsyon katmanları eklenerek oluşturduğundan birbirlerine yakın sonuçlara ulaşmışlardır.

Eğitim için harcanan zamanın incelenmesinde, modellerin eğitiminde kullanılan yazılımın da önemli yeri vardır. Bu çalışmada modeller Python yazılımı kullanılarak eğitilmiştir. Farklı yazılımlar kullanılarak, farklı eğitim süreleri elde edilebilir.

Gliom, meninjiyom ve hipofiz beyin tümörü görüntülerinin sınıflandırılmasında, gliom ve hipofiz tümörleri, meninjiyom tümörlerine kıyasla daha doğru sınıflandırılmıştır. Meninjiyom beyin tümörü görüntü sayısının diğer sınıflara göre daha az miktarda olması bu duruma neden olabilmektedir.



7. SONUÇLAR VE TARTIŞMA

Bu tez çalışmasında en yaygın görülen üç beyin tümörü çeşidi olan; Gliom, Meningiom ve Hipofiz bezi tümörlerinin sınıflandırılmasında hekimlere yardımcı olabilecek ve zamanı verimli kullanan bir mekanizma üzerinde çalışılmıştır. MRI cihazı kullanılarak elde edilen beyin kesit görüntülerinin incelenmesi, hangi tür beyin tümörüne karşılık geldiğinin anlaşılması ve bu sayede hastanın durumunun doğru ve en kısa sürede teşhisi ile tedaviye en kısa zamanda başlanabilmesi amaçlanmıştır. Elde edilen sınıflandırma mekanizmasının, yüksek doğruluk oranına ve optimal çıktı süresine sahip olması ön planda tutulmuştur.

Bu amaçlar doğrultusunda çeşitli CNN modelleri oluşturulmuş olup modeller, değerlendirme kriterleri olan doğruluk, kesinlik ve duyarlılık değerlerine bakılarak karşılaştırılmıştır. Ayrıca eğitimleri için harcanan süreler de gözlemlenmiştir. Yapılan incelemeler sonucunda oluşturulan en ideal modelin doğruluk oranının 0,90 olduğu, eğitim için harcanan zamanın ise 24 dakika ve 18 saniye olduğu belirlenmiştir. Çalışmanın amacında da belirtildiği üzere, hekimlere yardımcı ve zamanı verimli kullanan bir mekanizma başarıyla geliştirilmiştir.

Başka çalışmalar incelendiğinde elde edilen doğruluk oranının bazı çalışmalardan daha düşük olduğu görülmüştür. Bunun nedeni, bu çalışmada eğitim için harcanan zaman yani karar mekanizmasının hızı ön planda tutulmuştur. Aynı zamanda doğruluk oranı da olabileceği en yüksek düzeyde elde edilmeye çalışılmıştır.

Yapılan çalışmanın geliştirilmeye açık olmasından ötürü, gelecekte daha verimli sonuçlar elde edilebilir. Bunun için, çalışmada kullanılan veri seti genişletilerek derin öğrenme modellerinin daha etkili çalışması sağlanabilir. Veri seti büyütüldükten sonra kesit görüntüleri de kendi içlerinde sagittal, coronal ve transverse olacak şekilde gruplandırılarak ve modeller bu şekilde eğitilerek, sınıflandırma sonucuna etkisi gözlemlenebilir. Ayrıca, tümörsüz görüntü adında yeni bir sınıf eklenerek ve bu çalışmanın öncesine tümörlü - tümörsüz görüntü sınıflandırıcı eklenerek çalışmanın boyutu genişletilebilir.



KAYNAKLAR

- [1] **WHO.** (2019). Statistics on Brain Cancer. <http://www.who.int/cancer/en/>, alındığı tarih: 30.07.2020.
- [2] **Brain tumor - Symptoms and causes.** (2019). Mayo Clinic. <https://www.mayoclinic.org/diseases-conditions/brain-tumor/symptoms-causes/syc-20350084>, alındığı tarih: 20.07.2020.
- [3] **Brain Tumor - Introduction.** (2020). Cancer. <https://www.cancer.net/cancer-types/brain-tumor/introduction>, alındığı tarih: 03.08.2020.
- [4] **Vézina, L. G.** (2008). Imaging of central nervous system tumors in children: advances and limitations. *Journal of child neurology*, 23(10), 1128-1135.
- [5] **Loh, E.** (2018). Medicine and the rise of the robots: a qualitative review of recent advances of artificial intelligence in health. *BMJ Leader*, leader-2018.
- [6] **Cheng, J., Huang, W., Cao, S., Yang, R., Yang, W., Yun, Z., ... & Feng, Q.** (2015). Enhanced performance of brain tumor classification via tumor region augmentation and partition. *PloS one*, 10(10), e0140381.
- [7] **Pereira, S., Pinto, A., Alves, V., & Silva, C. A.** (2016). Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE transactions on medical imaging*, 35(5), 1240-1251.
- [8] **Mohsen, H., El-Dahshan, E. S. A., El-Horbaty, E. S. M., & Salem, A. B. M.** (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1), 68-71.
- [9] **Afshar, P., Mohammadi, A., & Plataniotis, K. N.** (2018). Brain tumor type classification via capsule networks. In *2018 25th IEEE International Conference on Image Processing (ICIP)* (pp. 3129-3133). IEEE.
- [10] **Das, S., Aranya, O. R. R., & Labiba, N. N.** (2019). Brain tumor classification using convolutional neural network. In *2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT)* (pp. 1-5). IEEE.
- [11] **Alqudah, A. M., Alquraan, H., Qasmieh, I. A., Alqudah, A., & Al-Sharu, W.** (2020). Brain Tumor Classification Using Deep Learning Technique—A Comparison between Cropped, Uncropped, and Segmented Lesion Images with Different Sizes. *arXiv preprint arXiv:2001.08844*.
- [12] **Rehman, A., Naz, S., Razzak, M. I., Akram, F., & Imran, M.** (2020). A deep learning-based framework for automatic brain tumors classification using transfer learning. *Circuits, Systems, and Signal Processing*, 39(2), 757-775.

- [13] **Sajjad, M., Khan, S., Muhammad, K., Wu, W., Ullah, A., & Baik, S. W.** (2019). Multi-grade brain tumor classification using deep CNN with extensive data augmentation. *Journal of computational science*, 30, 174-182.
- [14] **Srinivas, B., & Rao, G. S.** (2019). A Hybrid CNN-KNN model for MRI brain tumor classification. *Int J Recent Technol Eng (IJRTE)*, 8(2).
- [15] **American Brain Tumor Association.** (n.d.). *Brain Tumor Education*. <https://www.abta.org/about-braintumors/brain-tumor-education/>, alındığı tarih: 17.09.2020.
- [16] **Brain Tumor - Statistics.** (2020). Cancer. <https://www.cancer.net/cancertypes/brain-tumor/statistics>, alındığı tarih: 23.09.2020.
- [17] **Bondy, M. L., Scheurer, M. E., Malmer, B., Barnholtz-Sloan, J. S., Davis, F. G., Il'Yasova, D., ... & Sadetzki, S.** (2008). Brain tumor epidemiology: consensus from the Brain Tumor Epidemiology Consortium. *Cancer*, 113(S7), 1953-1968.
- [18] **DeAngelis, L. M.** (2001). Brain tumors. *New England journal of medicine*, 344(2), 114-123.
- [19] **Cancer Treatment Centers of America.** (n.d.). Types of Brain Cancer. <https://www.cancercenter.com/cancer-types/brain-cancer/types>, alındığı tarih: 29.09.2020.
- [20] **American Cancer Society.** (2020). *Cancer Facts & Figures*.
- [21] **Snyder, H., Robinson, K., Shah, D., Brennan, R., & Handrigan, M.** (1993). Signs and symptoms of patients with brain tumors presenting to the emergency department. *The Journal of emergency medicine*, 11(3), 253-258.
- [22] **Khoo, V. S., Dearnaley, D. P., Finnigan, D. J., Padhani, A., Tanner, S. F., & Leach, M. O.** (1997). Magnetic resonance imaging (MRI): considerations and applications in radiotherapy treatment planning. *Radiotherapy and Oncology*, 42(1), 1-15.
- [23] **Eroğul, O., & Karagöz, İ.** (1998). *Tıbbi Görüntüleme Sistemleri*. Haberal Eğitim Vakfı Yayınları.
- [24] **Nishimura, D. G.** (2010). *Principles of Magnetic Resonance Imaging*. Stanford University.
- [25] **Prince, J. L., & Links, J. M.** (2014). *Medical Imaging Signals and Systems* (2nd ed.). Pearson.
- [26] **Chollet, F.** (2019). *Python ile Derin Öğrenme*. Buzdağı Yayınevi.
- [27] **Gibney, E.** (2016). Google AI algorithm masters ancient game of Go. *Nature News*, 529(7587), 445.
- [28] **Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y.** (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press.
- [29] **LeCun, Y.** (1989). Generalization and network design strategies. *Connectionism in perspective*, 19, 1-20.

- [30] Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27-48.
- [31] Xia, Y., Wulan, N., Wang, K., & Zhang, H. (2018). Detecting atrial fibrillation by deep convolutional neural networks. *Computers in biology and medicine*, 93, 84-92.
- [32] Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354-377.
- [33] Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adeli, H. (2018). Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in biology and medicine*, 100, 270-278.
- [34] Cheng, J., Yang, W., Huang, M., Huang, W., Jiang, J., Zhou, Y., ... & Chen, W. (2016). Retrieval of brain tumors by adaptive spatial pooling and fisher vector representation. *PloS one*, 11(6), e0157112.
- [35] Wu, H., & Gu, X. (2015). Towards dropout training for convolutional neural networks. *Neural Networks*, 71, 1-10.
- [36] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Berg, A. C. (2015). Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115(3), 211-252.
- Url-1 https://figshare.com/articles/dataset/brain_tumor_dataset/1512427, alındığı tarih: 19.06.2020.
- Url-2 <https://www.indiamart.com/proddetail/1-5t-refurbished-ge-mri-machine-22759525933.html>, alındığı tarih: 12.09.2020.
- Url-3 <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad>, alındığı tarih: 17.09.2020
- Url-4 <https://www.semanticscholar.org/paper/Applications-of-Convolution-in-Image-ProcessingCasper/391f4dc0567f671b0718f80834fdc1e83a9fd54b>, alındığı tarih: 17.09.2020
- Url-5 <https://www.yapayakademi.com/derin-ogrenme-1-ileri-yayilim-algoritmasi>, alındığı tarih: 30.09.2020
- Url-6 <https://towardsdatascience.com/gradient-descent-algorithm-and-its-variants-10f652806a3>, alındığı tarih: 10.10.2020
- Url-7 <https://datasciencehub.medium.com/story-behind-the-convolutional-neural-networks-cnn-with-pytorch-part-i-977acdce01bf>, alındığı tarih: 12.10.2020



