

T.C.  
İSTANBUL GEDİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



EVRIŞİMLİ SİNİR AĞLARI (ESA) İLE BEYİN TÜMÖRÜ  
TESPİTİ

YÜKSEK LİSANS TEZİ

Ali GÜLSOY

Yapay Zekâ Mühendisliği Anabilim Dalı

Yapay Zekâ Mühendisliği Tezli Yüksek Lisans Programı

EYLÜL 2023  
İSTANBUL

T.C.  
İSTANBUL GEDİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**EVRIŞİMLİ SİNİR AĞLARI (ESA) İLE BEYİN TÜMÖRÜ  
TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**Ali GÜLSOY  
(200039001)**

**0009-0005-2025-6198**

**Yapay Zekâ Mühendisliği Anabilim Dalı**

**Yapay Zekâ Mühendisliği Tezli Yüksek Lisans Programı**

**Tez Danışmanı: Dr. Öğr. Üyesi Şerife Esra DİNÇER**

**İstanbul 2023**



**T.C.**  
**İSTANBUL GEDİK ÜNİVERSİTESİ**  
**Lisansüstü Eğitim Enstitüsü Müdürlüğü**

**Jüri Tez Onay Formu**

07.09.2023

**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ**

Bu çalışma 07.09 2023 tarihinde aşağıdaki jüri tarafından Yapay Zeka Mühendisliği Anabilim Dalı, Yapay Zeka Mühendisliği (Tezli Yüksek Lisans) Programı Yüksek Lisans Tezi olarak kabul edilmiştir.

**TEZ JÜRİSİ**

**Dr. Öğr. Üyesi Şerife Esra DİNÇER**

Danışman

İstanbul Gedik Üniversitesi

**Dr. Öğr. Üyesi Feridun Cemal**

**ÖZÇAKIR**

Üye (İmza)

İstanbul Gedik Üniversitesi

**Dr. Öğr. Üyesi Ümit ÖZTÜRK**

Üye (İmza)

İstanbul Beykent Üniversitesi

## YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum ‘Evrişimli Sinir Ağları (ESA) ile Beyin Tümörü Tespiti’ adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (07/09/2023)

Ali GÜLSOY

## ÖNSÖZ

Çalışmamın süreç aşamasında desteğini esirgemeyen tez danışmanım Dr. Öğretim Üyesi Şerife Esra DİNÇER'e,

Çalışmamın yazılım aşamasında her daim yanımda olan yardımcı tez danışmanım değerli hocam Dr. Çiğdem GÜNDOĞAN TÜRKER'e,

Çalışmamın yazılım aşamasında öneri ve eleştirileriyle beni yönlendiren hocam Sebahattin BABUR'e,

Çalışmamın bütüncül bir biçimde ortaya çıkmasına katkı sunan Hüsnü KÜÇÜKKÖYLÜ'e,

Eğitim hayatımın her anında yanımda olan aileme teşekkürlerimi ve sonsuz şükranlarımı sunarım.

Eylül 2023

Ali GÜLSOY

---

## İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖNSÖZ</b> .....	<b>iv</b>
<b>İÇİNDEKİLER</b> .....	<b>v</b>
<b>KISALTMALAR</b> .....	<b>viii</b>
<b>ÇİZELGE LİSTESİ</b> .....	<b>ix</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>x</b>
<b>ÖZET</b> .....	<b>xiii</b>
<b>ABSTRACT</b> .....	<b>xiv</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 Tezin Amacı .....	1
1.2 Literatür Araştırması .....	1
<b>2. BEYİN TÜMÖRLERİ</b> .....	<b>4</b>
2.1 Veri Setindeki Tümör Çeşitleri .....	4
2.1.1 Glioma .....	4
2.1.2 Meningioma.....	5
2.1.3 Pituitary .....	5
2.2 Beyin Tümörlerinin Tespiti .....	6
<b>3. MAKİNE ÖĞRENMESİ</b> .....	<b>10</b>
3.1 Yapay Zekâ, Makine Öğrenmesi, Derin Öğrenme Arasındaki İlişki .....	10
3.2 Makine Öğrenmesi .....	11
3.2.1 Denetimli öğrenme .....	11
3.2.2 Denetimsiz öğrenme .....	11
3.2.3 Pekiştirmeli öğrenme .....	12
3.3 Makine Öğrenmesi Algoritmaları .....	13
3.3.1 Karar ağaçları .....	13
3.3.2 Random forest .....	13
3.3.3 Lojistik regresyon .....	13
3.3.4 Naive bayes .....	13
3.3.5 K en yakın komşu algoritması .....	14
3.3.6 Destek vektör makineleri .....	14
<b>4. DERİN ÖĞRENME</b> .....	<b>15</b>
4.1 Yapay sinir ağları (YSA).....	15
4.1.1 Yapay sinir hücresi .....	15
4.1.2 Tek katmanlı algılayıcı .....	17
4.1.3 Çok katmanlı algılayıcı.....	18
4.1.4 İleri beslemeli yapay sinir ağları .....	19
4.1.5 İleri doğru hesaplama .....	19
4.1.6 Geri beslemeli yapay sinir ağları .....	20
4.1.7 Geri doğru hesaplama.....	21
4.2 Aktivasyon Fonksiyonları .....	23
4.2.1 Adım aktivasyon fonksiyonu .....	23
4.2.2 Doğrusal aktivasyon fonksiyonu .....	24

4.2.3 Sigmoid aktivasyon fonksiyonu .....	24
4.2.4 Hiperbolik tanjant aktivasyon fonksiyonu.....	25
4.2.5 Relu aktivasyon fonksiyonu .....	25
4.2.6 Leaky relu aktivasyon fonksiyonu.....	26
4.2.7 Soft plus aktivasyon fonksiyonu .....	26
4.2.8 Prelu aktivasyon fonksiyonu .....	27
4.2.9 Elu aktivasyon fonksiyonu .....	27
4.2.10 Swish aktivasyon fonksiyonu .....	28
4.2.11 Softmax aktivasyon fonksiyonu .....	29
4.3 Kayıp Fonksiyonları .....	30
4.3.1 Ortalama karesel hata .....	30
4.3.2 Mutlak hatalar ortalaması .....	30
4.3.3 Log-Cosh kayıp fonksiyonu .....	30
4.3.4 Log Loss kayıp fonksiyonu .....	30
4.3.5 Dengeli çapraz entropi.....	31
4.3.6 İkili çapraz entropi.....	31
4.3.6 Kategorik çapraz entropi .....	31
4.3.7 Seyrek kategorik çapraz entropi .....	31
4.4 Optimizasyon Fonksiyonları .....	32
4.4.1 Gradyan iniş.....	32
4.4.2 Yığın gradyan iniş .....	32
4.4.3 Stokastik gradyan iniş.....	32
4.4.4 Mini yığın gradyan iniş.....	33
4.4.5 Momentumlu gradyan iniş.....	33
4.4.6 Adagrad .....	33
4.4.7 AdaDelta.....	34
4.4.8 RMSprop .....	34
4.4.9 ADAM.....	34
4.5. Hiperparametreler.....	35
4.5.1 Öğrenme katsayısı .....	35
4.5.2 Mini yığın boyutu .....	35
4.5.3 Çevrim sayısı .....	36
4.5.4 Gizli katman sayısı .....	36
4.5.5 Gizli katmandaki nöron sayısı .....	36
4.5.6 Ağırlıklara başlangıç değerleri atama.....	37
4.6 Derin Öğrenme Mimarileri.....	37
4.6.1 Tekrarlayan sinir ağları (TSA) .....	37
4.6.2 Uzun -kısa süreli hafıza .....	37
4.6.3 Kısıtlı boltzman makinesi.....	37
4.6.4 Derin inanç ağı.....	38
4.6.5 Derin oto kodlayıcılar.....	38
4.6.6 Evrişimli sini ağları (ESA) .....	38
4.6.6.1 Evrişim katmanı.....	38
4.6.6.2 Havuzlama katmanı .....	39
4.6.6.3 Tam bağlı katman .....	40
4.6.6.4 Regülasyon.....	40
4.6.6.4.1 Seyreltme .....	40
4.6.6.5 Evrişimli sinir ağı (ESA) mimarileri .....	41
4.6.6.5.1 LeNet-5 .....	41
4.6.6.5.2 AlexNet.....	41

4.6.6.5.3 ZFNet .....	42
4.6.6.5.4 GoogleNet .....	42
4.6.6.5.5 ResNet.....	43
4.6.6.5.6 VGG16.....	44
4.6.6.5.7 VGG19.....	45
4.7 Öğrenme Aktarımı.....	45
4.8 Performans Değerlendirme Kriterleri.....	46
4.8.1 Hata matrisi .....	46
4.8.2 Doğruluk (Accuracy).....	46
4.8.3 Kesinlik (Precision) .....	47
4.8.4 Duyarlılık (Recall).....	47
4.8.5 F1 Score.....	47
<b>5. UYGULAMA.....</b>	<b>48</b>
5.1 Veri Seti Ön İşlemler.....	48
5.2 Görüntülerin Ön İşlenmesi .....	50
5.3 Çalışılan Modellerin Ana Özellikleri .....	51
5.4 Çalışılan Modeller .....	53
5.4.1 Model 1 .....	53
5.4.2 Model 2.....	60
<b>6. SONUÇLAR VE ÖNERİLER .....</b>	<b>81</b>
<b>KAYNAKLAR .....</b>	<b>85</b>
<b>ÖZGEÇMİŞ.....</b>	<b>95</b>

## KISALTMALAR

<b>BT</b>	: Bilgisayarlı Tomografi
<b>ESA</b>	: Evriřimli Sinir Ađları
<b>MR</b>	: Manyetik Rezonans
<b>MRG</b>	: Manyetik Rezonans Görüntüleme
<b>PET</b>	: Pozitron Emisyon Tomografi
<b>TSA</b>	: Tekrarlayan Sinir Ađları
<b>YSA</b>	: Yapay Sinir Ađları



## ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 4.1: Toplam Fonksiyonu Türleri.....	16
Çizelge 4.2: Aktivasyon Fonksiyonu Türleri.....	17
Çizelge 4.3: Hata Matrisi.....	46
Çizelge 5.1: Veri Setindeki Verilere Ait Bilgiler .....	49
Çizelge 5.2: 4X4 Hata Matrisi .....	52
Çizelge 5.3: Model 1-a Karışıklık Matrisi.....	54
Çizelge 5.4: Model 1-b Karışıklık Matrisi.....	55
Çizelge 5.5: Model 1-b-1 Karışıklık Matrisi .....	56
Çizelge 5.6: Model 1-b-2 Karışıklık Matrisi .....	58
Çizelge 5.7: Model 1-c Karışıklık Matrisi.....	59
Çizelge 5.8: Model 2-a Karışıklık Matrisi.....	61
Çizelge 5.9: Model 2-b Karışıklık Matrisi.....	62
Çizelge 5.10: Model 2-b-1 Karışıklık Matrisi .....	63
Çizelge 5.11: Model 2-b-2 Karışıklık Matrisi .....	65
Çizelge 5.12: Model 2-c Karışıklık Matrisi.....	66
Çizelge 5.13: Model 2-c-1 Karışıklık Matrisi.....	67
Çizelge 5.14: Model 2-c-2 Karışıklık Matrisi.....	69
Çizelge 5.15: Model 3-a Karışıklık Matrisi.....	70
Çizelge 5.16: Model 3-a-1 Karışıklık Matrisi.....	72
Çizelge 5.17: Model 3-a-2 Karışıklık Matrisi.....	73
Çizelge 5.18: Model 3-b Karışıklık Matrisi.....	75
Çizelge 5.19: Model 3-b-1 Karışıklık Matrisi .....	76
Çizelge 5.20: Model 3-b-2 Karışıklık Matrisi .....	78
Çizelge 5.21: Model 3-c Karışıklık Matrisi.....	79

## ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1: Glioma Tümör .....	4
Şekil 2.2: Meningioma Tümör.....	5
Şekil 2.3: Pituitary Tümör .....	5
Şekil 2.4: X-Ray Görüntüsü .....	6
Şekil 2.5: BT Görüntüsü .....	7
Şekil 2.6: MR Görüntüsü.....	7
Şekil 2.7: PET Görüntüsü.....	8
Şekil 2.8: Açık MRG Cihazı.....	9
Şekil 2.9: Kapalı MR Cihazı.....	9
Şekil 3.1: Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Arasındaki İlişki ....	10
Şekil 3.2: Denetimli Öğrenme .....	11
Şekil 3.3: Denetimsiz Öğrenme.....	12
Şekil 3.4: Pekiştirmeli Öğrenme.....	12
Şekil 4.1: Bir sinir hücresinin yapısı.....	15
Şekil 4.2: Sigmoid Fonksiyonu .....	17
Şekil 4.3: Tek Katmanlı Algılayıcı.....	18
Şekil 4.4: Çok Katmanlı Algılayıcı .....	18
Şekil 4.5: İleri Beslemeli Yapay Sinir Ağı.....	19
Şekil 4.6: Geri Beslemeli Yapay Sinir Ağları .....	20
Şekil 4.7: Adım Aktivasyon Fonksiyonu.....	23
Şekil 4.8: Doğrusal Aktivasyon Fonksiyonu .....	24
Şekil 4.9: Sigmoid Aktivasyon Fonksiyonu .....	24
Şekil 4.10: Hiperbolik Tanjant Aktivasyon Fonksiyonu .....	25
Şekil 4.11: Relu Aktivasyon Fonksiyonu .....	26
Şekil 4.12: Leakly Relu Aktivasyon fonksiyonu.....	26
Şekil 4.13: Softplus Aktivasyon Fonksiyonu .....	27
Şekil 4.14: Prelu Aktivasyon Fonksiyonu .....	27
Şekil 4.15: Elu Aktivasyon Fonksiyonu .....	28
Şekil 4.16: Swish Aktivasyon Fonksiyonu.....	29
Şekil 4.17: Softmax Aktivasyon Fonksiyonu .....	29
Şekil 4.18: ESA Mimarisi.....	38
Şekil 4.19: 5X5X3 Giriş Matrisine 3x3x3 Filtre ile Evrişim .....	39
Şekil 4.20: Havuzlama Çeşitleri .....	39
Şekil 4.21: Tam Bağlı Katman .....	40
Şekil 4.22: Seyreltme İşlemi.....	41
Şekil 4.23: Lenet -5 Mimarisi.....	41
Şekil 4.24: AlexNet Mimarisi.....	42
Şekil 4.25: ZFNet Mimarisi.....	42
Şekil 4.26: GoogleNet Mimarisi.....	43
Şekil 4.27: Artık Blok Yapısı .....	43
Şekil 4.28: ResNet Ağ Yapısı.....	43

<b>Şekil 4.29:</b> ResNet152V2 Ağ Yapısı .....	44
<b>Şekil 4.30:</b> VGG16 Ağ Yapısı .....	45
<b>Şekil 4.31:</b> VGG19 Ağ Yapısı .....	45
<b>Şekil 5.1:</b> Veri Setinde Bulunan Beyin MR Görüntü Örnekleri.....	48
<b>Şekil 5.2:</b> Veri Setindeki Verilerin Veri Gruplarına Göre Dağılımı.....	49
<b>Şekil 5.3:</b> Eğitim Verileri Dağılımı .....	50
<b>Şekil 5.4:</b> Test Verileri Dağılımı .....	50
<b>Şekil 5.5:</b> Model Blok diyagramı .....	51
<b>Şekil 5.6:</b> Model Yalancı (Pseudo Code) Kodu .....	51
<b>Şekil 5.7:</b> Model 1-a Yalancı (Pseudo Code) Kodu .....	53
<b>Şekil 5.8:</b> Model 1-a Eğitim Veri Seti Başarı- Kayıp Grafiği .....	53
<b>Şekil 5.9:</b> Model 1-a Sınıflandırma Raporu.....	54
<b>Şekil 5.10:</b> Model 1-b Yalancı (Pseudo Code) Kodu .....	54
<b>Şekil 5.11:</b> Model 1-b Eğitim Veri Seti Başarı- Kayıp Grafiği .....	55
<b>Şekil 5.12:</b> Model 1-b Sınıflandırma Raporu .....	55
<b>Şekil 5.13:</b> Model 1-b-1 Yalancı (Pseudo Code) Kodu.....	56
<b>Şekil 5.14:</b> Model 1-b -1 Eğitim Veri Seti Başarı- Kayıp Grafiği.....	56
<b>Şekil 5.15:</b> Model 1-b-1 Sınıflandırma Raporu .....	57
<b>Şekil 5.16:</b> Model 1-b-2Yalancı (Pseudo Code) Kodu.....	57
<b>Şekil 5.17:</b> Model 1-b -2Eğitim Veri Seti Başarı- Kayıp Grafiği.....	57
<b>Şekil 5.18:</b> Model 1-b-2 Sınıflandırma Raporu .....	58
<b>Şekil 5.19:</b> Model 1-c Yalancı (Pseudo Code) Kodu .....	58
<b>Şekil 5.20:</b> Model 1-c Eğitim Veri Seti Başarı- Kayıp Grafiği .....	59
<b>Şekil 5.21:</b> Model 1-c Sınıflandırma Raporu.....	59
<b>Şekil 5.22:</b> Model 2-a Yalancı (Pseudo Code) Kodu .....	60
<b>Şekil 5.23:</b> Model 2-a Eğitim Veri Seti Başarı- Kayıp Grafiği .....	60
<b>Şekil 5.24:</b> Model 2-a Sınıflandırma Raporu.....	61
<b>Şekil 5.25:</b> Model 2-b Yalancı (Pseudo Code) Kodu.....	61
<b>Şekil 5.26:</b> Model 2-b Eğitim Veri Seti Başarı- Kayıp Grafiği .....	62
<b>Şekil 5.27:</b> Model 2-b Sınıflandırma Raporu .....	62
<b>Şekil 5.28:</b> Model 2-b-1 Yalancı (Pseudo Code) Kodu.....	63
<b>Şekil 5.29:</b> Model 2-b-1 Eğitim Veri Seti Başarı- Kayıp Grafiği.....	63
<b>Şekil 5.30:</b> Model 2-b-1 Sınıflandırma Raporu .....	64
<b>Şekil 5.31:</b> Model 2-b-2 Yalancı (Pseudo Code) Kodu.....	64
<b>Şekil 5.32:</b> Model 2-b-2 Eğitim Veri Seti Başarı- Kayıp Grafiği.....	64
<b>Şekil 5.33:</b> Model 2-b-2 Sınıflandırma Raporu .....	65
<b>Şekil 5.34:</b> Model 2-c Yalancı (Pseudo Code) Kodu .....	65
<b>Şekil 5.35:</b> Model 2-c Eğitim Veri Seti Başarı- Kayıp Grafiği .....	66
<b>Şekil 5.36:</b> Model 2-c Sınıflandırma Raporu.....	66
<b>Şekil 5.37:</b> Model 2-c -1Yalancı (Pseudo Code) Kodu .....	67
<b>Şekil 5.38:</b> Model 2-c-1 Eğitim Veri Seti Başarı- Kayıp Grafiği .....	67
<b>Şekil 5.39:</b> Model 2-c-1 Sınıflandırma Raporu .....	68
<b>Şekil 5.40:</b> Model 2-c -2 Yalancı (Pseudo Code) Kodu .....	68
<b>Şekil 5.41:</b> Model 2-c-2 Eğitim Veri Seti Başarı- Kayıp Grafiği .....	69
<b>Şekil 5.42:</b> Model 2-c-2 Sınıflandırma Raporu .....	69
<b>Şekil 5.43:</b> Model 3-a Yalancı (Pseudo Code) Kodu .....	70
<b>Şekil 5.44:</b> Model 3-a Eğitim Veri Seti Başarı- Kayıp Grafiği .....	70
<b>Şekil 5.45:</b> Model 3-a Sınıflandırma Raporu.....	71
<b>Şekil 5.46:</b> Model 3-a-1 Yalancı (Pseudo Code) Kodu .....	71
<b>Şekil 5.47:</b> Model 3-a-1 Eğitim Veri Seti Başarı- Kayıp Grafiği .....	72

<b>Şekil 5.48:</b> Model 3-a-1 Sınıflandırma Raporu .....	72
<b>Şekil 5.49:</b> Model 3-a-2 Yalancı (Pseudo Code) Kodu .....	73
<b>Şekil 5.50:</b> Model 3-a-2 Eğitim Veri Seti Başarı- Kayıp Grafiği .....	73
<b>Şekil 5.51:</b> Model 3-a-2 Sınıflandırma Raporu .....	74
<b>Şekil 5.52:</b> Model 3-b Yalancı (Pseudo Code) Kodu .....	74
<b>Şekil 5.53:</b> Model 3-b Eğitim Veri Seti Başarı- Kayıp Grafiği .....	75
<b>Şekil 5.54:</b> Model 3-b Sınıflandırma Raporu .....	75
<b>Şekil 5.55:</b> Model 3-b-1 Yalancı (Pseudo Code) Kodu.....	76
<b>Şekil 5.56:</b> Model 3-b-1 Eğitim Veri Seti Başarı- Kayıp Grafiği.....	76
<b>Şekil 5.57:</b> Model 3-b-1 Sınıflandırma Raporu .....	77
<b>Şekil 5.58:</b> Model 3-b-2 Yalancı (Pseudo Code) Kodu.....	77
<b>Şekil 5.59:</b> Model 3-b-2 Eğitim Veri Seti Başarı- Kayıp Grafiği.....	78
<b>Şekil 5.60:</b> Model 3-b-2 Sınıflandırma Raporu .....	78
<b>Şekil 5.61:</b> Model 3-c Yalancı (Pseudo Code) Kodu .....	79
<b>Şekil 5.62:</b> Model 3-c Eğitim Veri Seti Başarı- Kayıp Grafiği .....	79
<b>Şekil 5.63:</b> Model 3-c Sınıflandırma Raporu.....	80
<b>Şekil 6.1:</b> Glioma Tümörün Adının Doğru Tahmini ve Yerinin Belirlenmesi.....	82
<b>Şekil 6.2:</b> Meningioma Tümörün Adının Doğru Tahmini ve Yerinin Belirlenmesi .	83
<b>Şekil 6.3:</b> Pituitary Tümörün Adının Doğru Tahmini ve Yerinin Belirlenmesi .....	83
<b>Şekil 6.4:</b> Tümör Olmayan Verinin Adının Doğru Tahmini ve Yerinin Belirlenmesi .....	84

## EVRIŞİMLİ SİNİR AĞLARI İLE (ESA)BEYİN TÜMÖRÜ TESPİTİ

### ÖZET

Beyin tümörü beyindeki hücrelerin anormal sayıda çoğalmasdır. Beyin tümörü tespitinde görüntüleme teknikleri arasında gösterilen Manyetik Rezonans (MR) başvuru en iyi yöntemdir. Beyin tümörlerinin erken, hızlı ve doğru teşhis edilmesi tedavi sürecindeki en önemli etkenler arasındadır.

Son yıllarda tedavi sürecinin başlangıcı olan teşhis aşamasında yardımcı olabilmek amacıyla sağlık alanında yapay zekâ uygulamaları kullanılmaya başlanmıştır. Bu uygulamalarda kullanılan derin öğrenme tekniklerinden biri olan Evrişimli Sinir Ağları (ESA) ve MR görüntüleri ile sınıflandırma işleminde yaygın olarak kullanılmaktadır.

Sunulan tez çalışmasında beyin tümörlerinin sınıflandırılması için Evrişimli Sinir Ağları arasında gösterilen VGG 16, VGG 19 ve ResNet152V2 modelleri kullanılmıştır. Sınıflandırmada beyin tümörü türleri; glioma, meningioma, pituitary (beyin tümörü türleri) ve tümörsüz veri setleri olarak 4 sınıfa ayrılmıştır. Yapılan çalışmanın performansını değerlendirmek için doğruluk, kesinlik, hassasiyet ve F1 skoru (kesinlik ve hassasiyet değerlerinin harmonik ortalaması) değerlendirilmiştir. Çalışılan yöntem Evrişimli Sinir Ağları modeli ile beyin tümörlerinin daha etkin ve hızlı tespiti amaçlanmıştır.

**Anahtar kelimeler:** Beyin tümörü, Derin öğrenme, Evrişimli sinir ağları (ESA), Magnetik rezonans (MR)

## **BRAIN TUMOR DETECTION WITH CONVOLUTIONAL NEURAL NETWORKS (CNN)**

### **ABSTRACT**

A brain tumor is an abnormal proliferation of cells in the brain. Magnetic Resonance Imaging (MRI) is the best method used to detect brain tumors. Early, fast and accurate diagnosis of brain tumors is among the most important factors in the treatment process.

In recent years, artificial intelligence applications have started to be used in the field of health in order to help in the diagnosis phase, which is the beginning of the treatment process. Convolutional Neural Networks (DNN), one of the deep learning techniques used in these applications, are widely used in the classification process with MRI images.

In this thesis, VGG 16, VGG 19 and ResNet152V2 models, which are among the Convolutional Neural Networks, were used to classify brain tumors. In classification, brain tumor types are divided into 4 classes as glioma, meningioma, pituitary (brain tumor types) and tumor-free data sets. Accuracy, precision, sensitivity and F1 score (harmonic mean of precision and sensitivity values) were evaluated to assess the performance of the study. The studied method aims to detect brain tumors more effectively and faster with the Convolutional Neural Network model.

**Keywords:** Brain Tumor, Deep learning, CNN, MR

## 1. GİRİŞ

Beyin tümörleri beyindeki hücrelerin anormal şekilde ve kontrolsüz olarak çoğalmasdır. Beyin tümörlerinde erken tanı tedavi imkanlarını arttırmakta, tedavi sürecini hızlandırmakta ve tedavi başarısını arttırmaktadır. Beyin tümörlerinin teşhisinde Manyetik Rezonans Görüntüleme (MRG) kullanılır. Elde edilen görüntü verilerin bir radyolog tarafından incelenerek tümörün ve tümör çeşidinin belirlenmesi yaygın olarak kullanılan geleneksel bir yöntemdir. Bu yöntem hekimlerin hata yapma olasılığını arttırmakta ve onların çokça zamanını almaktadır.

Hızla gelişen teknoloji ile veri sayısı her geçen gün arttığından bilgisayarlar sağlık alanında hızla yer tutmaya başlamıştır. Bu anlamda yapay zekâ, hastalıkların teşhisi için kullanılmaya başlanmıştır. Makine öğrenmesi metotlarından olan yapay zekâ ile MR görüntü verilerinin sınıflandırılması etkin ve doğru bir şekilde yapılmaktadır.

Yapay zekâ sayesinde beyin tümörlerini sınıflandırmada ve tümör teşhisinde hata yapma olasılığı en aza indirilerek hastanın durumunun belirlenmesinde harcanan zaman azaltılmış olacaktır.

### 1.1 Tezin Amacı

Bu çalışmada glioma, meningioma, pituitary tümörlerinin sınıflandıran bir sistem üzerinde çalışılmıştır. Manyetik Rezonans kullanarak elde edilen beyin görüntülerinde tümörün olup olmadığı, tümör varsa hangi çeşit tümörün var olduğunun tespiti ve bu sayede hastalığın doğru ve hızlı teşhisine yardımcı olmak amaçlanmıştır.

### 1.2 Literatür Araştırması

Bu bölümde beyin tümörü tespiti ile ilgili yapılmış çalışmalara yer verilmiştir.

Swati vd. (2019) da yapmış oldukları çalışmada 233 kişinin toplamda 3064 adet beyin MR verisini kullanmışlar.6 katmanla kurmuş oldukları modelde ESA mimarilerinden olan VGG 16, VGG 19 ve AlexNet modellerini kullanarak sırasıyla %94.65, %94.82 ve %89.95 başarımlar elde etmişler.

Abbood, Shallal, Fadhel ve Shallal (2021) 1800 ü tümörlü,1200 ü tümörsüz 3000 adetlik MR veri setini kullanarak yapmış oldukları çalışmada bu veri setinin %80 ini eğitim, %10 unu doğrulama ve % 10 unu test için kullanmışlar. Bu çalışmada dört ESA modelini karşılaştırmışlar. VGG16 için %86.4, AlexNet için %82.7, GoogleNet için %91 ve ResNet50 için %95.8 doğruluk elde etmişler ve burdan hareketle en başarılı modelin ResNet50, en hızlı modelin AlexNet olduğu sonucuna varmışlardır.

Alnemer ve Rasheed, (2021) 4923 adet 4 sınıflı (1096 adet glioma, 1096 adet meningeoma, 1120 adet pituitary, 1475 adet tümörsüz) beyin MR seti ile ESA modellerinden ResNet152V2 i kullanarak karşılaştırmalı iki çalışma yapmışlar. İlk çalışmada verileri direkt olarak modelden geçirerek %96.47 lik doğruluk elde etmişler. İkinci çalışmada ise veri setindeki veri sayısını veri artırma yöntemi ile toplamda 133.669 adete çıkararak kullanmışlar ve %98.9 başarımlar elde etmişler.

Şener ve Ergen (2022) VGG 19 ESA modelini kullanarak 24 katmanlı bir model yapısı önermişler. Önerilen bu yapıda veri seti olarak 7648 adet beyin MR verisi kullanmışlar ve bu seti 5712 tanesi eğitim, 1311 tanesi test ve 655 tanesi doğrulama verisi olmak üzere üçe bölmüşler. Aktivasyon fonksiyonu olarak RELU yu kullanmışlar ve 134.309.700 adet parametre ile %95 başarımlar ile çalışmayı bitirmişler.

Srinivas vd. (2022) beyin tümörü tespiti için yapmış oldukları çalışmada ESA mimarilerinden olan VGG 16, ResNet50 ve InceptionV3 modellerini karşılaştırmışlar. Bu çalışmayı 256 158 tanesi tümörlü, 98'i tümörsüz beyin MR verisi üzerinde yapmışlar. Aktivasyon fonksiyonu olarak RELU yu kullanmışlar. VGG 16 da %96, Inception V3 de %78 ve ResNet50 de %95 doğrulukmlar elde etmişler.

Almadhoun ve Abu-Naser (2022)5000'i tümörlü 5000'i tümörsüz olmak üzere 10000 adet beyin MR verisi kullanmışlardır. Bu veri setini üçe bölmüşlerdir.7000 adedi eğitim verisi,2000 adedi doğrulama verisi,1000 adedi de test

verisinden iştilal etmiş. Oluşturmuş oldukları veri setleri eşi sayıda tümörlü ve tümörsüz veri içermektedir. Yapmış oldukları çalışmada verileri 200x200 boyutlarında ön işleme tabi tutarak kullanmışlar. Bu verileri tasarladıkları 12 katmanlı bir modelde eğitmişler. Dört farklı ESA modelini kullanmışlar. VGG 16 ile %99, MobileNet ile %88.98, ResNet50 ile %98.14, InceptionV3 ile %99.88 başarıya ulaşmışlar.

Han -Trong vd. (2022) 674 adet tümörlü ve 660 adet tümörsüz toplam 1307 adet veriden oluşan beyin MR veri seti ile DenseNet 201, REsNet152V2, MobileNetV3 ve VGG 19 ESA modellerini karşılaştırmak için yapmış oldukları çalışmada sırasıyla %99.88, %99.95, %99.7 ve %99.91 başarı elde etmişler.

Sharma ve diğerleri (2022) beyin MR görüntülerini ikili sınıflandırma (tümör var tümör yok) ve VGG16, VGG19, DenseNet121, DenseNet201 CNN mimarilerinin performanslarını değerlendirmek amacıyla yaptıkları çalışmada VGG16'da %94, VGG19'da %98, DenseNet121'de %96, DenseNet201'de %96 doğruluk sağlamışlardır.

Harahap vd. (2022) önermiş oldukları ESA modeli, VGG16, ResNet50, DenseNet121, InceptionV3, MobileNetV2, ESA modellerini karşılaştırmak için yapmış oldukları çalışmada 252 adet eğitim verisi, 155 adet doğrulama verisi ve 97 adet test verisinden oluşan beyin MR veri setini kullanmışlar. Çalışma sonunda VGG 16 ile %97.92, Resnet50 ile %94.03, DenseNet121 ile %9.86, InceptionV3 ile %94.78 ve MobileNet V2 ile %97.02 doğruluğa ulaşmışlar.

Asif, Zhao, Chen ve Zhu, (2023) Xception, vgg16 , DenseNet201,ResNet152V2 , InceptionResNetv2 ESA modellerini karşılaştırmak için 3064 adet veri ve 3 sınıftan oluşan (930 adet pituitary, 708 adet meningioma, 1426 adet glioma)oluşan veri seti ile önerdikleri modelde RELU aktivasyon fonksiyonunu, ADAM optimizasyon fonksiyonunu ve kategorik çapraz entropi kayıp fonksiyonunu kullanarak Xception ile %91.83,VGG16 ile %93.54,DenseNet ile %97.22,Resnet152V2 ile %95.58,inceptionResNetv2 ile %95.75 doğruluğa ulaşmışlar.

## 2. BEYİN TÜMÖRLERİ

Beyindeki hücrelerin düzensiz olarak artması beyin tümörü olarak adlandırılır. Tümörler kafatası içinde fazla basınca sebebiyet vererek beyin hücrelerine zarar verirler (Amin, ve diğ., 2020, s. 119).


Beyin içinde oluşan tümörlere primer tümör denir. Vücudun başka bir bölgesinde oluşup beyne metastaz yapan tümörlere ise sekonder tümör denir (Mohsen vd.,2018, s. 68).

Kanser olan beyin tümörlerine kötü huylu tümör denir. Kanser olmayanlar ise iyi huylu tümör olarak isimlendirilir. Beyin tümörleri glioma, meningioma ve pituitary olarak sınıflandırılırlar (Shaik, Nagur ve Cherukuri, 2022, s.817).

### 2.1 Veri Setindeki Tümör Çeşitleri

#### 2.1.1 Glioma

Glioma tümörler sıkça görülen primer tümörlerden biridir. Beyinde oluşan tümörlerin yaklaşık olarak %80 i bu tümör çeşidine aittir. Merkezi sinir sisteminde olan tümörlerdir. Gelişimleri iyi veya kötü huylu olabilir (Van Tellingen ve diğ., 2015, s.2).




**Şekil 2.1:** Glioma Tümör

**Kaynak:** (www.kaggle.com,16.05.2023)

### 2.1.2 Meningioma

Meningioma tümörler beyin ve omuriliğin etrafındaki zar tabakada görülürler ve yavaş büyürler. Çoğu iyi huyludur. Primer tümörlerdendir (Domingues ve diğ., 2016, s.2).




Şekil 2.2: Meningioma Tümör

Kaynak: (www.kaggle.com,16.05.2023)

### 2.1.3 Pituitary

Hipofiz bezindeki hücrelerin kontrolsüz çoğalması sonucu oluşur. Hipofiz Bezi Adenomu olarak adlandırılır. Beyinde oluşan tümörlerin yaklaşık %15' ini oluşturur. Primer tip tümörlerdendir (Mete ve Lopes, 2017, s.228).



Şekil 2.3: Pituitary Tümör

Kaynak: (www.kaggle.com,16.05.2023)

## 2.2 Beyin Tümörlerinin Tespiti

Bu işlem için tıbbi görüntüleme tekniklerinden faydalanılmaktadır. Tıbbi Görüntüleme çeşitli tekniklerle insan bedeninin iç yapısını farklı enerjiler ile görülebilir hale getirmektedir (Bankman, 2008, s.1).

Görüntüleme işleminin gerçekleşmesi için farklı enerji türleri kullanılır. Örnek olarak Manyetik Rezonans Görüntüleme (MRG) de radyo dalgaları, Bilgisayarlı Tomografi (BT) de X ışınları kullanılır. Bir nükleer tıp görüntüleme tekniği olan Pozitron Emisyon Tomografi (PET) da ise enerji türü olarak gama ışınları kullanılır (Bushberg ve diğ., 2011, s.8).


- **Röntgen (X-Ray):** En temel ve en eski görüntüleme yöntemidir. Vücudun bölümleriyle (baş, boyun, gövde vb.) birlikte kemiklerin (kırık vb.) görüntülenmesinde kullanılır. X ışınları ayırt etme kabiliyeti az olduğundan dolayı görüntülenen bölge ile ilgili hasar vb. hakkında net bilgi vermez (Szabo, 2004, s.24).



**Şekil 2.4:** X-Ray Görüntüsü

**Kaynak:** (Sethy ve Beher.,2020: s. 5)

- **Bilgisayarlı Tomografi (BT):** Tomografi bir dilimin resmi anlamına gelir ve vücudun düşük çözünürlükte görüntülenmesine imkân tanır. Bu sayede tümörler, damar hastalıkları ve lezyonların belirlenir (Sürmen, 2006, s.3).



**Şekil 2.5: BT Görüntüsü**

**Kaynak:** (Klingenbeck- ve diğ., 1999: s .117)


- **Manyetik Rezonans Görüntüleme (MRG):** Bu teknikte manyetik alan kullanıldığından görüntü kalitesi yüksektir. İnsan anatomisi ve metabolizması ile ilgili detaylı bilgi verir (Moser ve diğ., 2009, s .31).



**Şekil 2.6: MR Görüntüsü**

**Kaynak:** (Vande Berg ve diğ., 1998: s. 472)

- **Pozitron Emisyon Tomografi (PET):** Bu yöntem insan bedenine verilen radyoizotopların gama detektörleriyle tespit edildiği görüntüleme tekniğidir. PET organları ve yumuşak dokuları yüksek çözünürlüğü sayesinde detaylıca görüntüler (Demir ve diğ., 2009, s. 88).



**Şekil 2.7:** PET Görüntüsü

**Kaynak:** (Kara, Koç, Köksel ve Ayan.,2018: s.476)

Genellikle beyin tümörü tespitinde Manyetik Rezonans Görüntüleme (MRG) tekniği kullanılmaktadır (Tasçı, 2022, s .1).

Manyetik Rezonans Görüntüleme (MRG) büyük boyutlu mıknatıslar kullanılarak elde edilen manyetik alanla ile radyo dalgalarını kullanarak vücut içindeki dokuları görüntüleye bir tıbbi görüntüleme tekniğidir. Elde edilen görüntü çözünürlüğü yüksektir (Herek ve Karabulut, 2010, s. 214).

Yüksek çözünürlüğü sayesinde vücutta bulunan yumuşak dokuların ayrıştırılması ve incelenmesini kolaylaştırmaktadır (Oyar, 2008, s. 32).



**Şekil 2.8:** Açık MRG Cihazı

**Kaynak:** (Fischbach ve diğ., 2011: s.189)

Açık MRG, üç tarafı açık, rahat, daha az gürültülüdür. Kilolu hastalar, nefes darlığı olan hastalar, kapalı alan fobisi olan hastalarda açık MR kullanmak daha uygundur. Açık MRG cihazının dezavantajı açık formada yapıldığından manyetik alanı güçlü ve çözünürlüğü düşüktür (Bangard ve diğ., 2007, s.152).



**Şekil 2.9:** Kapalı MR Cihazı

**Kaynak:** (Yakıncı, 2013: s.4)

Kapalı MR cihazı çok gürültülü çalışır ve güçlü bir manyetik alan vardır. Elde edilen görüntü kalitesi yüksektir ve bu sayede çalışılan görüntü hakkında ayrıntılı bilgi verebilme yeteneğine sahiptir (Gassert ve diğ., 2006, s. 199).

### 3. MAKİNE ÖĞRENMESİ

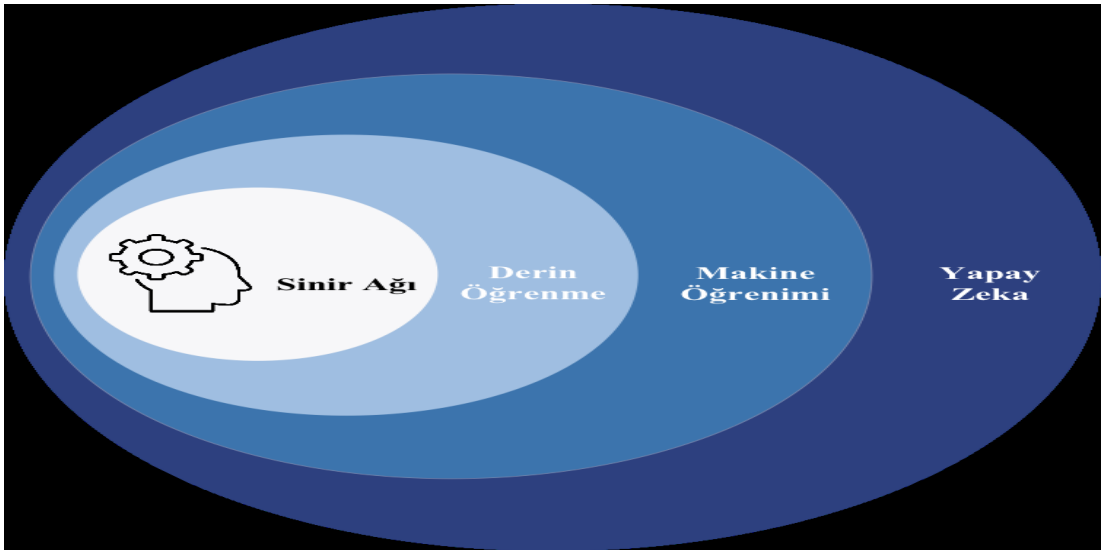
#### 3.1 Yapay Zekâ, Makine Öğrenmesi, Derin Öğrenme Arasındaki İlişki

Yapay zekâ; Bir bilgisayar sisteminin ya da bilgisayar kontrollü bir makinenin insana has olduğu varsayılan öğrenme, karar verme, deneyimlerden faydalanma gibi zihinsel süreçleri kullanarak belirlenen görevleri yerine getirme yeteneğidir (Hamet ve Tremblay, 2017, s.36).

Makine Öğrenmesi; Algoritmaların sisteme girilen verileri kullanarak kendi kendine öğrenmesini ve tahmin yapabilmesini sağlayan bir disiplindir ve yapay zekanın bir alt dalıdır (Janiesch ve diğ., 2021, s.685).

Derin öğrenme; obje tanıma, konuşmayı ayırt etme, doğal dil işleme vb. alanlarda kullanılan ve yapay sinir ağlarını kullanarak karmaşık problemleri çözmek için geliştirilmiş bir makine öğrenmesi alt dalıdır LeCun, Bengio ve Hinton,2015, s.436).

Sinir Ağları; İnsan beyni çalışma prensiplerinden esinlenerek tasarlanmış istatistiksel modellerdir (Liu, Zhao, Ju ve Shi, 2017, s. 161).



Şekil 3.1: Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Arasındaki İlişki

Kaynak: (Gökalp,2022: s2)

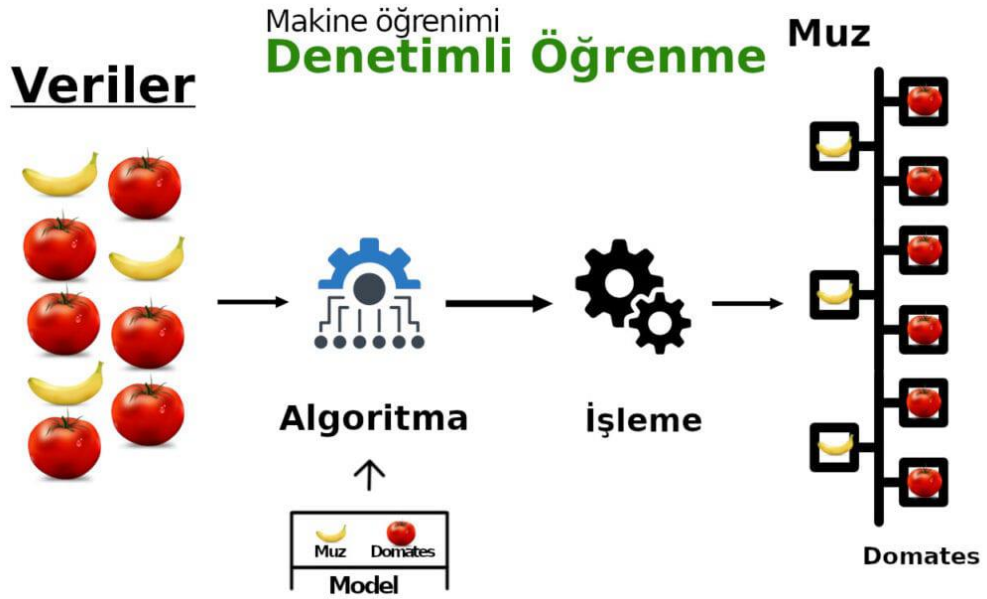
### 3.2 Makine Öğrenmesi

Teknolojinin her geçen gün gelişmesinden dolayı yüksek hızlı bilgisayarlar üretilmiştir ve çok sayıda veri oluşmuştur. Buna paralel olarak bu verilerin işlenmesi, analiz edilmesi gerekliliği ortaya çıkmıştır. Bu ihtiyaca makine öğrenmesi cevap vermiştir (Mahesh, 2020, s.381).

Makine Öğrenmesi; Bilgisayarların, algoritmalar yardımıyla veri analizleri ve deneyimleri kullanarak kendilerini geliştirmelerini sağlayan bir yöntemdir (Sharma ve diğerleri, 2021, s.25).

#### 3.2.1 Denetimli öğrenme

Makine öğrenmesi yöntemlerinden biridir. Belirli bir amacı gerçekleştirmek için verileri kullanarak bir model oluşturmayı amaçlayan ve bu verilerin etiketlerine bağlı kalarak sınıflandırma yapan bir öğrenme yaklaşımıdır (Bilgin, 2017, s.1).

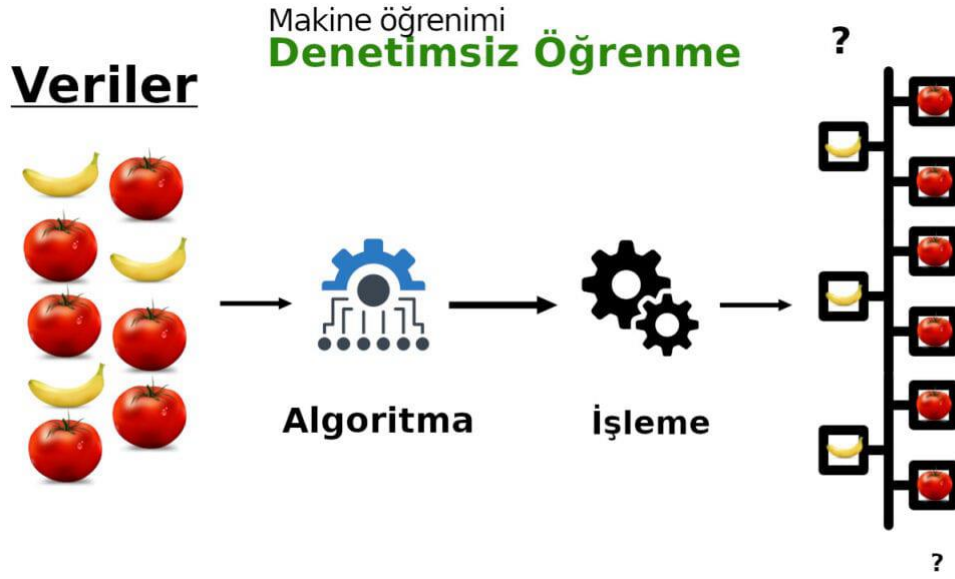


Şekil 3.2: Denetimli Öğrenme

Kaynak: (Gökalp,.2022: s.6)

#### 3.2.2 Denetimsiz öğrenme

Etiketlenmemiş verinin modelde kullanıldığı, öğrenme işleminin ağız eğitimi sırasında gerçekleştiği ve sistemin doğru çıkış hakkında bir bilgiye sahip olmadığı öğrenme türüdür. Veri içindeki benzerlikleri, grupları ve yapıları tespit etmek amacıyla kullanılır (Song, Goncalves ve Perona, 2003, s.814).



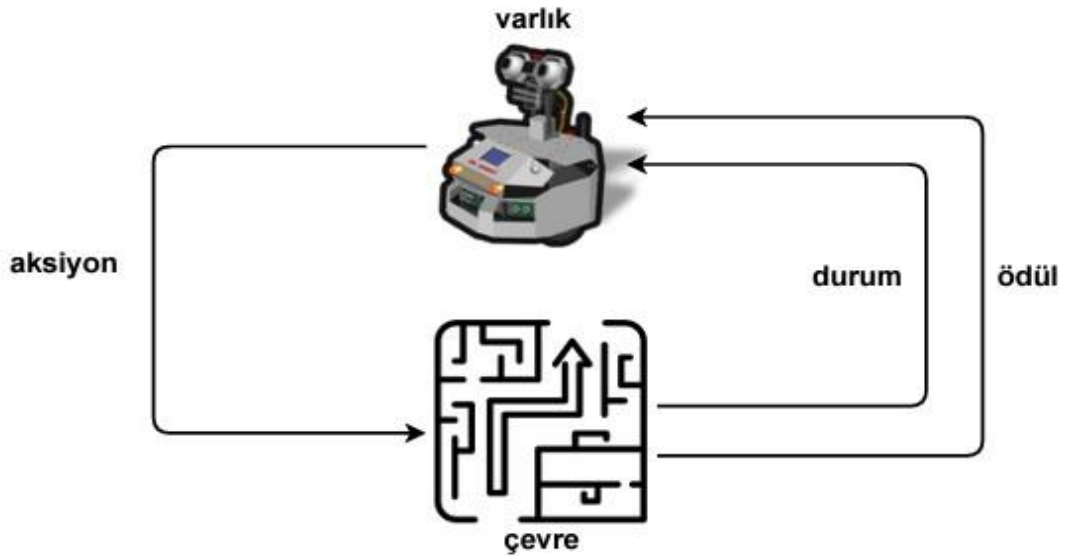
**Şekil 3.3: Denetimsiz Öğrenme**

**Kaynak:** (Gökalp,.2022: s.7)

### 3.2.3 Pekiştirmeli öğrenme

Bu tür öğrenmede temel yaklaşım gerçek olan bir vakanın ödül-ceza anlayışı ile istenen sonuca ulaşmaya çalışmaktır (İmamoğlu, Eresen ve Efe, 2009, s.1).

Sistemde var olan ajan çevre ile etkileşim halindedir ve kendisini sonuca götürecek en kısa yöntemi deneme yanılma metodolojisi içinde bulmaya çalışır (Cruz, Twiefel, Magg, Weber ve Wermter, 2015, s. 2).



**Şekil 3.4: Pekiştirmeli Öğrenme**

**Kaynak:** (Büyükoflaz,.2021: s.16)

### **3.3 Makine Öğrenmesi Algoritmaları**

#### **3.3.1 Karar ağaçları**

Sınıflandırma ve regresyon problemlerinin çözümünde kullanılırlar. Karar ağaçları hedefe ulaşmak için çeşitli yollar geliştirirler ve bu yollar bir ağaca benzer (Zorman ve diğerleri,2001, s.110).

Karar ağaçlarında esas olan sonuca ulaşabilmek olduğundan çözüm yolları birbirine bağlı koşullardan oluşur. Karar ağaçları başlangıçtan itibaren verileri düğümlere, dallara ve yapraklara bölerek sınıflandırma işlemini gerçekleştirmektedirler (Jensen,2008, s.409).

#### **3.3.2 Random forest**

Rastgele orman algoritması bir karar ağacı yöntemidir. Tek bir çıktıya ulaşmak amacıyla birden fazla karar ağacının bir araya getirilmesiyle oluşturulur. Sınıflandırma ve regresyon problemlerinde kullanılır (Biau ve Scornet, 2016, s.198).

#### **3.3.3 Lojistik regresyon**

İstatistikte sıklıkla kullanılan bir regresyon yöntemidir. Bu yöntemin amacı en az değişken kullanarak değişkenler arasındaki ilişkiyi tanımlamaktır (Bircan, 2004, s.186).

Lojistik regresyonda bağımlı değişkenler ikili değişkenlerle ölçülür. Bağımsız değişkenlerin katsayılarını tahmin eder ve tahminleri kullanarak bağımlı değişkenin bir kategoriye ait olma olasılığını hesaplar (Real, Barbosa ve Vargas,2006, s.237).

#### **3.3.4 Naive bayes**

Naive Bayes algoritması sınıflandırma ve veri madenciliğinde kullanılır. Verilerin özellik vektörleri ve bu vektörlere karşılık gelen sınıf etiketlerinin olduğu bir eğitim seti vardır. Bu veri seti kullanılarak öğrenme işlemi gerçekleşir (Chen, Webb, Liu ve Ma, 2020, s.1).

Bu algoritma Bayes Teoremini esas alarak çalışır. Buna istinaden her bir veri elemanın her durumunun olasılığını hesaplayarak olasılığı en yüksek olan duruma göre sınıflandırmayı gerçekleştirir (Frank, Trigg, Holmes ve Witten,2000, s.6).

### **3.3.5 K en yakın komşu algoritması**

Sınıflandırma ve regresyon problemlerinde kullanılır. Bu algoritmada ana düşünce eğitim veri setindeki verilerin ait olduğu sınıf etiketlerini öğrenerek en yakında bulunan verilerin ait olduğu sınıfı tahmin etmektir (Sun ve Huang, 2010, s.92).

K en yakın komşu algoritması basit bir yapıya sahiptir. Büyük veri setlerinde yavaş çalıştığından performansı düşüktür (Taunk, De, Verma ve Swetapadma, 2019, s.1255).

### **3.3.6 Destek vektör makineleri**

Bu algoritmanın temel amacı veri noktalarını en makul şekilde bölen hiper düzlemi oluşturmaktır. Diğer bir ifadeyle veri sınıflarına ait olan destek vektörleri arasındaki mesafeyi en büyük yapmaya çalışmaktır (Wen, Yang, Song ve Jig, 2010, s.1017).

## 4. DERİN ÖĞRENME

Derin öğrenme; Ses, resim, metin gibi verileri yapay sinir ağları ve benzeri algoritmalar yardımıyla öğrenerek kendisine verilen görevleri yapan sistemlerdir (Kelleher, 2019, s.10).


### 4.1 Yapay sinir ağları (YSA)

Bilim adamlarının insan beyni üzerinde yaptıkları çalışmalar ile beyin fonksiyonlarının matematiksel modelleri çıkartılmaya çalışılmıştır. Bu çalışmalar neticesinde yapay sinir hücresi ve yapay sinir ağları geliştirilmiştir (Ataseven, 2013, s.102).

İnsan beyni işlevlerinden ilham alınarak geliştirilen yapay sinir ağları (YSA), öğrenme yöntemiyle geliştirilmiştir. Bu sistemler öğrenme, sınıflandırma, özellik çıkarma gibi görevlerde kullanılırlar (Ersoy ve Karal ,2012, s.192).

#### 4.1.1 Yapay sinir hücresi

Yapay sinir ağlarının temel yapıtaşı yapay sinir hücreleridir. Yapay sinir hücresine nöron da denir (Kukreja, Bharath, Siddesh ve Kuldeep, 2016, s.28).



**Şekil 4.1:** Bir sinir hücresinin yapısı

**Kaynak:** Zhang, Yu, Barbiero, Wang ve Gu.,2019: s.3)

- **Girdi:** Bir yapay sinir hücresine, dışarıdan ya da başka bir sinir hücresinden gelen bilgidir (Hristev,1998, s.3).

- **Ağırlık:** Yapay sinir hücresine giren değerin ağırlığını gösterir. Ağırlıklar girdi bilgilerinin nöron üzerindeki etkisini belirler. Negatif, pozitif ve sıfır değerlerini alabilir (Çuhadar, 2006, s.118).
- **Toplam Fonksiyonu:** Yapay sinir hücresinde hücrenin net girdisini hesaplayan fonksiyondur. Genel olarak ağırlıklı toplamı bulan fonksiyon tercih edilir (Abraham,2005, s.902).

$$NET = \sum_i^n G_i A_i \quad (4.1)$$

Denklem 4.1 de G: girdi bilgilerini, A: ağırlık değerlerini ve N: nörona gelen toplam girdi sayısını gösterir.

**Çizelge 4.1: Toplam Fonksiyonu Türleri**

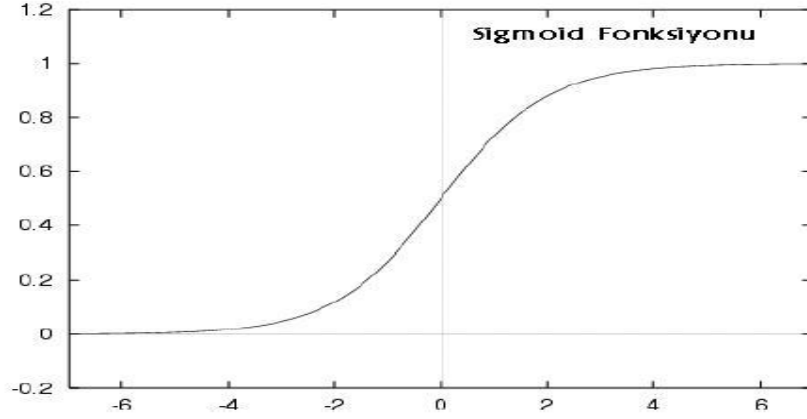
NET GİRİŞ	AÇIKLAMA
Çarpım Net Girdi= $\prod_i G_i A_i$	Ağırlık değerleriyle girdi değerlerinin birbiri ile çarpımından elde edilir.
Maksimum Net Girdi= $Max(G_i A_i), i = 1 \dots N$	Ağırlıklar ile girdiler çarpılır, çarpılmış değerler birbirleri ile karşılaştırılır, en büyük olan değer sistemin net girdisi olur.
Minimum Net Girdi= $Min(G_i A_i), i = 1 \dots N$	Ağırlıklar ile girdiler çarpılır, çarpılmış değerler birbirleri ile karşılaştırılır, en küçük olan değer sistemin net girdisi olur.
Çoğunluk Net Girdi= $\sum_i sgn(G_i A_i)$	Ağırlıklarla çarpılmış olan girdilerin işaret fonksiyonu alınır ve net girdi olarak sisteme gönderilir.
Kümülatif Toplam Net Girdi= $Net(eski) + \sum_i^n G_i A_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve önceki bilgilere eklenerel hücrenin net girdisi olur.

**Kaynak:** (Kölmek ,2012: s 6 )

- **Aktivasyon Fonksiyonu:** Hücreye gelen net değeri kullanarak çıkış değerini belirler. Aktivasyon fonksiyonu eşik değer, transfer fonksiyonu ya da sıkıştırma fonksiyonu olarak da adlandırılır.

$$F(NET) = \frac{1}{1+e^{-NET}} \quad (4.2)$$

Denklem 4.2 sigmoid fonksiyonu için kullanılan formülü göstermektedir.  $F(NET)$  olarak gösterilen ifade aktivasyon fonksiyonuna gelen net girdi değerini temsil eder (Yücesoy, 2011, s.46).



Şekil 4.2: Sigmoid Fonksiyonu

Kaynak: (Yücesoy,2011: s.46)

Çizelge 4.2: Aktivasyon Fonksiyonu Türleri


AKTİVASYON FONKSİYONU	AÇIKLAMA
Linear Fonksiyon $F(NE T) = NE T$	Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir.
Step Fonksiyonu $F(NE T) = \begin{cases} 1 & \text{if } NE T > \text{eşik değ er} \\ 0 & \text{if } NE T \leq \text{eşik değ er} \end{cases}$	Gelen net girdi değ erinin belirlenen bir eşik değ erinin üstünde veya altına olmasına göre hücrenin çıktısı 1 veya 0 olur.
Sinüs Fonksiyonu $F(NE T) = \text{Sin}(NE T)$	Öğrenilmesi düşünölen olayların sinüs fonksiyonuna uygun olduğu durumlarda kullanılır.
Eşik Değ er Fonksiyonu $F(NE T) = \begin{cases} 0 & \text{if } NE T \leq 0 \\ NE T & \text{if } 0 < NE T < 1 \\ 1 & \text{if } NE T \geq 1 \end{cases}$	Gelen bilgilerin 0 veya 1'den büyük veya küçük olmasına göre bir değ er alır.0 ile 1 arasında değ erler alabilir.
Hiperbolik Tanjant Fonksiyonu $F(NE T) = (e^{NE T} + e^{-NE T}) / (e^{NE T} - e^{-NE T})$	Gelen net girdi değ erinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.

Kaynak: (Kölmek ,2012, s.7)

- **Çıkış:** Aktivasyon fonksiyonundan çıkan değ eridir. Bu değ er bir sonraki sinir hücresine giriş değ eri ya da dış dünyaya gönderilir (Çuhadar, 2006, s.118).

#### 4.1.2 Tek katmanlı algılayıcı

İlk yapılan ve en basit yapay sinir ağıdır. Tek bir giriş katmanı ve tek bir çıkış katmanından oluşur (Gazel,2019, s.408).



**Şekil 4.3:** Tek Katmanlı Algılayıcı

**Kaynak:** (Öztürk ve Şahin, 2018: s.20)

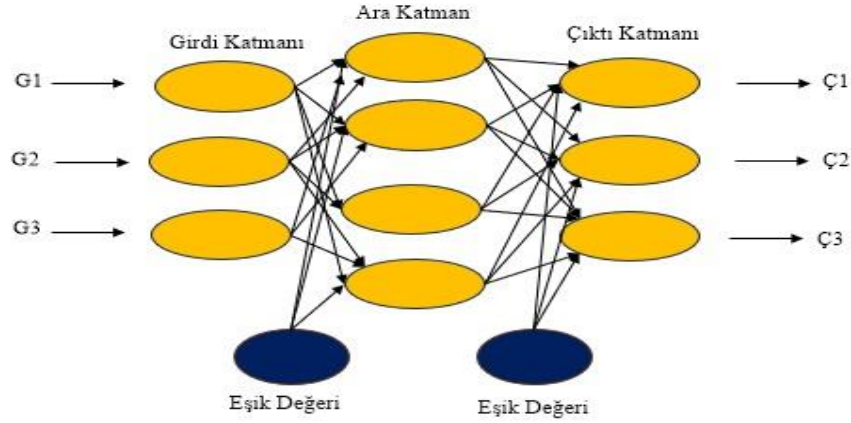
Şekil 4.4 'de  $X_1$  ve  $X_2$  girdi değerlerini,  $W_1$  ve  $W_2$  ağırlık değerlerini,  $\phi$  değeri eşik değerini (her zaman 1dir.) Ve  $\zeta$  ise çıkış değerini ifade eder.

$$\zeta = f(\sum_{i=1}^m w_i + x_i + \phi) \quad (4.3)$$

Denklem 4.3 de tek katmanlı algılayıcının çıkış fonksiyonunun formülü yer almaktadır. Ağın çıktısı 1 ya da -1dir.

#### 4.1.3 Çok katmanlı algılayıcı

Girdiye göre çıktı değerlerinin üretildiği ve en az üç katmandan oluşan ağlardır.



**Şekil 4.4:** Çok Katmanlı Algılayıcı


**Kaynak:** (İclal, 2016: s.739)

- **Giriş Katmanı:** Dışarıdan gelen giriş değerlerinin direk olarak bir sonraki katmana iletiildiği yerdir.
- **Ara (Gizli) Katman:** Giriş katmanından aldığı bilgileri bir sonraki katmana gönderir, bir sinir ağı mantığı ile çalışır.

- **Çıkış Katmanı:** Gizli katmandan almış olduğu girdileri işleyerek bir çıktı üretir. Çıkış katmanında birden çok nöron bulunabilir, her bir nöronun tek bir çıkış değeri vardır (İclal,2016, s.739).

#### 4.1.4 İleri beslemeli yapay sinir ağları

İleri beslemeli ağlarda öğeler katmanlara bölünmüştür. Giriş katmanından çıkış katmanına kadar tek yönlü sinyal iletimi vardır. Tek yönlü iletim ileri yönlü olduğundan ileri beslemeli yapay sinir ağları denir. Bir öğenin çıkışı diğerinin girişi konumundadır. Dış dünyadan gelen giriş katmanına gelen bilgi ara katmana iletilir. Buradan da çıkış katmanına gönderilerek bilginin işlenmesi sağlanır ve ağın çıktısı hesaplanır (Yılmaz, 2020, s.85).



**Şekil 4.5:** İleri Beslemeli Yapay Sinir Ağı

**Kaynak:** (Erilli, Eğrioğlu, Yolcu, Aladağ ve Uslu, 2010: s.45)

#### 4.1.5 İleri doğru hesaplama

Veri setindeki bilgiler girdi katmanından (G1, G2, G3 ...) hiçbir işlem yapılmadan ara katmana gönderilir.

$$\zeta_k^i = G_k \quad (4.4)$$

Bu denklemde;

$G_k$ : Giriş katmanındaki  $k$ . süreç ögesinin çıktısı

$\zeta_k^i$  :  $k$ . süreç ögesinin çıktısıdır.

Ara katmandaki her süreç ögesi giriş katmanındaki bütün süreç öğelerinden gelen bilgileri bağlantı ağırlıkları (A1, A2 ...) ile alır.

$$NET_j^a = \sum_{k=1}^n A_{kj} S_k^i \quad (4.5)$$

Bu denklemde;

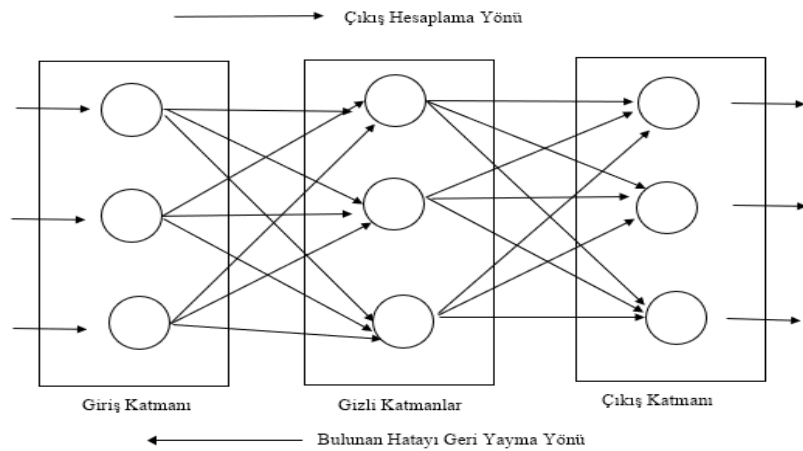
$NET_j^a$  : Ara katmandaki süreç öğelerine gelen net girdi

$A_{kj}$ :  $k$ . giriş katmanı öğesini  $j$ . ara katman öğesine bağlayan bağlantının ağırlık değeridir.

$j$ . ara katman öğesinin çıktısı da net girdinin bir aktivasyon fonksiyonundan geçirilmesiyle hesaplanır. Geriye doğru hesaplama yapılırken kullanılan aktivasyon fonksiyonunun türevi alınacağı için burada türevi alınabilir bir fonksiyon seçmek gerekir (Öztemel, 2020, s.78).

#### 4.1.6 Geri beslemeli yapay sinir ağları

Geri beslemeli yapay sinir ağları denetimsiz öğrenme yöntemiyle çözülen problemlerde kullanılır. Bu ağlarda sinyal iletimi çıkış ve ara katmandan önceki katmanlara doğru yapıldığından geri beslemeli ağlar denir. Ağ belleğinde çıkışa ait o anki değer ve önceki değerler saklanır. Bu özelliğinden dolayı geri beslemeli ağlar tahmin problemlerinde kullanılır. Geciktirme unsuru ile geri besleme işlevi yapılır. Bu işlev aynı katmandaki öğeler ya da katmanlar arasında da yapılır. Geri beslemeli ağlarda geriye doğru hesaplama yapılırken ağına çıktı değeri ile hedef çıktı değeri hesaplanır. Aradaki farka hata denir. Amaç hatayı en küçük tutmaya çalışmaktır. Bütün hatalar toplanarak toplam hata değeri hesaplanır (Yılmaz, 2020, s.87).



**Şekil 4.6:** Geri Beslemeli Yapay Sinir Ağları

**Kaynak:** (Öztürk ve Şahin, 2018: s.32)

#### 4.1.7 Geri doğru hesaplama

Ağda üretilen çıktı değerleri (Ç1, Ç2 ...) ağın beklenen çıktı değerleri (B1, B2, ...) ile karşılaştırılır. Aradaki fark hata olarak ifade edilir. Bu değer en düşük seviyede tutulmaya çalışıldığından dolayı geriye doğru hesaplama yönteminde ağın ağırlık değerlerine yayılarak bir sonraki döngüde hata değerinin düşürülmesi sağlanmış olur. Çıktı katmanında bulunan  $m$ . Süreç ögesi için hata değeri:

$$E_m = B_m - \zeta_m \quad (4.6)$$

$E_m$ : Çıktı katmanındaki  $m$ . süreç ögesi için gerçekleşen hata değeri

$B_M$ : Çıktı katmanındaki  $m$ . süreç ögesi için beklenen çıktı değeri

$\zeta_m$ : Çıktı katmanındaki  $m$ . süreç ögesi için gerçekleşen çıktı değerini ifade eder.

Çıktı katmanındaki toplam hatayı bulmak için:

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (4.7)$$

$TH$ : Toplam hata denklem 4.7'deki formül kullanılır. Toplam hatayı en düşük seviyede tutmak için ögelerin ağırlığını değiştirmek gerekir. Bu işlem iki şekilde yapılır:

- **Ara Katman ile Çıktı Katmanı Arasındaki Ağırlıkların Değiştirilmesi:**

Herhangi bir  $t$ . Döngüdeki ağırlığın değişimi:

$$\Delta A_{jm}^a(t) = \lambda \delta_m \zeta_j^a + a \Delta A_{jm}^a(t-1) \quad (4.8)$$

$\Delta A_{jm}^a$  : Ara katmandaki  $j$ . süreç ögesini çıktı katmanındaki  $m$ . ögesine bağlayan bağlantının ağırlığındaki değişim miktarı

$\lambda$  : Öğrenme katsayısı

$a$  : Momentum katsayısı

$\delta_m$  :  $m$ . çıktı ünitesinin hatası

Denklem 4.8 de  $a$  ile ifade edilen momentum katsayısı ağın öğrenme sürecinde yerel bir optimum noktada kalmaması için ağırlık değişim değerinin

belirlenen bir oran ile bir sonraki deęişime eklenmesini sağlar.  $\delta_m$  ile ifade edilen deęer ise:

$$\delta_m = f'(NET) * E_m \quad (4.9)$$

$f'(NET)$  : Aktivasyon fonksiyonu türevi

Denklem 4.8 ile deęişim miktarı hesaplandıktan sonra aęırlıkların  $t$ . Döngüdeki yeni deęerleri:

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (4.10)$$

Bununla birlikte eşik deęerlerinin de deęişimini hesaplamak gerekir.

$$\Delta \beta_m^c(t) = \lambda \delta_m + a \Delta \beta_m^c(t-1) \quad (4.11)$$

$\Delta \beta_m^c(t)$ : Çıktı katmanındaki süreç öęelerinin eşik deęer aęırlıkları

Denklem 4. 11 ile eşik deęerlerinin deęişim deęerleri bulunur. Bu deęerlerin  $t$ . döngüdeki yeni aęırlık deęeri:

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta \beta_m^c(t) \quad (4.12)$$

- **Ara Katmanlar Arası Ya Da Ara Katman Giriş Katmanı Arasındaki Aęırlıkların Deęiştirilmesi**

Ara katman ile çıktı katmanı arasındaki aęırlıkların deęişimi için her aęırlıkta sadece çıktı katmanındaki bir süreç öęesinin hatası kullanılır. Bu hatanın oluşumunda önceki katmanlarda oluşan hataların katkısı vardır. Aęırlardaki deęişim deęeri:

$$\Delta A_{kj}^i(t) = \lambda \delta_j^a \zeta_k^i + a \Delta A_{kj}^i(t-1) \quad (4.13)$$

$\Delta A_{kj}^i$  :  $k$ . Girdi katmanı öęesini  $j$ . ara katman öęesine baęlayan baęlantının aęırlık deęişimi

Denklem 4.12 de girdi katmanından ara katman arasındaki aęırlık deęişim formülü verilmiştir. Bu formülde kullanılan  $\delta^a$  hata ifadesi:

$$\delta_j^a = f'(NET) \sum_m \delta_m A_{jm}^a \quad (4.14)$$

Hata değeri bulunduktan sonra denklem 4.12 kullanılarak değışim değeri bulunur. Ağırlıkların yeni değeri:

$$A_{kj}^i(t) = A_{kj}^i(t-1) + \Delta A_{kj}^i(t) \quad (4.15)$$

Ara katman eşik değeri ağırlıkları ( $\beta^a$ ) ise bunların değışimi:

$$\Delta \beta_j^a(t) = \lambda \delta_j^a + a \Delta \beta_j^a(t-1) \quad (4.16)$$

4.16 daki denklemde ara katman eşik değeri ağırlıklarının değışim formülü verilmiştir. Bu değışim değeri hesaplandıktan sonra ağırlıkların  $t$ . döngüdeki yeni değeri bulunur.

$$\beta_j^a(t) = \beta_j^a(t) + \Delta \beta_j^a(t) \quad (4.17)$$


Bu şekilde ağırlıklar değıştirilmiş olur (Öztemel, 2020, s.79).

## 4.2 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonu bir nöronun çıkış verip vermeme kararını veren fonksiyondur (Karakurt ve İşeri, 2022, s.196).

### 4.2.1 Adım aktivasyon fonksiyonu

Basamak fonksiyonu olarak da bilinir. Eşik değeri baz alarak 0 veya 1 değeri üretir. Eğer giriş değeri 0'dan küçükse 0 değeri, geri kalan bütün giriş değeri için 1 değeri üretir (Mehrotra, Mohan ve Ranka,1997, s. 12).



Şekil 4.7: Adım Aktivasyon Fonksiyonu


**Kaynak:** (Apicella, Donnarumma, Isgro ve Prevete, 2021: s. 19)

### 4.2.2 Doğrusal aktivasyon fonksiyonu

Doğrusal aktivasyon fonksiyonu girdi değeri ile orantılı çıktı değeri üretir.

$$f(x) = a \quad (4.18)$$

Denklem 4.17 de a değeri sabit bir sayıdır. X ise girişi verisini temsil eder. Fonksiyonun türevi sabittir (Sharma ve diğerleri, 2017, s.312).



Şekil 4.8: Doğrusal Aktivasyon Fonksiyonu


Kaynak: (Apicella, Donnarumma, Isgrò ve Prevete, 2021: s. 19)

### 4.2.3 Sigmoid aktivasyon fonksiyonu

Lojistik aktivasyon fonksiyonu olarak da adlandırılan sigmoid aktivasyon fonksiyonu bağımsız değişkenleri 0 ile 1 arasında olacak şekilde dönüşümlerini gerçekleştirir. Giriş değeri büyüdükçe türevi küçülür (Goodfellow, Bengio ve Courville, 2016, s.68).

$$y = \frac{1}{1+e^{-x}} \quad (4.19)$$

Denklem 4.18 de x girdi değerini y ise çıktı değerini ifade eder.



Şekil 4.9: Sigmoid Aktivasyon Fonksiyonu

Kaynak: (Çetin, Temurtaş ve Gülgönül, 2015: s.153)


#### 4.2.4 Hiperbolik tanjant aktivasyon fonksiyonu

Tanh aktivasyon fonksiyonu olarak da bilinir. Bu fonksiyon girişteki bağımsız değerleri -1,1 aralığında olacak biçimde dönüştürür (Turhan, Talu, 2022, s.91).

Hiperbolik tanjant fonksiyonunun sigmoid fonksiyonuna benzer bir yapısı vardır. Sigmoid fonksiyonundan farkı negatif giriş değerleri için de çıkış değeri üretmesi ve kaybolan eğim sorununa sahip olmasıdır (Heaton,2015, s.44).

$$y = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.20)$$

Denklem 4.19 da x girdi değerlerini y ise fonksiyonun ürettiği değerleri gösterir.




Şekil 4.10: Hiperbolik Tanjant Aktivasyon Fonksiyonu

Kaynak: (Sezer,.2007: s18)

#### 4.2.5 Relu aktivasyon fonksiyonu

Doğrultulmuş doğrusal ünite anlamına gelen RELU aktivasyon fonksiyonu negatif değerler için 0'dır ve pozitif değerler için doğrusal biçimde artmaktadır. Bu fonksiyonun avantajları hesaplaması kolay olması ve kaybolan eğim problemi olmamasıdır. Dezavantajları ise çıkış değerleri 0 merkezli değildir ve bununla birlikte negatif değerler için geriye geçişte eğim olmaz. Bundan dolayı ağırlık değerleri güncellenmez ve ağır öğrenmesi gerçekleşmez (Gulli ve Pal, 2017, s.15).

$$fx = \max(0, x) \quad (4.21)$$




**Şekil 4.11:** Relu Aktivasyon Fonksiyonu

**Kaynak:** (Apicella, Donnarumma, Isgrò ve Prevete,.2021: s. 19)

#### 4.2.6 Leaky Relu aktivasyon fonksiyonu

Relu aktivasyon fonksiyonunun negatif giriş değerleri için 0 çıkış değerini ürettiğinden ölü Relu olarak bilinir. Negatif giriş değerlerinin çok olması halinde katmanlardaki öğeler aktif hale gelemez. Bu problemi önlemek amacıyla Leaky Relu aktivasyon fonksiyonu geliştirilmiştir (Xu, Li, Du, Zhang ve Liu, 2020: s.2).

$$f(x) = \max(0.1x, x) \quad (4.22)$$




**Şekil 4.12:** Leaky Relu Aktivasyon fonksiyonu

**Kaynak:** (Varshney ve Singh,.2021: s.1325)

#### 4.2.7 Soft plus aktivasyon fonksiyonu

Leaky Relu aktivasyon fonksiyonunun istikrarsız sonuçlar vermesi üzerine Relu aktivasyon fonksiyonunu iyileştirme çalışmaları devam etmiştir. Relunun pürüzsüz versiyonu olarak kabul edilen Softplus aktivasyon fonksiyonu geliştirilmiştir (Patterson ve Gibson, 2017, s.70).

$$f(x) = \ln(1 + \exp(x)) \quad (4.23)$$




**Şekil 4.13:** Softplus Aktivasyon Fonksiyonu

**Kaynak:** (Emeksiz.,2023: s.596)

#### 4.2.8 Prelu aktivasyon fonksiyonu

Parametrik Relu aktivasyon fonksiyonu girişi değerlerini Leaky Relu nun sabit bir sayı ile çarpması yerine bir hiper parametre olan  $a$  değeri ile çarparak çıkış değeri üretir. Buradaki  $a$  hiper parametre değeri nöronlara negatif tarafta iyi bir eğim seçme yeteneği kazandırır (Ding, Qian ve Zhau,2018, s.1836).

$$f(x) = \max(ax, x) \quad (4.24)$$



**Şekil 4.14:** Prelu Aktivasyon Fonksiyonu


**Kaynak:** Salur, Aydın ve Karaköse.,2019: s.500)

#### 4.2.9 Elu aktivasyon fonksiyonu

Üstel doğrusal birimler olarak da adlandırılan elu aktivasyon fonksiyonu  $X$  değerlerinin 0'dan farklı olduğu durumlar için kullanılır.

$$f(x) = a(\exp(x) - 1) \quad (4.25)$$

Denklem 4.23 de  $a$  hiper parametre değeri olup negatif değerler için kaybolan gradyan etkisini azaltır. Elu aktivasyon fonksiyonu negatif değerlere sahip olduğundan aktivasyon ortalamalarını 0'a yaklaştırır. Bu ise ağıın eğitim hızını arttırırken gradyan inişini de takip eder (Clevert, Unterthiner ve Hochreiter, 2015, s.5).



**Şekil 4.15:** Elu Aktivasyon Fonksiyonu

**Kaynak:** (Lau ve Lim, 2018: s.688)

#### 4.2.10 Swish aktivasyon fonksiyonu

Swish aktivasyon fonksiyonu Google araştırmacılarınca 2017 de geliştirilmiştir. Görüntü sınıflandırma, nesne tespiti gibi konularda Relu ya göre daha iyi sonuçlar vermiştir.


$$y = \frac{x}{1+e^{-x}} \quad (4.26)$$

Denklem 4.24 de görüldüğü gibi Swish aktivasyon fonksiyonu girdi değerlerinin sigmoid aktivasyon fonksiyonu ile çarpılmasından elde edilmiştir. Bir  $\beta$  eğitim parametresi tanımlanarak Swish  $-\beta$  formu elde edilmiştir.

$$f(x, \beta) = 2x\sigma(\beta \cdot x) \quad (4.27)$$

Denklem 4.25 de Swish  $-\beta$  formunun formülü verilmiştir.

Swish aktivasyon fonksiyonu Relu ya benzemesine karşın negatif bölgede bir eğimli bölge oluşturur ve bu nöronu aktif hale getirir (Ramachandran, Zoph ve Le, 2017, s.5).



**Şekil 4.16:** Swish Aktivasyon Fonksiyonu


**Kaynak:** (Fatima ve Pethe.,2022: s.2)

#### 4.2.11 Softmax aktivasyon fonksiyonu

Bu fonksiyon sınıflandırma problemleri için çıktı katmanında kullanılır. Sigmoid fonksiyonuna benzer bir yapıya sahip olmakla beraber tek farkı çıktı değerlerinin 0 ile 1 aralığında normalize edilmesidir. İkili sınıflandırma için sigmoid, çoklu sınıflandırma için softmax kullanılır. Çıkan sonuçların hangi sınıfa ait olduğu belirlenir (Yılmaz ve Kaya, 2019, s.99).

$$\mathit{softmax}(z)_i = \frac{\exp(z_i)}{\sum_j \exp(z_j)} \quad (4.28)$$

Denklem 4.26 da  $z_i$  çıkış vektörünü,  $i$  örnek sayısını,  $j$  sınıf sayısını gösterir.



**Şekil 4.17:** Softmax Aktivasyon Fonksiyonu

**Kaynak:** (Çırak.,2019: s.222)

### 4.3 Kayıp Fonksiyonları

Kayıp fonksiyonu kayıp fonksiyonu veya maliyet fonksiyonu olarak da bilinir. Kayıp fonksiyonu sinir ağında yapılan hatayı hesaplar. Sinir ağındaki eğitim verilerinin ne kadar iyi modellendiğini ölçer (Goodfellow, Bengio ve Courville, 2016, s.82).

#### 4.3.1 Ortalama karesel hata

Regresyon problemlerinde kullanılır. Gerçek değerler ile tahmin edilen değerlerin farklarının karesinin ortalamasını hesaplar (Taşar, 2018, s.546).

$$okH = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n} \quad (4.29)$$

Denklem 4.27 de  $n$  veri sayısını,  $Y_i$  gerçek değeri,  $\hat{Y}_i$  tahmin edilen değeri göstermektedir.

#### 4.3.2 Mutlak hatalar ortalaması

Regresyon problemlerinde kullanılır. Tahmin edilen değerler ile gerçek değerlerin mutlak farkları alınarak hesaplanır (Aydemir, 2019, s.72).

$$mho = \frac{\sum_{i=1}^n |Y_i - \hat{Y}_i|}{n} \quad (4.30)$$

#### 4.3.3 Log-Cosh kayıp fonksiyonu

Bazı makine öğrenmesi algoritmalarında kullanılan bu fonksiyon veri kümesindeki aykırı değerlere daha toleranslıdır (Saleh ve Saleh, 2022, s.3).

$$\log - \cosh \text{ kaybı} = \log(\cosh(Y_i - \hat{Y}_i)) \quad (4.31)$$

#### 4.3.4 Log Loss kayıp fonksiyonu

Çapraz entropi kayıp fonksiyonu olarak da bilinir. Tahmin edilen olasılıkları gerçek değerler ile karşılaştırır. Sınıflandırmadan çok sınıfa ait olma olasılığının ön planda olduğu problemlerde kullanılır (Gordon-Rodriguez, Loaiza-Ganem, Pleiss ve Cunningham, 2020, s.1).

$$\text{logloss} = -\frac{1}{N} \sum_{i=1}^N (Y_i \log(\hat{Y}_i) + (1 - Y_i) \log(1 - \hat{Y}_i)) \quad (4.32)$$

#### 4.3.5 Dengeli çapraz entropi

Dengesiz sınıf dağılımlarına sahip veri kümelerinde kullanılır (Lin, Goyal, Girshick, He ve Dollar, 2017, s.2982).

$$d_{\text{çp}} = -\frac{1}{N} \sum_{i=1}^N (\beta Y_i \log(p_i) + (1 - Y_i) \log(1 - p_i)) \quad (4.33)$$

Denklem 4.31 de N veri sayısını,  $\beta$  dengelenme faktörünü,  $Y_i$  gerçek değeri,  $p_i$  tahmin edilen değeri gösterir.

#### 4.3.6 İkili çapraz entropi

İkili sınıflandırma problemlerinde kullanılır. Bu fonksiyon gerçek değerler ile tahmin edilen değerler arasındaki çapraz entropi kaybını hesaplar (Güçlü, 2022, s.52).

$$i_{\text{çp}} = -y \log p + (1 - y) \log(1 - p) \quad (4.34)$$

Denklem 4.32 de y sınıf etiketini (0 ya da 1), p ise tahmin edilen değeri ifade eder.

#### 4.3.6 Kategorik çapraz entropi

Çoklu sınıflandırma problemlerinde kullanılır. Bu fonksiyon gerçek değerler ile tahmin edilen değerler arasındaki çapraz entropi kaybını hesaplar (Dikici ve Altuntaş, 2023, s.100).

$$k_{\text{çe}} = - \sum_{i=1}^N \sum_{j=1}^C Y_{ij} \log(p_{ij}) \quad (4.35)$$

Denklem 4.33 de N veri sayısını, C sınıf sayısını,  $Y_{ij}$  i. Verinin j. Sınıfa ait gerçek etiketini,  $p_{ij}$  ise i. Verinin j. Sınıfa ait olma olasılığını ifade eder.

#### 4.3.7 Seyrek kategorik çapraz entropi

Çoklu sınıflandırma problemlerinde her bir veri sadece bir sınıfa aitse bu fonksiyon kullanılır (Salouhou, 2019, s.28).

$$s_{\text{cc}} = -\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^k y_i^j \log(\hat{y}_i^j) \quad (4.36)$$

Denklem 4.34 de seyrek kategorik çapraz entropi fonksiyonu gösterilmiştir. Burada  $\hat{y}_i^j$  İ. verinin J. Sınıfa ait olduğunun öngörülen etiketini gösterir.  $y_i^j$ , İ verinin gerçekten J sınıfa ait olduğunu gösterir.

#### 4.4 Optimizasyon Fonksiyonları

Optimizasyon bir sistem veya işlemin belirli bir amaca veya hedefe en iyi şekilde ulaşmasıdır. Derin öğrenmede ise sinir ağının ağırlık ve öğrenme hızı gibi özelliklerini optimize etmek için optimizasyon fonksiyonları kullanılır (Ünal, 2022, s.69).

##### 4.4.1 Gradyan iniş

Makine öğrenmesinde ve yapay sinir ağlarında iteratif numerik çözümler üretebildiği için kullanılan algoritmalarından biridir. Bu algoritma model parametrelerinin güncellenmesi esnasında öğrenme hatasını azaltır (Yağmur, 2020, s.8).

##### 4.4.2 Yığın gradyan iniş

Her döngüde parametre güncellemek için veri seti üzerinde çalışır. Bu yüzden yavaş çalışır (Ayavah ve diğerleri,2022, s.7).

$$w = w - a\nabla_w J \quad (4.37)$$

Denklem 4.35 de  $w$  model parametrelerini,  $a$  öğrenme hızını,  $\nabla_w J$  ise gradyan vektörünü ifade eder.

##### 4.4.3 Stokastik gradyan iniş

Bu algoritma bütün veri seti üzerinde çalışmak yerine veri setinin rastgele bir kısmını işleyerek ağırlıkları günceller (Seyyarer, Ayata, Uçkan ve Karcı, 2020, s.93).

$$w = w - a\nabla_w J(x^i, y^i; w) \quad (4.38)$$

Denklem 4.36 da  $w$  model parametrelerini,  $a$  öğrenme hızını,  $\nabla_w J$  gradyan vektörünü,  $x^i$  eğitim örneğini,  $y^i$  ise etiket değerini gösterir.

#### 4.4.4 Mini yığın gradyan iniş

Başarılı olarak kullanılan gradyan iniş yöntemidir. Skolastik gradyan iniş de her turda bütün veriler işleme tabi tutulduğundan eğitim sürecini tamamlamak zaman alır. Yığın gradyan iniş ise büyük veri setlerinde kullanılmaz. Bu iki yöntemin ortasını bulan mini yığın gradyan iniş metodu makine öğrenmesi algoritmalarında genellikle tercih edilir (Zhang, Lipton, Li ve Smola, 2021, s.518).

$$w = w - a \nabla_w J(x^{i:i+b} + y^{i:i+b}; w) \quad (4.39)$$

Denklem 4.37 de  $w$  model parametrelerini,  $a$  öğrenme hızını,  $\nabla_w J$  gradyan vektörünü,  $x^i$  eğitim örneğini,  $y^i$  etiket değerini,  $b$  mini yığın veri sayısını gösterir.

#### 4.4.5 Momentumlu gradyan iniş

Öğrenme hızı küçük seçildiğinde modelin öğrenme süreci uzar. Bu parametre büyük seçildiğinde ise model en küçük değer etrafında salınım yapar. Bu sorunu engellemek için geliştirilen modele momentum adı verilen bir parametre eklemiştir. Algoritmanın sorunsuz çalışması için bu değer doğru seçilmelidir (Ruder,2016, s.4).

$$v_t = Y v_{t-1} + a \nabla_w J(w) \quad (4.40)$$

$$w = w - v_t \quad (4.41)$$

Denklem 4.38 ve 4.39 da  $v_t$  parametre değişme miktarını,  $v_{t-1}$  önceki değişme miktarını,  $Y$  momentum katsayısını,  $w$  model parametrelerini,  $\nabla_w J$  gradyan vektörünü ifade eder.

#### 4.4.6 Adagrad

Uyarlanmış gradyan algoritması da denilir. Diğer optimizasyon algoritmalarında öğrenme hızı sabittir. Bu algoritma modelin eğitim süreci boyunca bütün adımları izler ve öğrenme hızını sürekli ayarlar (Zeiler,2012, s.2).

$$W_{t+1,i} = W_{t,i} - \frac{a}{\sqrt{G_{t,i} + \epsilon}} * g_{t,i} \quad (4.42)$$

$$g_{t,i} = \nabla_w J(w_{t,i}) \quad (4.43)$$

Denklem 4.40 ve 4.41 de  $g_{t,i}$  t anında  $W_i$  ağırlık parametresine göre hesaplanan maliyet fonksiyonunun eğimini,  $G_{t,i}$  t. iterasyona kadar hesaplanmış gradyan karelerinin toplamını,  $a$  öğrenme hızını,  $\epsilon$  öğrenme hızının 0'a bölünmediğinden emin olmak için atanan ve değeri genel olarak  $10^{-8}$  olan sabit bir sayıyı gösterir.

#### 4.4.7 AdaDelta

Adagrad algoritmasının gelişmiş bir versiyonu olan bu algoritma önceki gradyanların tümünü toplamak yerine sadece dar bir kesit alınarak paydanın büyümesi engellenmiştir. Bu şekilde öğrenme ilerlemesi sürer. Adagrad da baş gösteren öğrenme hızının giderek azalması problemine karşı geliştirilmiştir (Zeiler,2012, s.3).

$$E[g^2]_t = \gamma E[g^2]_{t-1} + (1 - \gamma)g_t^2 \quad (4.44)$$

$$w_{t+1,i} = w_{t,i} - \frac{a}{\sqrt{E[g^2]_t + \epsilon}} * g_{t,i} \quad (4.45)$$

Denklem 4.42 ve 4.43 de  $E[g^2]_t$  geçmiş eğitim değerlerinin karelerinin bozulan ortalamasını,  $g_t^2$  t anında  $w$  parametresine göre hesaplanana maliyet fonksiyonunun karesini,  $\gamma$  momentum katsayısını gösterir.

#### 4.4.8 RMSprop

Geoff Hinton tarafından önerilmiş ancak yayınlanmamış bir öğrenme katsayısı uyarlama şeklidir. Adagrad meydana gelen öğrenme hızının zamanla azalmasına çözüm olarak aynı zamanda ve birbirinden bağımsız olarak Adadelta ile birlikte geliştirilmişlerdir. Bu algoritma dikey yöndeki salınımları sınırlı hale getirir (Ruder,2016, s.7).

$$w_{t+1,i} = w_{t,i} - \frac{a}{\sqrt{E[g^2]_t + \epsilon}} * g_t \quad (4.46)$$

$$E[g^2]_t = 0,9 * E[g^2]_{t-1} + 0.1 * g_t^2 \quad (4.47)$$

#### 4.4.9 ADAM

Uyarlanmış momentum tahmini olarak da bilinen bu algoritma her parametre için uyarlanabilir öğrenme katsayısını hesaplar (Kingma ve Ba 2014, s.1).

RMSProp ve Momentumlu gradyan iniş algoritmalarının faydalı yönlerini bir araya getirilmesiyle geliştirilmiş bir algoritmadır (Seyyarer ve diğerleri, 2020, s.94).

$$m_t = \beta_1 * m_{t-1} + (1 - \beta_1) * gt \quad (4.48)$$

$$v_t = \beta_2 * v_{t-1} - (1 - \beta_2) * gt^2 \quad (4.49)$$

$$\hat{v}_t = \max(\hat{v}_{t-1} - v_t) \quad (4.50)$$

$$w_{t+1,i} = w_t - \frac{a}{\sqrt{\hat{v}_t + \epsilon}} * m_t \quad (4.51)$$

Denklem 4.46,4.47,4.48 ve 4.49 da  $\beta_1$  ve  $\beta_2$  değeri 0 ile 1 arasında değişen hiperparametreleri,  $v_t$  önceki karesel gradyanların üssel azalan ortalamasını,  $m_t$  gradyanların ikinci momentlerinin ortalamasını gösterir.

## 4.5. Hiperparametreler

Makine öğrenmesinde modelin girdileri parametre olarak adlandırılır. Performansı etkileyen yapılandırma ayarları hiperparametre olarak bilinir (Patterson, Gibson. 2017, s.102).

### 4.5.1 Öğrenme katsayısı

Yapay sinir ağlarının eğitiminde öğrenme hızı atılan adımı ifade eder. Öğrenme katsayısı ise ağın öğrenmesi sırasında işlemin her tekrarı için ağırlıkların güncellenmesi anlamına gelmektedir. Öğrenme katsayısının yüksek olması daha hızlı ve daha çok şey öğrenme anlamına gelmez. Bu katsayının yüksek olması modelin sürekli olarak en küçük nokta etrafında dolaşması ve asla en küçük noktaya ulaşamaması demektir. Bu katsayının küçük seçilmesi de algoritma ilerlemesini yavaşlatacağından en düşük noktayı bulmak için iterasyon sayısı artacaktır (Michelucci, 2018, s.52).

### 4.5.2 Mini yığın boyutu

Sinir ağı hesaplamasını hızlandırmak için kullanılır. Bu şekilde gradyan eğimi hesaplanır. Yığın boyutu arttıkça modelin işleyeceği veri artacağından daha fazla belleğe ihtiyaç olacaktır. Bellek artırımı işlemciye fazladan iş anlamına geldiğinden ağın eğitim süresi uzar. Bu ve benzeri sorunlara engel olmak için veri setindeki

veriler modele küçük gruplar halinde gönderilir. Böylece her grup için gradyan hesaplanır ve ağırlıklar güncellenir. Burada grup sayısı kadar ağırlıklar güncellendiğinden modelden hızlı sonuç olma söz konusu olur. Bu grupta kaç veri olacağına mini yığın parametresi ile karar verilir (Lewis,2016, s.55).

#### **4.5.3 Çevrim sayısı**

Derin öğrenme algoritmalarında hata fonksiyonunun türevi negatif ise ağırlık artar, pozitifse ağırlık azalır. Ağın eğitimi sırasında her bir güncellemeye iterasyon denir (Lewis,2016, s.20).

Verilerin eğitim aşamasında geriye yayılım ile ağırlıklarının güncellendiği her bir iterasyona çevrim denir. Ağırlık değerleri ilk iterasyonda belirlendiği için bu esnada doğruluk değeri düşük olacaktır. İterasyon sayısı arttığında ağırlıklar güncelleneceğinden doğruluk değeri artacaktır (Michelucci, 2018, s.114).

#### **4.5.4 Gizli katman sayısı**

Derin öğrenme mimarilerinde katman sayısının en elverişli düzeyde tutulması gerekir. Gizli katman sayısı ise çalışılan probleme göre gereken sayıda belirlenmelidir (Bengio,2009, s.6).

#### **4.5.5 Gizli katmandaki nöron sayısı**

Giriş katmanındaki nöron sayısı giriş vektöründeki değişken sayısına eşittir. Çıkış katmanında ise tek çıkış için tek bir nöron ya da probleme özel istenilen sınıf sayısının gerektirdiği sayıda nöron olacaktır.

Gizli katmanlardaki nöron sayıları denemeler yapılarak bulunabilir. Katmandaki nöron sayısının fazla olması ağın verileri anlamasını kolaylaştıracağından ağın başarısı artar.

Girdi verisi ne kadar çok ise ilk gizli katmanda gereken nöron sayısı da o kadar çoktur. Bu durum çıkış katmanı için de geçerlidir (Ünal, 2022,102).

#### **4.5.6 Ağırlıklara başlangıç değerleri atama**

Bir sinir ağı tasarlanırken ağırlıklara başlangıç değerleri doğru şekilde atanırsa bu durum ağın en kısa zamanda doğru sonuçlar vereceğine işaret eder. Aksi durumda gradyan inişini kullanarak bir en küçük hataya yaklaşıma gerçekleşmez.

Ağırlıklara büyük başlangıç değerlerini atama ağın aşırı öğrenmesine, küçük başlangıç değerleri atamak ise ağın hiçbir şey öğrenmemesine neden olur (Ünal,2022, s.105).

### **4.6 Derin Öğrenme Mimarileri**

#### **4.6.1 Tekrarlayan sinir ağları (TSA)**

Sıralı verilerin analizi, sınıflandırması ve işlenmesi amacıyla kullanılan tekrarlayan sinir ağları sıkça başvurulan derin öğrenme modellerindendir. Bu modelde önceki katmanlardan gelen bilgileri bellekte tutma özelliğine sahip olduğunda bilginin sürekliliği sağlanmış olur. Tekrarlayan sinir ağları doğal dil işleme, duygu sınıflandırılması, video sınıflandırılması gibi alanlarda kullanılır (Elmas, 2021, s.233).

#### **4.6.2 Uzun -kısa süreli hafıza**

Sıralı verilerin modellenmesi amacıyla kullanılan bu model tekrarlayan sinir ağlarının bir çeşididir (Kara, 2019, s.885).

Bu ağ mimarisi hücrelerden oluşmaktadır. Bu mimari giriş, çıkış, unutma/hatırlama kapıları sayesinde bilginin önemli olup olmamasına göre kaydedilmesine karar verirler. (Latifoğlu ve Nuralan,2020, s.378).

#### **4.6.3 Kısıtlı boltzman makinesi**

1986 yılında Hinton ve arkadaşları tarafından önerilen ve veri seti üzerinden olasılık dağılımlarını öğrenebilen bu yapı sınıflandırma, regresyon, özellik öğrenme gibi işlevleri yapabilme özelliğine sahiptir. Bu sayede değişkenler arası olasılık ilişkilerinin modellenmesinde kullanılır (Yılmaz ve Kaya, 2019, s.36).

#### 4.6.4 Derin inanç ağı

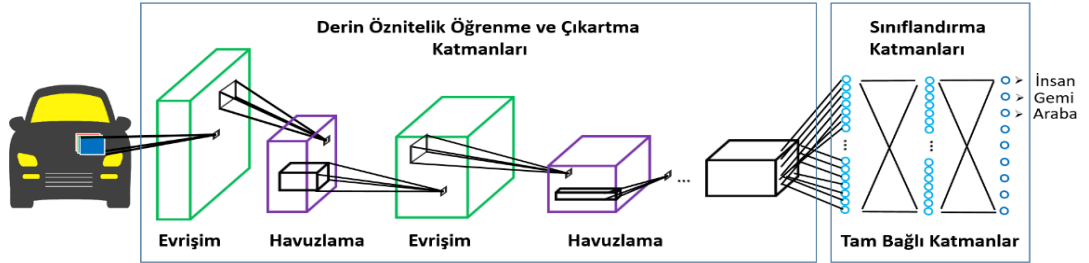
Hinton ve arkadaşları tarafından birden fazla kısıtlı Boltzman makinesinin ve tam bağlı yapay sinir katmanlarının arka arkaya eklenmesiyle oluşturulmuştur. Nesne, yüz ve video tanıma, hareket algılama gibi alanlarda kullanılır (Elmas, 2021, s.249).

#### 4.6.5 Derin oto kodlayıcılar

Denetimsiz öğrenmeyi kullanan bu mimari eğitim aşamasında etiketli veri kullanmaz. Derin oto kodlayıcılarda ön eğitim vardır. Eğitim işlemi hataların kaybolmasından dolayı kayıp yaşanabilmektedir. Yüz tanıma, konuşma tanıma, sinyalde gürültü temizleme gibi alanlarda kullanılır (Yılmaz ve Kaya, 2019, s.35).

#### 4.6.6 Evrişimli sını ağı (ESA)

Evrişimli sinir ağı (ESA) birden fazla sayıda katmandan oluşan, bir nesneyi diğerinden ayırabilen bir derin öğrenme mimarisidir ve genel olarak görüntü verilerine bu yöntem uygulanır. Bu model; obje tespiti, görüntü verisi sınıflandırma ve analizi vb. alanlarda kullanılmaktadır ve görüntü uygulamaları arasında en başarı ve en çok kullanılan derin öğrenme yöntemidir (Akbulut ve Aslantaş, 2023, s.1442).

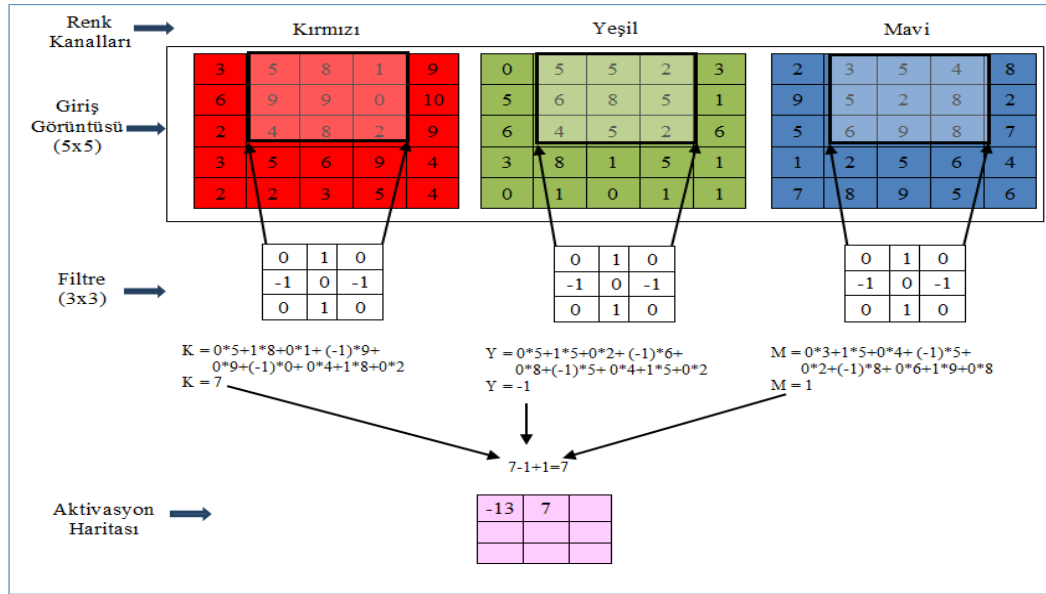


Şekil 4.18: ESA Mimarisi

Kaynak: (Hanbay, 2020: s.607)

##### 4.6.6.1 Evrişim katmanı

Bu katmanda görüntü verilerinin öznitelikleri belirlenir. Yeni bir matris elde edilir. Bu matrise öznitelik matrisi denir. Evrişim işlevi için görüntü verisi üzerinde önceden tespit edilmiş filtre, adım sayısı kadar kaydırılır ve görüntü verisi üzerinde gezdirilir. 3 renk kanallı bir görüntü verisinde kanallar için ayrı ayrı hesap edilen değer toplanıp çıkış değeri bulunur (İnik ve Ülker, 2017, s.89)



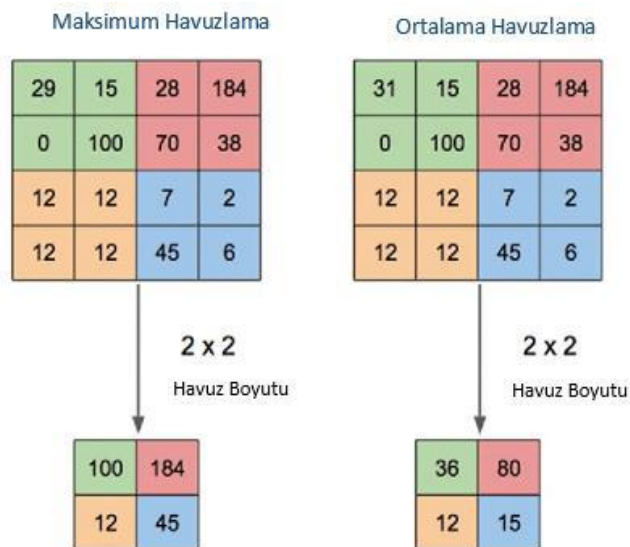
Şekil 4.19: 5X5X3 Giriş Matrisine 3x3x3 Filtre ile Evrişim

Kaynak: (Ülker,.2017: s.90)

#### 4.6.6.2 Havuzlama katmanı

Verilerin öznitelikleri korunarak boyutunun küçültüldüğü katmandır. Genellikle iki çeşit havuzlama kullanılır:

- **Maximum Havuzlama:** Uygulanan filtrenin matriste gördüğü en büyük değer
- **Ortalama Havuzlama:** Uygulanan filtrenin matriste gördüğü değerlerin ortalaması (Uysal, 2020, s.10).




Şekil 4.20: Havuzlama Çeşitleri

Kaynak: (Yani, Budhi Irawan ve Casi Setiningsih,.2019: s.3)

#### 4.6.6.3 Tam bağı katman

Görüntü verisi ESA modelinde birçok katmandan geçerek çok boyutlu matris halinde bu katmana gelir. Matrisimiz bu katmanda tek boyutlu bir matris haline getirilir. Bu işleme düzleştirme denir. Sınıflandırma işleminin yapıldığı katmandır (Öznel, 2018, s.43).



Şekil 4.21: Tam Bağlı Katman


Kaynak: (Msonda, 2020: s.22).

#### 4.6.6.4 Regülasyon

Evrışimli sinir ağı modellerinde kullandığımız model eğitim sırasında veri setini overfitting (uyum gösterme) ezberleyebilir ya da underfitting (yetersiz uyum) veri setine uyum sağlayamayabilir. Bu nedenle başarıyı iyileştirme teknikleri kullanılır. Bunlardan biri de dropout (seyreltme) yöntemidir (Özaydın, 2022, s.25).

##### 4.6.6.4.1 Seyreltme

Yapay sinir ağı eğitiminde model belirli bir aşamadan sonra eğitim verisini ezberler. Drop out işlemi katmandaki sinir hücrelerinin bir kısmının geçici olarak ağdan çıkarılması ile yapılır. Bu aşamada bu nöronlara giren ve o nöronlardan çıkan bağlantıların tamamı ortadan kaldırılır. Hangi nöronların modelden geçici olarak çıkarılacağı rastgele olarak seçilir (Srivastava, Hinton, Krizhevsky, Sutskever ve Salakhutdinov, 2014, s.1930).




**Şekil 4.22: Seyreltme İşlemi**

**Kaynak:** (Srivastava, Hinton, Krizhevsky, Sutskever ve Salakhutdinov, 2014: s.1930)

#### 4.6.6.5 Evrişimli sinir ağı (ESA) mimarileri

##### 4.6.6.5.1 LeNet-5

Bu mimari 1998 yılında Yann LeCun ve arkadaşları tarafından posta kodu ve banka çeklerindeki rakamları ayırt etmek için geliştirilmiştir. El yazısı tanımda bu mimari oldukça başarılı sonuçlar vermiştir. Lenet-5 ağı giriş katmanı, peş peşe konmuş evrişim katmanı, ortalama havuzlama katmanı, evrişim katmanı, tam bağlantılı katman ve çıkış katmanından oluşmaktadır. Aktivasyon fonksiyonu olarak RELU ve tam bağlı katmanda sınıf sayısını belirlemek için softmax kullanılmıştır (Fırat ve Hanbay, 2022, s.524).




**Şekil 4.23: Lenet -5 Mimarisi**

**Kaynak:** (LeCun, Bottou, Bengio ve Haffner, 1998: s. 2283)

##### 4.6.6.5.2 AlexNet

AlexNet, Alex Krizhevsky ve arkadaşları tarafından 2012 de yapılan ILSVRC-2012 görüntü sınıflandırma yarışmasını kazanmış bir evrişimli sinir ağı modelidir. Model, ImageNet veri kümelerindeki 1000 farklı görüntüyü sınıflandırmıştır. Giriş verileri 224x224 boyutlarında ayarlanır. AlexNet 5 adet evrişim ve 3 adet tam bağlı katmandan oluşur. Aktivasyon fonksiyonu olarak RELU kullanılmıştır (Krizhevsky, Sutskever ve Hinton, 2012, s.4).

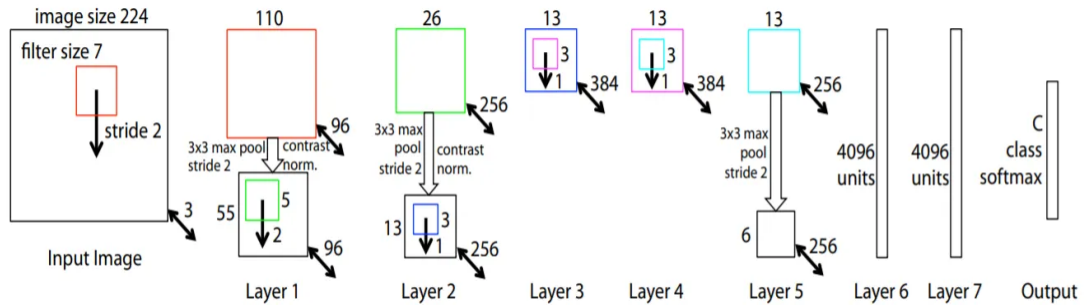


**Şekil 4.24:** AlexNet Mimarisi

**Kaynak:** (Krizhevsky, Sutskever ve Hinton,.,2012: s.5)

#### 4.6.6.5.3 ZFNet

Matthew Zeiler ve Rob Fergus tarafından geliştirilmiştir.2013 de ILSVRC-2013 görüntü sınıflandırma yarışmasını kazanmış bir evrişimli sinir ağı modelidir. AlexNet mimarisine benzemektedir. ZFNet 8 katmandan oluşur,224x224 boyutlarında giriş verisi kabul eder. Aktivasyon fonksiyonu olarak RELU kullanılmıştır (Zeiler, Fergus,2014, s.825)



**Şekil 4.25:** ZFNet Mimarisi

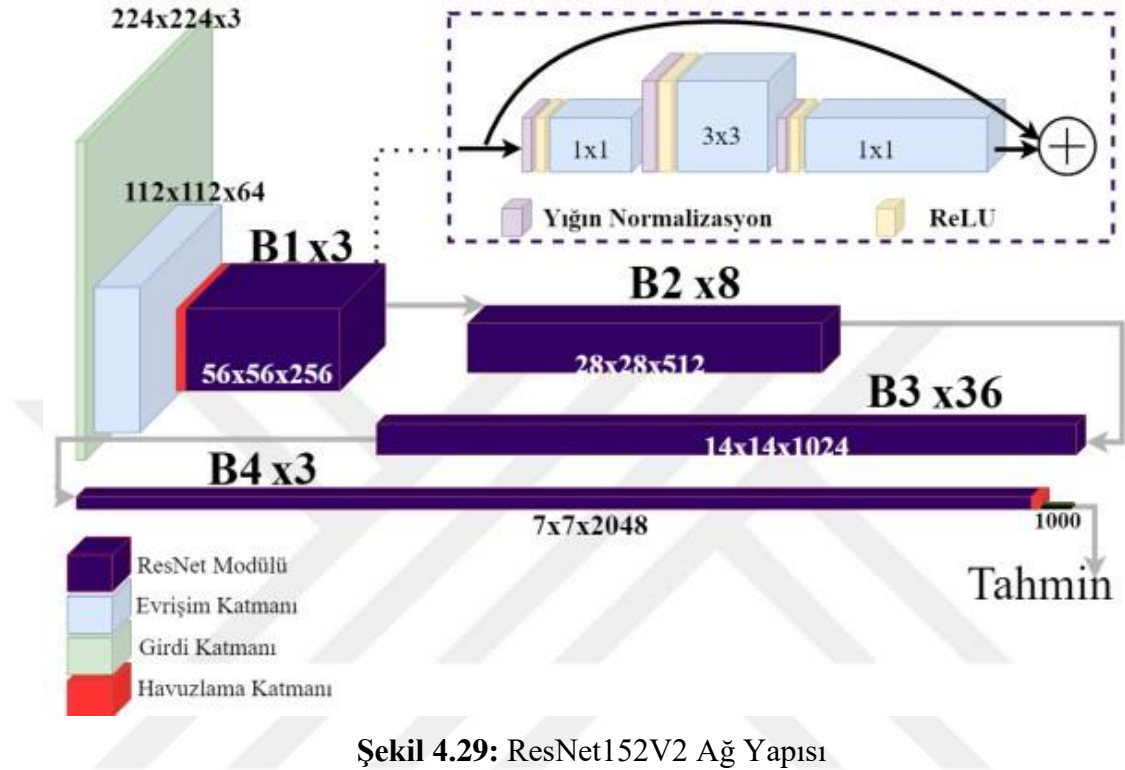
**Kaynak:**( Zeiler ve Fergus,.,2014: s.825)

#### 4.6.6.5.4 GoogleNet

Google çalışanlarından Christian Szegedy ve arkadaşları tarafından yapılan ve 2014 de ILSVRC-2014 görüntü sınıflandırma yarışmasını kazanmış bir evrişimli sinir ağı modelidir. Ağın en önemli özelliği inception modülü adı verilen küçük ağların kullanılmasıyla parametre sayısının azaltılmış olmasıdır. Bu modüllerden 9 tane vardır ve mimari 22 katmandan oluşmaktadır. Bu modüller değişik boyutlardaki filtreler ile oluşturulan evrişim ve havuzlama katmanlarından oluşur (Szegedy ve diğerleri,2015, s.5).




Resnet'e ait çeşitli versiyonlar vardır. Resnet152v2 bunlardan biridir. Bu model dört blok ve 152 katmandan oluşmaktadır. Her blokta 3 adet evrişim katmanı vardır. Tam bağlı katmanda 1000 adet nöron bulunmaktadır (Kural,2022, s.28).



#### 4.6.6.5.6 VGG16

VGG16, Oxford Üniversitesi'nden Karen Simonyan ve Andrew Zisserman tarafından önerilen 16 katmanlı bir Evrişimsel Sinir Ağı (CNN) modelidir. 2014 yılında, Image Net Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) 1000 sınıfa ait 14 milyondan fazla görüntüden oluşan bir veri tabanında, %92,7 sınıflandırma başarımlarını sağlamıştır. Ağa RGB formatında gönderilen veriler iki kez  $3 \times 3$ 'lük evrişim katmanı sonrasında, 3 kez  $3 \times 3$ 'lük evrişim katmanından geçirilir. Her evrişim ve RELU işleminden sonra  $2 \times 2$ 'lik maksimum havuzlama işlemi yapılır. Sonrasında sırasıyla birincisi ve ikincisi 4096 nörona sahip olan ve üçüncüsü 1000 nörona sahip tam bağlantı katmanından geçirilir ve softmax ile sınıflandırma işi yapılmış olur (Simonyan ve Zisserman, 2014, s.3).




**Şekil 4.30: VGG16 Ağ Yapısı**

**Kaynak:** (Shi ve diğerleri,2018: s.4)

#### 4.6.6.5.7 VGG19

VGG19 modeli, 2014 yılı ImageNet yarışmasında %9 ‘luk hata oranı elde etmiştir.19 katmandan oluşmaktadır. VGG19 mimarisi, sırasıyla evrişim ve maksimum havuzlama katmanları ile tam bağlantılı katmanlardan oluşur. VGG ağlarının ana özelliği, sürekli olarak 3x3 evrişim filtrelerinin kullanılmasıdır. Ayrıca, 2x2 boyutunda olan maksimum katmanları da kullanılır. Son olarak 2 adet 4096 nörona ve 1 er adet 1000 nörona sahip tam bağlı katman vardır (Nguyen ve diğerleri, 2022, s.875).



**Şekil 4.31: VGG19 Ağ Yapısı**

**Kaynak:** (Nguyen ve diğerleri,2022: s.875)

### 4.7 Öğrenme Aktarımı

Normal koşullar altında bir yapay sinir ağının eğitimi zaman alır ve sonuç almakta her zaman mümkün olmaz. Bu durum ele alınan problemin sil baştan gözden geçirilmesi anlamına gelmektedir. Öğrenme aktarımı bir iş, bir problem için eğitilmiş yapay sinir ağı modelinin başka bir görev için kullanıldığı yöntemdir. Bu sayede adapte edilen iş için daha kısa zamanda işi bitirme ve istenilen sonucu alma imkânı sağlanmış olur (Kaya ve diğerleri,2019, s.22).

## 4.8 Performans Değerlendirme Kriterleri

Derin öğrenme modellerinde modellerin birbirleriyle karşılaştırılması için çeşitli değerlendirme kriterleri vardır.

### 4.8.1 Hata matrisi

Bu matrise karışıklık matrisi de denir. Modelde eğitilen eğitim verileri ile test verilerinin sınıflandırma işlemi sonuçları karşılaştırılır.

Çizelge 4.3: Hata Matrisi

		Pozitif	Negatif
		TP	FN
Gerçek Değerler	Pozitif	TP	FN
	Negatif	FP	TN

### Tahmini Değerler

Kaynak: (Valero-Carreras, Alcaraz ve Landete,.,2023: s.4)

Bu matrisin öğeleri:

- **Gerçek Pozitif (True Positive):** Pozitif olan gerçek verinin sınıfı ile tahmin edilen sınıfın aynı olmasını gösteren durumdur.
- **Gerçek Negatif (True Negative):** Negatif olan gerçek verinin sınıfı ile tahmin edilen sınıfın aynı olmasını gösteren durumdur.
- **Yanlış Pozitif (False Positive):** Negatif olan gerçek verinin, tahmin sınıfının pozitif olmasını gösteren durumdur.
- **Yanlış Negatif (False Negative):** Pozitif olan gerçek verinin, tahmin sınıfının negatif olmasını gösteren durumdur.

### 4.8.2 Doğruluk (Accuracy)

Model hakkında en genel yargıya vardığımız bir değerlendirme parametresidir. Kullanılan veri sayısından kaç tanesinin doğru olarak sınıflandırıldığını verir.

$$\text{Doğruluk} = \frac{(TP + TN)}{TP + TN + FP + FN}$$

#### 4.8.3 Kesinlik (Precision)

Sınıflandırılan verilerin gerçekte o sınıfta olup olmadığını verir.

$$\text{Kesinlik} = \frac{TP}{FP + TP}$$

#### 4.8.4 Duyarlılık (Recall)

Sınıflandırılan verilerin ne kadarının doğru sınıflandırıldığını verir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN}$$

#### 4.8.5 F1 Score

F1 Score kesinlik ve duyarlılık parametrelerinin çarpımlarının toplamına oranının iki katı alınmasıyla veya kesinlik ve duyarlılık parametrelerinin harmonik ortalamasının alınmasıyla hesaplanır.

$$F1\ Score = 2 * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık}$$


## 5. UYGULAMA

Bu bölümde, tez kapsamında kullanılan veri setinin detayları, veri setinde bulunan görüntülerin ön işlenmesi, oluşturulan modelin özellikleri ve yapılan çalışmanın görsel uygulaması üzerinde durulmuştur. Bu çalışmada kullanılan veriler sıralı veri olmadığından, evrişimli sinir ağları ile daha önce yapılmış çalışmalar (Akbulut ve Aslantaş,2023; Şeker, Diri ve Balık, 2017; Şeker,2017; Atlan ve Pençe,2021) bu mimarinin daha başarılı olduğunu gösterdiğinden evrişimli sinir ağları, her bir veri sadece bir sınıfa ait olduğundan ve (Çiftçi ve Üzülmez,2023) seyrek kategorik çapraz entropinin kategorik çapraz entropiye göre daha başarılı olduğundan kayıp fonksiyonu olarak seyrek kategorik çapraz entropi tercih edilmiştir. Çalışma python programlama dili kullanılarak yapılmıştır.

### 5.1 Veri Seti Ön İşlemler

Bu tez çalışmasında eğitim ve test için;

<https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset> adresindeki veri seti kullanıldı. Veri setleri beyin MR görüntüleri içermektedir.



Şekil 5.1: Veri Setinde Bulunan Beyin MR Görüntü Örnekleri

İlk adımda görüntüler etiketlerine göre gruplandırılarak, dosya tipleri .jpeg uzantılı olacak şekilde kaydedilmiştir. Bu suretle görüntülerin bit sayısı azaltılarak,

yapılacak olan işlemlerin donanımsal kısıtlamalara takılmadan hızlı bir şekilde ilerlemesi amaçlanmıştır.


Çizelge 5.1 de görüldüğü üzere veri seti üç adet tümör tipini içeren beyin MR görüntüsü ve bir adet de tümör olmayan beyin MR görüntüsü olan 4 adet sınıftan oluşur. Veri setinde 1861 adet glioma tümörlü beyin MR görüntüsü,1895 adet meningioma tümörlü beyin MR görüntüsü,2007 adet pituitary tümörlü beyin MR görüntüsü,2250 adet tümör olmayan beyin MR görüntüsü olmak üzere toplamda veri setinde 8013 adet beyin MR verisi vardır

**Çizelge 5.1:** Veri Setindeki Verilere Ait Bilgiler

SINIF	EĞİTİM	TEST
Glioma Tümör	1311	300
Meningioma Tümör	1339	306
Pituitary Tümör	1457	300
No Tümör	1595	405

Bu verilerden 5702 tanesi modelin eğitim için,1311 tanesi modeli test etmek için kullanılmıştır.

**Veri Setindeki Eğitim Ve Test Verileri Dağılımı**




**Şekil 5.2:** Veri Setindeki Verilerin Veri Gruplarına Göre Dağılımı

Şekil 5.2 de veri setindeki verilerin eğitim ve test gruplarına göre dağılımı pasta grafiği olarak verilmiştir.7013 adet veriden %81.3'ü eğitim için ve %18.7'si test için ayrılmıştır.



**Şekil 5.3:** Eğitim Verileri Dağılımı

Şekil 5.3 de eğitim verilerinin dağılımı pasta grafiği olarak gösterilmiştir. Eğitim veri grubunda 5702 adet veri bulunmaktadır ve bu verilerin %23.1'i glioma, % 23.4'ü meningioma, %25.5'i pituitary, %27.9'u tümör olmayan beyin MR verisidir.



**Şekil 5.4:** Test Verileri Dağılımı

Şekil 5.4 de test verilerinin dağılımı pasta grafiği olarak gösterilmektedir. Test veri setindeki 1311 verinin %22.9'u gliomayı, % 23.3'ü meningiomayı, %22.9'u pituitaryi, %30.9'u tümör olmayan beyin görüntüsünü temsil etmektedir.

## 5.2 Görüntülerin Ön İşlenmesi

Beyin MRI görüntüleri ESA modeline verilmeden önce, daha doğru ve hızlı sonuç almak amacıyla ön işleme tabi tutulmuştur. Veriler görüntüler augment image ile yeniden boyutlandırılarak 224X224 piksel olarak yeniden ölçeklendirilmiştir ve bu sayede modelin daha verimli eğitilmesi sağlanmıştır.

### 5.3 Çalışılan Modellerin Ana Özellikleri

Bu tez çalışmasında bir ESA mimarilerinden VGG 16 ,VGG 19 ve ResNet152V2 modelleri öğrenme aktarımı ile kullanılmıştır.



Şekil 5.5: Model Blok diyagramı

```
ESA Modeli Tanımlama  
Sıralı model oluşturma  
Veri boyutlandırma  
Tanımlanan ESA modelini ekleme  
Düz Vektör Oluşturma  
Veri Seyreltme (0.3)  
Aktivasyon fonksiyonu  
Veri Seyreltme (0.2)  
Sınıflandırma
```

Şekil 5.6: Model Yalancı (Pseudo Code) Kodu

Çalışılan modellerde birincisi 0.3, ikincisi 0.2 olmak üzere iki defa seyreltme işlemi yapılmıştır. Sınıflandırma fonksiyonu olarak Softmax, kayıp fonksiyonu olarak seyrek kategorik çapraz entropi kullanılmıştır.

ESA modelleri için performanslarını değerlendirmek için çeşitli ölçütler vardır. Bunlar; doğruluk, kesinlik, duyarlılıktır. Bütün bu değerlerin hesaplanabilmesi için gerekli olan bütün değerler hata matrisi adı verilen bir matris

işlenir ve bu değerler üzerinden modelin performans değerlendirilir. Bu tez çalışmasında 4 sınıflı bir model kullanılmıştır.

**Çizelge 5.2: 4X4 Hata Matrisi**

		HATA MATRİSİ			
		A	B	C	D
GERÇEK DEĞERLER	Glioma	A	B	C	D
	Meningioma	E	F	G	H
	No Tumor	I	J	K	L
	Pituitary	M	N	O	S
		Glioma	Meningioma	No Tumor	Pituitary
		TAHMİN DEĞERLERİ			

**Kaynak:**( Valero-Carreras, Alcaraz ve Landete,,2023: s.4)

- Doğruluk (Accuary) **Doğruluk** =  $\frac{A+F+K+S}{A+B+C+D+E+F+G+H+I+J+K+L+M+N+O+S}$
- Kesinlik Glioma ( $P_G$ )  $PG = \frac{A}{A + E + I + M}$
- Kesinlik Meningioma ( $P_M$ )  $PM = \frac{F}{B+F+J+N}$
- Kesinlik No Tumor ( $P_{NOT}$ )  $PNOT = \frac{K}{C+G+K+O}$
- Kesinlik Pituitary ( $P_P$ )  $PP = \frac{S}{D+H+L+S}$
- Duyarlılık Glioma ( $R_G$ )  $RG = \frac{A}{A+B+C+D}$
- Duyarlılık Meningioma ( $R_M$ )  $RM = \frac{F}{E+F+G+H}$
- Duyarlılık NoTumor ( $R_{NOT}$ )  $RNOT = \frac{K}{I+J+K+L}$
- Duyarlılık Pituitary ( $R_p$ )  $RP = \frac{S}{M+N+O+S}$

## 5.4 Çalışılan Modeller

### 5.4.1 Model 1


Bu modelde ESA mimarilerinden VGG16, VGG19 ve ResNet152V2 kullanılmıştır. Aktivasyon fonksiyonu olarak RELU, sigmoid ve tanh kullanılmıştır. Optimizasyon fonksiyonu olarak Adam, SGD ve RMSProp kullanılmıştır.

- **Model 1-a**

```
ESA Modeli Tanımlama=VGG16
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =RELU
Veri Seyreltme (0.2)
Sınıflandırma
```

**Şekil 5.7:** Model 1-a Yalancı (Pseudo Code) Kodu

Model 1-a da VGG16 ESA modeli, RELU aktivasyon fonksiyonu, optimizasyon fonksiyonu ADAM ile hiperparametreler; çevrim sayısı 10, mini yığın boyutu 16 ve öğrenme katsayısı olarak 0.001 seçilmiştir.



**Şekil 5.8:** Model 1-a Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.8 incelendiğinde model 1-a'nın başarısının 0.2 civarında olduğu ve kaybının da 1.39 civarında olduğu görülmektedir.

**Çizelge 5.3:** Model 1-a Karışıklık Matrisi

<b>Glioma</b>	0	0	300	0
<b>Meningioma</b>	0	0	306	0
<b>No Tumor</b>	0	0	405	0
<b>Pituitary</b>	0	0	300	0
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```
Sınıflandırma Raporu ==>
      precision    recall  f1-score   support

   glioma         0.00      0.00      0.00         300
 meningioma       0.00      0.00      0.00         306
   notumor       0.31      1.00      0.47         405
   pituitary       0.00      0.00      0.00         300

 accuracy         0.31         1311
 macro avg        0.08      0.25      0.12         1311
 weighted avg     0.10      0.31      0.15         1311
```

**Şekil 5.9:** Model 1-a Sınıflandırma Raporu


Çizelge 5.3 ve şekil 5.9 incelediğinde model 1-a testing verileri yardımıyla tabi tutulduğu tahmin işleminde modelin sadece tümör olmayan verileri doğru tahmin etmiştir ve diğer veri sınıflarına ait verileri de tümör olmayan veri olarak tahmin etmiştir. Genel doğruluk oranı ise 0.31dir.

- **Model 1-b**

```
ESA Modeli Tanımlama=VGG16
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Sigmoid
Veri Seyreltme (0.2)
Sınıflandırma
```

**Şekil 5.10:** Model 1-b Yalancı (Pseudo Code) Kodu

Model 1-b de VGG16 ESA modeli, sigmoid aktivasyon fonksiyonu, optimizasyon fonksiyonu SGD ile hiperparametreler; çevrim sayısı 10, mini yığın boyutu 16 ve öğrenme katsayısı olarak 0.001 seçilmiştir.



Şekil 5.11: Model 1-b Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.11 incelendiğinde model 1-b'nin başarısının 0.9 civarında olduğu ve kaybının da 0.2 civarında olduğu görülmektedir.

Çizelge 5.4: Model 1-b Karışıklık Matrisi

<b>Glioma</b>	247	43	2	8
<b>Meningioma</b>	4	256	17	29
<b>No Tumor</b>	8	6	388	3
<b>Pituitary</b>	1	3	300	296
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```

Sınıflandırma Raporu ==>
      precision    recall  f1-score   support

   glioma         0.95     0.82     0.88         300
  meningioma      0.83     0.84     0.83         306
   notumor       0.95     0.96     0.96         405
  pituitary       0.88     0.99     0.93         300

 accuracy                   0.91         1311
 macro avg                 0.90     0.90     0.90         1311
 weighted avg              0.91     0.91     0.90         1311

```

Şekil 5.12: Model 1-b Sınıflandırma Raporu

Çizelge 5.4 ve şekil 5.12 incelediğinde model 1-b'nin 300 glioma test verisinden 247'sini ,305 meningioma verisinden 256'sını ,405 tümör olmayan veriden 388'ini ,300 pituitary verisinden 296'sını doğru tahmin ettiği ve test veri seti için doğruluk oranının 0.91 olduğu görülmektedir.

- **Model 1- b-1**

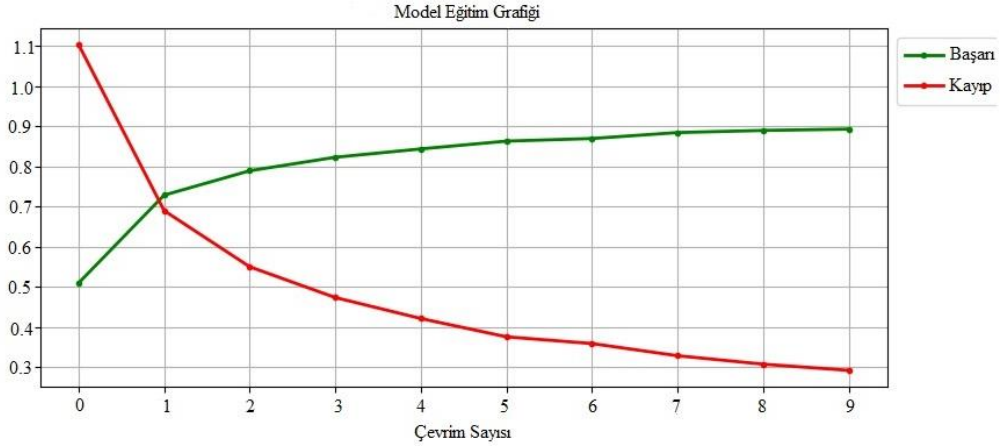
```

ESA Modeli Tanımlama=VGG19
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Sigmoid
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.13:** Model 1-b-1 Yalancı (Pseudo Code) Kodu

Model 1-b-1 de VGG19 ESA modeli, sigmoid aktivasyon fonksiyonu, optimizasyon fonksiyonu SGD ile hiperparametreler; çevrim sayısı 10, mini yığın boyutu 16 ve öğrenme katsayısı olarak 0.001 seçilmiştir.



**Şekil 5.14:** Model 1-b -1 Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.14 incelendiğinde model 1-b-1'in başarısının 0.9 civarında olduğu ve kaybının da 0.3 civarında olduğu görülmektedir.

**Çizelge 5.5:** Model 1-b-1 Karışıklık Matrisi

<b>Glioma</b>	257	37	2	4
<b>Meningioma</b>	43	202	33	28
<b>No Tumor</b>	9	8	385	3
<b>Pituitary</b>	6	6	2	286
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

Sınıflandırma Raporu ==>				
	precision	recall	f1-score	support
glioma	0.82	0.86	0.84	300
meningioma	0.80	0.66	0.72	306
notumor	0.91	0.95	0.93	405
pituitary	0.89	0.95	0.92	300
accuracy			0.86	1311
macro avg	0.85	0.86	0.85	1311
weighted avg	0.86	0.86	0.86	1311

**Şekil 5.15:** Model 1-b-1 Sınıflandırma Raporu

Çizelge 5.5 ve şekil 5. 15 incelediğinde model 1-b-1'in 300 glioma test verisinden 257'sini ,305 meningioma verisinden 202'sini ,405 tümör olmayan veriden 385'ini ,300 pituitary verisinden 286'sını doğru tahmin ettiği ve test veri seti için doğruluk oranının 0.86 olduğu görülmektedir.

- **Model 1-b-2**


```

ESA Modeli Tanımlama=ResNet152V2
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Sigmoid
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.16:** Model 1-b-2Yalancı (Pseudo Code) Kodu

Model 1-b-2 de ResNet152V2 ESA modeli, sigmoid aktivasyon fonksiyonu, optimizasyon fonksiyonu SGD ile hiperparametreler; çevrim sayısı 10, mini yığın boyutu 16 ve öğrenme katsayısı olarak 0.001 seçilmiştir.



**Şekil 5.17:** Model 1-b -2Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.17 incelendiğinde model 1-b-2 başarısının 0.94 civarında olduğu ve kaybının da 0.2 civarında olduğu görülmektedir.

**Çizelge 5.6:** Model 1-b-2 Karışıklık Matrisi

<b>Glioma</b>	259	29	4	8
<b>Meningioma</b>	13	255	14	24
<b>No Tumor</b>	2	6	397	0
<b>Pituitary</b>	2	8	2	288
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```

Sınıflandırma Raporu ==>
      precision    recall  f1-score   support

 glioma           0.94      0.86      0.90         300
 meningioma       0.86      0.83      0.84         306
 notumor          0.95      0.98      0.97         405
 pituitary        0.90      0.96      0.93         300

 accuracy                   0.91         1311
 macro avg                  0.91         1311
 weighted avg               0.91         1311
  
```

**Şekil 5.18:** Model 1-b-2 Sınıflandırma Raporu

Çizelge 5.6 ve şekil 5.18 incelediğinde model 1-b-2'nin 300 glioma test verisinden 259'unu ,305 meningioma verisinden 255'ini ,405 tümör olmayan veriden 397'sini ,300 pituitary verisinden 288'ini doğru tahmin ettiği ve test veri seti için doğruluk oranının 0.91 olduğu görülmektedir.


- **Model 1-c**

```

ESA Modeli Tanımlama=VGG16
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Tanh
Veri Seyreltme (0.2)
Sınıflandırma
  
```

**Şekil 5.19:** Model 1-c Yalancı (Pseudo Code) Kodu

Model 1-c de VGG16 ESA modeli, tanh aktivasyon fonksiyonu, optimizasyon fonksiyonu RMSProp ile hiperparametreler; çevrim sayısı 20, mini yığın boyutu 16 ve öğrenme katsayısı olarak 0.001 seçilmiştir.



Şekil 5.20: Model 1-c Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.20 incelediğinde model 1-c'nin eğitim verisi başarı oranının 0.2 civarında, kayıp oranını ise 1.4 olduğu görülmektedir.

Çizelge 5.7: Model 1-c Karışıklık Matrisi

<b>Glioma</b>	0	0	300	0
<b>Meningioma</b>	0	0	306	0
<b>No Tumor</b>	0	0	405	0
<b>Pituitary</b>	0	0	300	0
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```

Sınıflandırma Raporu ==>
precision    recall  f1-score   support

 glioma      0.00    0.00    0.00      300
 meningioma  0.00    0.00    0.00      306
 notumor     0.31    1.00    0.47      405
 pituitary   0.00    0.00    0.00      300

 accuracy                    0.31    1311
 macro avg                   0.08    0.25    0.12    1311
 weighted avg                 0.10    0.31    0.15    1311

```

Şekil 5.21: Model 1-c Sınıflandırma Raporu

Çizelge 5.7 ve şekil 5.21 incelendiğinde model 1-c'nin tümör olmayan verileri doğru tahmin ettiği, diğer sınıflara ait bütün verileri de tümörsüz veri olarak tahmin ettiği ve genel doğruluk oranının 0.31 olduğu görülmektedir.

### 5.4.2 Model 2


Bu modelde ESA mimarilerinden VGG16, VGG19 ve ResNet152V2 kullanılmıştır. Aktivasyon fonksiyonu olarak RELU, sigmoid, tanh ve optimizasyon fonksiyonu olarak Adam, SGD, RMSProp kullanılmıştır.

- **Model 2-a**

```
ESA Modeli Tanımlama=VGG19
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =RELU
Veri Seyreltme (0.2)
Sınıflandırma
```

Şekil 5.22: Model 2-a Yalancı (Pseudo Code) Kodu

Model 2-a da VGG19 ESA modeli, RELU aktivasyon fonksiyonu, optimizasyon fonksiyonu SGD ile hiperparametreler; çevrim sayısı 20, mini yığın boyutu 32 ve öğrenme katsayısı olarak 0.0001 seçilmiştir.



Şekil 5.23: Model 2-a Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.23 incelendiğinde model 2-a'nın başarısının 0.8 civarında, kayıp oranının ise 0.5 civarında olduğu görülmektedir.

**Çizelge 5.8:** Model 2-a Karışıklık Matrisi

<b>Glioma</b>	217	64	4	15
<b>Meningioma</b>	50	130	54	72
<b>No Tumor</b>	10	10	376	9
<b>Pituitary</b>	4	9	2	285
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```
Sınıflandırma Raporu ==>
precision    recall  f1-score   support

   glioma     0.77    0.72    0.75     300
 meningioma   0.61    0.42    0.50     306
  notumor     0.86    0.93    0.89     405
 pituitary    0.75    0.95    0.84     300

 accuracy                    0.77     1311
 macro avg                   0.75    0.76    0.74     1311
 weighted avg                 0.76    0.77    0.76     1311
```

**Şekil 5.24:** Model 2-a Sınıflandırma Raporu

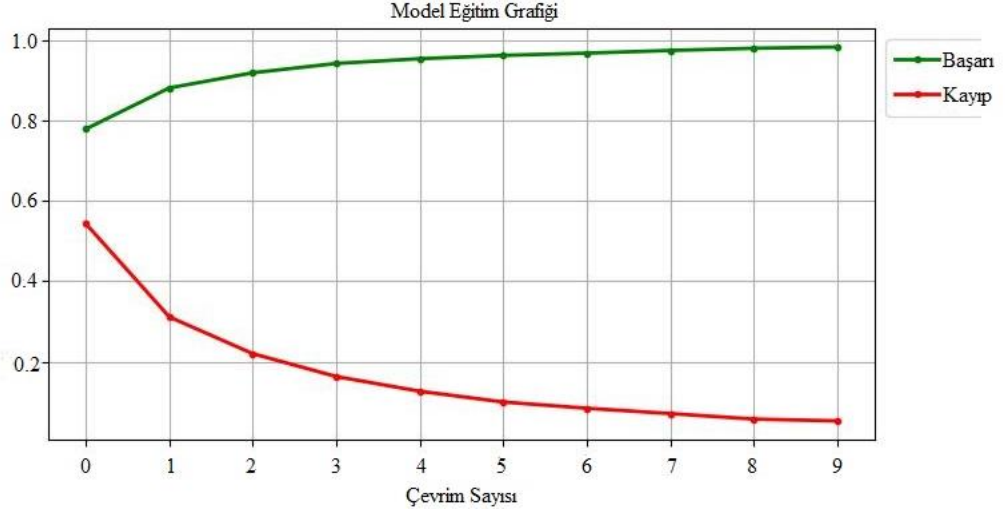
Çizelge 5.8 ve şekil 5. 24 incelediğinde model 2-a'nın 300 glioma test verisinden 217'sini, 305 meningioma verisinden 130'unu ,405 tümör olmayan veriden 376'sını, 300 pituitary verisinden 285'ini doğru tahmin ettiği ve test veri seti için başarı oranının 0.77 olduğu görülmektedir.

- **Model 2-b**

```
ESA Modeli Tanımlama=VGG19
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Sigmoid
Veri Seyreltme (0.2)
Sınıflandırma
```

**Şekil 5.25:** Model 2-b Yalancı (Pseudo Code) Kodu

Model 2-b de VGG19 ESA modeli, Sigmoid aktivasyon fonksiyonu, optimizasyon fonksiyonu RMSProp ile hiperparametreler; çevrim sayısı 10, mini yığın boyutu 32 ve öğrenme katsayısı olarak 0.0001 seçilmiştir.



Şekil 5.26: Model 2-b Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.26 incelendiğinde model 2-b için eğitim doğruluk oranının 0.98 civarında ve kayıp oranının 0.02 civarında olduğu görülmektedir.

Çizelge 5.9: Model 2-b Karışıklık Matrisi

<b>Glioma</b>	277	22	0	1
<b>Meningioma</b>	16	272	3	15
<b>No Tumor</b>	0	2	403	0
<b>Pituitary</b>	0	1	1	298
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```

Sınıflandırma Raporu ==>
precision    recall  f1-score   support

   glioma     0.95     0.92     0.93     300
 meningioma   0.92     0.89     0.90     306
  notumor     0.99     1.00     0.99     405
 pituitary    0.95     0.99     0.97     300

 accuracy                    0.95     1311
 macro avg                   0.95     0.95     0.95     1311
 weighted avg                 0.95     0.95     0.95     1311

```

Şekil 5.27: Model 2-b Sınıflandırma Raporu

Çizelge 5.9 ve şekil 5.27 incelediğinde model 2-b' nin 300 glioma test verisinden 277'sini, 305 meningioma verisinden 272'sini, 405 tümör olmayan veriden 403'ünü, 300 pituitary verisinden 298'ini doğru tahmin ettiği ve test veri seti için başarı oranının 0.95 olduğu görülmektedir.

- **Model 2 -b-1**


```

ESA Modeli Tanımlama=VGG16
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Sigmoid
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.28:** Model 2-b-1 Yalancı (Pseudo Code) Kodu

Model 2-b-1 de VGG16 ESA modeli, Sigmoid aktivasyon fonksiyonu, optimizasyon fonksiyonu RMSProp ile hiperparametreler; çevrim sayısı 10, mini yığın boyutu 32 ve öğrenme katsayısı olarak 0.0001 seçilmiştir.



**Şekil 5.29:** Model 2-b-1 Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.29 incelendiğinde model 2-b-1 için eğitim doğruluk oranının 0.99 civarında ve kayıp oranının 0.03 civarında olduğu görülmektedir.

**Çizelge 5.10:** Model 2-b-1 Karışıklık Matrisi

<b>Glioma</b>	298	2	0	0
<b>Meningioma</b>	65	230	1	10
<b>No Tumor</b>	12	0	393	0
<b>Pituitary</b>	4	2	0	294
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

Sınıflandırma Raporu ==>				
	precision	recall	f1-score	support
glioma	0.79	0.99	0.88	300
meningioma	0.98	0.75	0.85	306
notumor	1.00	0.97	0.98	405
pituitary	0.97	0.98	0.97	300
accuracy			0.93	1311
macro avg	0.93	0.92	0.92	1311
weighted avg	0.94	0.93	0.93	1311

Şekil 5.30: Model 2-b-1 Sınıflandırma Raporu

Çizelge 5.10 ve şekil 5.30 incelediğinde model 2-b-1'in 300 glioma test verisinden 298'ini, 305 meningioma verisinden 230'unu, 405 tümör olmayan veriden 393'ünü, 300 pituitary verisinden 294'ünü doğru tahmin ettiği ve test veri seti için başarı oranının 0.93 olduğu görülmektedir.

- **Model 2-b-2**


```

ESA Modeli Tanımlama=ResNet152V2
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Sigmoid
Veri Seyreltme (0.2)
Sınıflandırma

```

Şekil 5.31: Model 2-b-2 Yalancı (Pseudo Code) Kodu

Model 2-b-2 de ResNet152V2 ESA modeli, Sigmoid aktivasyon fonksiyonu, optimizasyon fonksiyonu RMSProp ile hiperparametreler; çevrim sayısı 10, mini yığın boyutu 32 ve öğrenme katsayısı olarak 0.0001 seçilmiştir.



Şekil 5.32: Model 2-b-2 Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.32 incelendiğinde model 2-b-2 için eğitim doğruluk oranının 1 civarında ve kayıp oranının 0.001 civarında olduğu görülmektedir.

**Çizelge 5.11:** Model 2-b-2 Karışıklık Matrisi

<b>Glioma</b>	274	19	2	5
<b>Meningioma</b>	12	284	1	9
<b>No Tumor</b>	0	0	405	0
<b>Pituitary</b>	0	1	1	298
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```
Sınıflandırma Raporu ==>
precision recall f1-score support
glioma      0.96      0.91      0.94      300
meningioma  0.93      0.93      0.93      306
notumor     0.99      1.00      1.00      405
pituitary   0.96      0.99      0.97      300

accuracy    0.96      0.96      0.96      1311
macro avg   0.96      0.96      0.96      1311
weighted avg 0.96      0.96      0.96      1311
```

**Şekil 5.33:** Model 2-b-2 Sınıflandırma Raporu


Çizelge 5.11 ve şekil 5.33 incelediğinde model 2-b-1'in 300 glioma test verisinden 274'ünü, 305 meningioma verisinden 284'ünü, 405 tümör olmayan veriden tamamını, 300 pituitary verisinden 298'ini doğru tahmin ettiği ve test veri seti için başarı oranının 0.96 olduğu görülmektedir.

- **Model 2-c**

```
ESA Modeli Tanımlama=VGG19
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Tanh
Veri Seyreltme (0.2)
Sınıflandırma
```

**Şekil 5.34:** Model 2-c Yalancı (Pseudo Code) Kodu

Model 2-c de VGG19 ESA modeli, Tanh aktivasyon fonksiyonu, optimizasyon fonksiyonu ADAM ile hiperparametreler; çevrim sayısı 15, mini yığın boyutu 32 ve öğrenme katsayısı olarak 0.0001 seçilmiştir.



**Şekil 5.35:** Model 2-c Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.35 de model 2-c'nin doğruluk oranının 0.99 civarında, kayıp oranının ise 0.01 civarında olduğu görülmektedir.

**Çizelge 5.12:** Model 2-c Karışıklık Matrisi

<b>Glioma</b>	297	2	1	0
<b>Meningioma</b>	58	239	1	8
<b>No Tumor</b>	0	0	405	0
<b>Pituitary</b>	1	2	0	297
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```

Sınıflandırma Raporu ==>
      precision    recall  f1-score   support

   glioma         0.83      0.99      0.91      300
 meningioma       0.98      0.78      0.87      306
   notumor        1.00      1.00      1.00      405
   pituitary       0.97      0.99      0.98      300

 accuracy         0.94         1311
 macro avg         0.95         0.94         0.94         1311
 weighted avg         0.95         0.94         0.94         1311

```

**Şekil 5.36:** Model 2-c Sınıflandırma Raporu

Çizelge 5.12 ve şekil 5.36 incelediğinde model 2-c'nin 300 glioma test verisinden 297'sini ,305 meningioma verisinden 239'unu ,405 tümör olmayan veriden 405'ini ,300 pituitary verisinden 297'ini doğru tahmin ettiği ve test veri seti için başarı oranının 0.94 olduğu görülmektedir.

- **Model 2 -c-1**


```

ESA Modeli Tanımlama=VGG16
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Tanh
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.37:** Model 2-c -1Yalancı (Pseudo Code) Kodu

Model 2-c-1 de VGG16 ESA modeli, Tanh aktivasyon fonksiyonu, optimizasyon fonksiyonu ADAM ile hiperparametreler; çevrim sayısı 15, mini yığın boyutu 32 ve öğrenme katsayısı olarak 0.0001 seçilmiştir.



**Şekil 5.38:** Model 2-c-1 Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.38 de model 2-c-1'in doğruluk oranının 0.99 civarında, kayıp oranının ise 0.005 civarında olduğu görülmektedir.

**Çizelge 5.13:** Model 2-c-1 Karışıklık Matrisi

<b>Glioma</b>	291	9	0	0
<b>Meningioma</b>	10	290	1	5
<b>No Tumor</b>	0	0	405	0
<b>Pituitary</b>	3	3	1	293
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

Sınıflandırma Raporu ==>				
	precision	recall	f1-score	support
glioma	0.96	0.97	0.96	300
meningioma	0.96	0.95	0.95	306
notumor	1.00	1.00	1.00	405
pituitary	0.98	0.98	0.98	300
accuracy			0.98	1311
macro avg	0.97	0.97	0.97	1311
weighted avg	0.98	0.98	0.98	1311

**Şekil 5.39:** Model 2-c-1 Sınıflandırma Raporu

Çizelge 5.13 ve şekil 5.39 incelediğinde model 2-c-1'in 300 glioma test verisinden 291'ini ,305 meningioma verisinden 290'ını ,405 tümör olmayan veriden 405'ini ,300 pituitary verisinden 293'ünü doğru tahmin ettiği ve test veri seti için başarı oranının 0.98 olduğu görülmektedir.

- **Model 2-c-2**

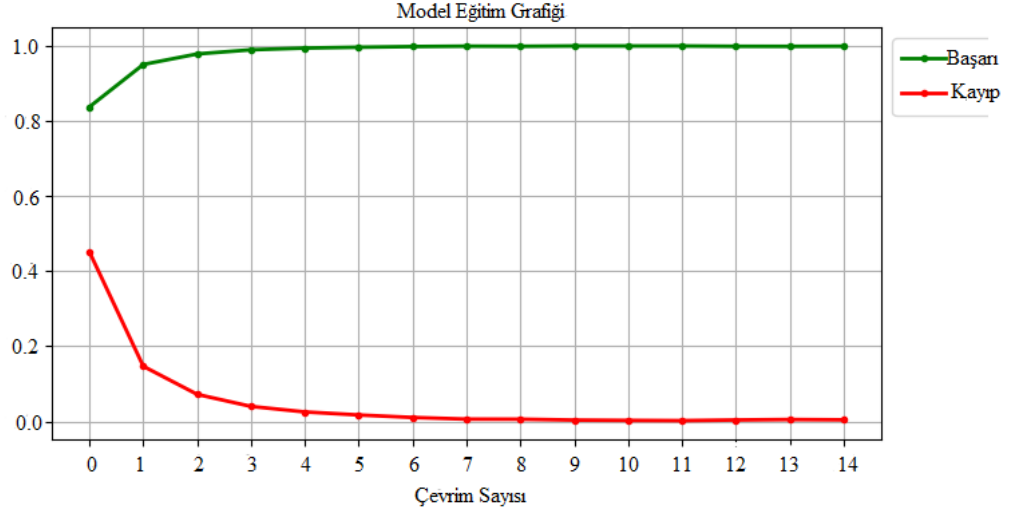
```

ESA Modeli Tanımlama=ResNet152V2
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Tanh
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.40:** Model 2-c -2 Yalancı (Pseudo Code) Kodu

Model 2-c-2 de ResNet152V2 ESA modeli, Tanh aktivasyon fonksiyonu, optimizasyon fonksiyonu ADAM ile hiperparametreler; çevrim sayısı 15, mini yığın boyutu 32 ve öğrenme katsayısı olarak 0.0001 seçilmiştir.



**Şekil 5.41:** Model 2-c-2 Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.41de model 2-c-2'nin doğruluk oranının 0.99 civarında, kayıp oranının 0.0040 civarında olduğu görülmektedir.

**Çizelge 5.14:** Model 2-c-2 Karışıklık Matrisi

<b>Glioma</b>	271	24	0	5
<b>Meningioma</b>	9	286	0	11
<b>No Tumor</b>	0	0	405	0
<b>Pituitary</b>	1	2	1	296
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```

Sınıflandırma Raporu ==>
      precision    recall  f1-score   support

   glioma         0.96     0.90     0.93     300
 meningioma       0.92     0.93     0.93     306
  notumor         1.00     1.00     1.00     405
 pituitary        0.95     0.99     0.97     300

 accuracy                   0.96     1311
 macro avg                   0.96     1311
 weighted avg                 0.96     1311

```

**Şekil 5.42:** Model 2-c-2 Sınıflandırma Raporu

Çizelge 5.14 ve şekil 5.42 incelediğinde model 2-c-2'nin 300 glioma test verisinden 271'ini ,305 meningioma verisinden 286'sını ,405 tümör olmayan veriden 405'ini ,300 pituitary verisinden 296'sını doğru tahmin ettiği ve test veri seti için başarı oranının 0.96 olduğu görülmektedir.

### 5.4.3 Model 3


Bu model de ESA mimarilerinden VGG16, VGG19 ve ResNet152V2 kullanılmıştır. Aktivasyon fonksiyonu olarak RELU, sigmoid, tanh ve optimizasyon fonksiyonu olarak Adam, SGD, RMSProp kullanılmıştır.

- **Model 3-a**

```
ESA Modeli Tanımlama=ResNet152V2
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =RELU
Veri Seyreltme (0.2)
Sınıflandırma
```

**Şekil 5.43:** Model 3-a Yalancı (Pseudo Code) Kodu

Model 3-a da ResNet152V2 ESA modeli, RELU aktivasyon fonksiyonu, optimizasyon fonksiyonu RMSProp ile hiperparametreler; çevrim sayısı 15, mini yığın boyutu 64 ve öğrenme katsayısı olarak 0.00001 seçilmiştir.



**Şekil 5.44:** Model 3-a Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.44 de model 3-a'nın doğruluk oranı 0.98 civarında, kayıp oranı ise 0.02 civarındadır.

**Çizelge 5.15:** Model 3-a Karışıklık Matrisi

<b>Glioma</b>	262	35	0	3
<b>Meningioma</b>	18	273	2	13
<b>No Tumor</b>	0	1	403	1
<b>Pituitary</b>	1	5	1	293
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

Sınıflandırma Raporu ==>				
	precision	recall	f1-score	support
glioma	0.93	0.87	0.90	300
meningioma	0.87	0.89	0.88	306
notumor	0.99	1.00	0.99	405
pituitary	0.95	0.98	0.96	300
accuracy			0.94	1311
macro avg	0.93	0.93	0.93	1311
weighted avg	0.94	0.94	0.94	1311

**Şekil 5.45:** Model 3-a Sınıflandırma Raporu

Çizelge 5.15 ve şekil 5.45 incelediğinde model 3-a'nın 300 glioma test verisinden 262'sini, 305 meningioma verisinden 273'ünü, 405 tümör olmayan veriden 403'ünü, 300 pituitary verisinden 293'ünün doğru tahmin ettiği ve test veri seti için başarı oranının 0.94 olduğu görülmektedir.

- **Model 3-a-1**


```

ESA Modeli Tanımlama=VGG16
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =RELU
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.46:** Model 3-a-1 Yalancı (Pseudo Code) Kodu

Model 3-a-1 de VGG16 ESA modeli, RELU aktivasyon fonksiyonu, optimizasyon fonksiyonu RMSProp ile hiperparametreler; çevrim sayısı 15, mini yığın boyutu 64 ve öğrenme katsayısı olarak 0.00001 seçilmiştir.



**Şekil 5.47:** Model 3-a-1 Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.47 de model 3-a-1'in doğruluk oranının 0.97 civarında olduğu, kayıp oranının ise 0.07civarında olduğu görülmektedir.

**Çizelge 5.16:** Model 3-a-1 Karışıklık Matrisi

<b>Glioma</b>	253	40	2	5
<b>Meningioma</b>	3	287	2	14
<b>No Tumor</b>	2	2	401	0
<b>Pituitary</b>	0	2	1	297
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```

Sınıflandırma Raporu ==>
      precision    recall  f1-score   support

   glioma         0.98     0.84     0.91         300
 meningioma       0.87     0.94     0.90         306
  notumor         0.99     0.99     0.99         405
  pituitary       0.94     0.99     0.96         300

 accuracy                   0.94         1311
 macro avg                  0.94     0.94     0.94         1311
 weighted avg               0.95     0.94     0.94         1311

```

**Şekil 5.48:** Model 3-a-1 Sınıflandırma Raporu

Çizelge 5.16 ve şekil 5.48 incelediğinde model 3-a-1'in 300 glioma test verisinden 25' ünü, 305 meningioma verisinden 287'sini, 405 tümör olmayan veriden 401'ini, 300 pituitary verisinden 297'sini doğru tahmin ettiği ve test veri seti için başarı oranının 0.94 olduğu görülmektedir.

- **Model 3-a-2**

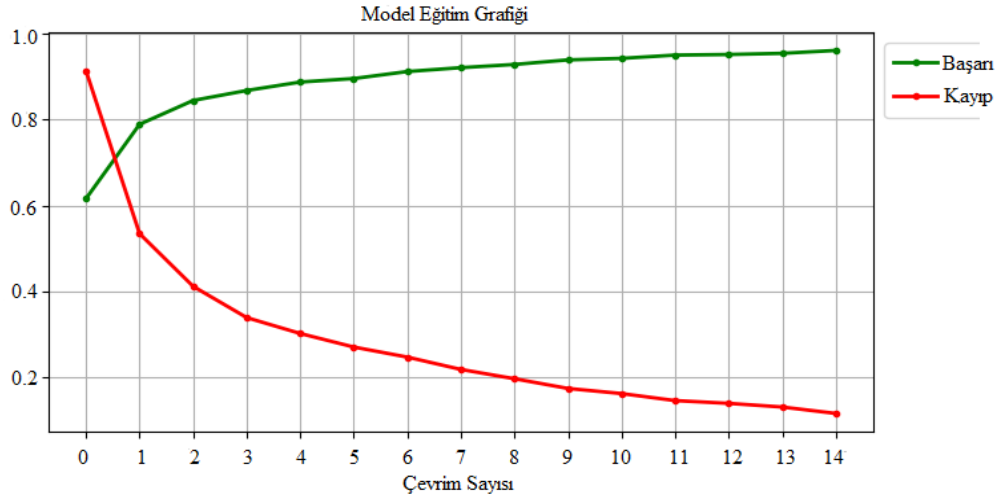
```

ESA Modeli Tanımlama=VGG19
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =RELU
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.49:** Model 3-a-2 Yalancı (Pseudo Code) Kodu

Model 3-a-2 de VGG19 ESA modeli, RELU aktivasyon fonksiyonu, optimizasyon fonksiyonu RMSProp ile hiperparametreler; çevrim sayısı 15, mini yığın boyutu 64 ve öğrenme katsayısı olarak 0.00001 seçilmiştir.



**Şekil 5.50:** Model 3-a-2 Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.50 de model 3-a-2 in doğruluk oranı 0.92 civarında, kayıp oranı ise 0.05 civarındadır.

**Çizelge 5.17:** Model 3-a-2 Karışıklık Matrisi

<b>Glioma</b>	276	20	1	3
<b>Meningioma</b>	17	270	5	14
<b>No Tumor</b>	6	1	396	2
<b>Pituitary</b>	0	2	1	297
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

Sınıflandırma Raporu ==>				
	precision	recall	f1-score	support
glioma	0.92	0.92	0.92	300
meningioma	0.92	0.88	0.90	306
notumor	0.98	0.98	0.98	405
pituitary	0.94	0.99	0.96	300
accuracy			0.95	1311
macro avg	0.94	0.94	0.94	1311
weighted avg	0.94	0.95	0.94	1311

**Şekil 5.51:** Model 3-a-2 Sınıflandırma Raporu

Çizelge 5.17 ve şekil 5.51 incelediğinde model 3-a-2'in 300 glioma test verisinden 276'sını, 305 meningioma verisinden 270'ini, 405 tümör olmayan veriden 396'sını, 300 pituitary verisinden 297'sini doğru tahmin ettiği ve test veri seti için başarı oranının 0.94 olduğu görülmektedir.

- **Model 3-b**


```

ESA Modeli Tanımlama=ResNet152V2
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Sigmoid
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.52:** Model 3-b Yalancı (Pseudo Code) Kodu

Model 3-b de ResNet152V2 ESA modeli, Sigmoid aktivasyon fonksiyonu, optimizasyon fonksiyonu ADAM ile hiperparametreler; çevrim sayısı 20, mini yığın boyutu 64 ve öğrenme katsayısı olarak 0.00001 seçilmiştir.



Şekil 5.53: Model 3-b Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.53 de model 3-b'nin doğruluk oranının 0.98 civarında, kayıp oranının da 0.1 civarında olduğu görülmektedir.

Çizelge 5.18: Model 3-b Karışıklık Matrisi

<b>Glioma</b>	262	31	3	4
<b>Meningioma</b>	12	275	6	13
<b>No Tumor</b>	1	4	400	0
<b>Pituitary</b>	0	7	1	292
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```

Sınıflandırma Raporu ==>
      precision    recall  f1-score   support

   glioma         0.95     0.87     0.91         300
 meningioma       0.87     0.90     0.88         306
 notumor         0.98     0.99     0.98         405
 pituitary       0.94     0.97     0.96         300

 accuracy                   0.94         1311
 macro avg                 0.94     0.93     0.93         1311
 weighted avg              0.94     0.94     0.94         1311

```

Şekil 5.54: Model 3-b Sınıflandırma Raporu

Çizelge 5.18 ve şekil 5.54 incelediğinde model 3-b'nin 300 glioma test verisinden 262'sini, 305 meningioma verisinden 27'inin ,405 tümör olmayan veriden 400'ünü ,300 pituitary verisinden 292'sini doğru tahmin ettiği ve test veri seti için başarı oranının 0.94 olduğu görülmektedir.

- **Model 3-b-1**


```

ESA Modeli Tanımlama=VGG 16
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Tanh
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.55:** Model 3-b-1 Yalancı (Pseudo Code) Kodu

Model 3-b -1 de VGG16 ESA modeli, Sigmoid aktivasyon fonksiyonu, optimizasyon fonksiyonu ADAM ile hiperparametreler; çevrim sayısı 20, mini yığın boyutu 64 ve öğrenme katsayısı olarak 0.00001 seçilmiştir.



**Şekil 5.56:** Model 3-b-1 Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.56 de model 3-b-1'in doğruluk oranı 0.98 civarında, kayıp oranı 0.05 civarındadır.

**Çizelge 5.19:** Model 3-b-1 Karışıklık Matrisi

<b>Glioma</b>	279	19	1	1
<b>Meningioma</b>	8	291	5	2
<b>No Tumor</b>	5	0	400	0
<b>Pituitary</b>	1	3	1	295
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

Sınıflandırma Raporu ==>				
	precision	recall	f1-score	support
glioma	0.95	0.93	0.94	300
meningioma	0.93	0.95	0.94	306
notumor	0.98	0.99	0.99	405
pituitary	0.99	0.98	0.99	300
accuracy			0.96	1311
macro avg	0.96	0.96	0.96	1311
weighted avg	0.97	0.96	0.96	1311

**Şekil 5.57:** Model 3-b-1 Sınıflandırma Raporu

Çizelge 5.19 ve şekil 5.57 incelediğinde model 3-b-1'in 300 glioma test verisinden 279'unu, 305 meningioma verisinden 291'ini ,405 tümör olmayan veriden 400'ünü ,300 pituitary verisinden 295'ini doğru tahmin ettiği ve test veri seti için başarı oranının 0.96 olduğu görülmektedir.

- **Model 3-b-2**


```

ESA Modeli Tanımlama=VGG 19
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Tanh
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.58:** Model 3-b-2 Yalancı (Pseudo Code) Kodu

Model 3-b-2 de VGG19 ESA modeli, Sigmoid aktivasyon fonksiyonu, optimizasyon fonksiyonu ADAM ile hiperparametreler; çevrim sayısı 20, mini yığın boyutu 64 ve öğrenme katsayısı olarak 0.00001 seçilmiştir.



**Şekil 5.59:** Model 3-b-2 Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.59 da model 3-b-2'nin doğruluk oranı 0.97 civarında, kayıp oranı 0.10 civarındadır.

**Çizelge 5.20:** Model 3-b-2 Karışıklık Matrisi

<b>Glioma</b>	280	17	2	1
<b>Meningioma</b>	24	267	11	4
<b>No Tumor</b>	6	0	399	0
<b>Pituitary</b>	0	3	1	296
	<b>Glioma</b>	<b>Meningioma</b>	<b>No Tumor</b>	<b>Pituitary</b>

```

Sınıflandırma Raporu ==>
      precision    recall  f1-score   support

   glioma         0.90      0.93      0.92         300
 meningioma       0.93      0.87      0.90         306
  notumor         0.97      0.99      0.98         405
 pituitary        0.98      0.99      0.99         300

 accuracy                   0.95         1311
 macro avg                 0.95      0.94      0.94         1311
 weighted avg              0.95      0.95      0.95         1311

```

**Şekil 5.60:** Model 3-b-2 Sınıflandırma Raporu

Çizelge 5.20 ve şekil 5.60 incelediğinde model 3-b-2'nin 300 glioma test verisinden 280'ini, 305 meningioma verisinden 267'sini ,405 tümör olmayan veriden 399'unu,300 pituitary verisinden 296'sını doğru tahmin ettiği ve test veri seti için başarı oranının 0.95 olduğu görülmektedir.

- **Model 3-c**


```

ESA Modeli Tanımlama=ResNet152V2
Sıralı model oluşturma
Veri boyutlandırma
Tanımlanan ESA modelini ekleme
Düz Vektör Oluşturma
Veri Seyreltme (0.3)
Aktivasyon fonksiyonu =Tanh
Veri Seyreltme (0.2)
Sınıflandırma

```

**Şekil 5.61:** Model 3-c Yalancı (Pseudo Code) Kodu

Model 3-c de ResNet152V2 ESA modeli, Tanh aktivasyon fonksiyonu, optimizasyon fonksiyonu SGD ile hiperparametreler; çevrim sayısı 10, mini yığın boyutu 64 ve öğrenme katsayısı olarak 0.00001 seçilmiştir.



**Şekil 5.62:** Model 3-c Eğitim Veri Seti Başarı- Kayıp Grafiği

Şekil 5.62 de model 3-c'nin doğruluk oranı 0.5 civarında, kayıp oranı 1.24 civarındadır.

**Çizelge 5.21:** Model 3-c Karışıklık Matrisi

<b>Glioma</b>	148	67	37	48
<b>Meningioma</b>	62	89	74	81
<b>No Tumor</b>	25	19	343	18
<b>Pituitary</b>	22	29	23	226

**Glioma    Meningioma    No Tumor    Pituitary**

```
Sınıflandırma Raporu ==>
precision    recall  f1-score   support

   glioma     0.58    0.49    0.53     300
 meningioma  0.44    0.29    0.35     306
  notumor    0.72    0.85    0.78     405
 pituitary   0.61    0.75    0.67     300

 accuracy                    0.61     1311
 macro avg    0.58    0.60    0.58     1311
 weighted avg 0.59    0.61    0.60     1311
```

**Şekil 5.63:** Model 3-c Sınıflandırma Raporu

Çizelge 5.21 ve şekil 5.63 incelediğinde model 3-c'nin 300 glioma test verisinden 148'ini, 305 meningioma verisinden 289'unu, 405 tümör olmayan veriden 343'ünü, 300 pituitary verisinden 226'sını doğru tahmin ettiği ve test veri seti için başarı oranının 0.61 olduğu görülmektedir.

## 6. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında yaygın olarak görülen üç beyin tümörü çeşidi olan; Glioma, Meningioma ve Pituitary beyin tümörlerinin sınıflandırılmasında VGG 16, VGG19 ve ResNet152v2 ESA modelleri üzerinde çalışılmıştır.

Kullanılan veriler sıralı olmayan görüntü verisi olduğundan ESA mimarileri kullanılmıştır. ESA bu özellikteki verileri daha kullanılabilir ve işlenebilir hale kolay getirebildiğinden, ESA'nın özellik çıkarma yeteneği ve görüntü verilerinin yapısı, şekli gibi yapısal bilgilerini koruma özelliği yüksek olduğundan tercih edilmiştir. Bu çalışma ile Manyetik Rezonans görüntüleme tekniği kullanılarak elde edilen beyin görüntülerinin incelenmesi, hangi tür beyin tümör olduğunun hızlı bir şekilde anlaşılması amaçlanmaktadır. Modelin eğitimi için veriler 224X224 piksel olarak yeniden boyutlandırılmıştır.

Aktivasyon fonksiyonu olarak RELU, Sigmoid ve Tanh, optimizasyon fonksiyonu olarak ADAM, SGD ve RMSProp, kayıp fonksiyonu olarak seyrek kategorik çapraz entropi kullanılmıştır.

**Çizelge 6.1: Çalışılan Modellerin Sonuçları**

Model	ESA Modeli	Aktivasyon Fonksiyonu	Optimizasyon Fonksiyonu	Çevrim Sayısı	Yığın Boyutu	Öğrenme Katsayısı	Doğruluk Oranı
Model 1-b	VGG 16	SIGMOID	SGD	10	16	0.001	0.91
Model 1-b-1	VGG 19	SIGMOID	SGD	10	16	0.001	0.86
Model 1-b-2	ResNet152V2	SIGMOID	SGD	10	16	0.001	0.91
Model 2-a	VGG 19	RELU	SGD	20	32	0.0001	0.77
Model 2-b	VGG 19	SIGMOID	RMSProp	10	32	0.0001	0.95
Model 2-b-1	VGG 16	SIGMOID	RMSProp	10	32	0.0001	0.93
Model 2-b-2	ResNet152V2	SIGMOID	RMSProp	10	32	0.0001	0.96
Model 2-c	VGG 19	TANH	ADAM	15	32	0.0001	0.94
Model 2-c-1	VGG 16	TANH	ADAM	15	32	0.0001	0.99
Model 2-c-2	ResNet152V2	TANH	ADAM	15	32	0.0001	0.96
Model 3-a	ResNet152V2	RELU	RMSProp	15	64	0.00001	0.94
Model 3-a-1	VGG 16	RELU	RMSProp	15	64	0.00001	0.94
Model 3-a-2	VGG 19	RELU	RMSProp	15	64	0.00001	0.94
Model 3-b	ResNet152V2	SIGMOID	ADAM	20	64	0.00001	0.94
Model 3-b-1	VGG 16	SIGMOID	ADAM	20	64	0.00001	0.96
Model 3-b-2	VGG 19	SIGMOID	ADAM	20	65	0.00001	0.95
Model 3-c	ResNet152V2	TANH	SGD	10	64	0.00001	0.61


Bu çalışmanın sonuçları, farklı model mimarileri, aktivasyon fonksiyonları ve optimizasyon fonksiyonlarının kullanıldığı derin öğrenme modelinin performansını

değerlendirdiğini göstermektedir. İncelenen sonuçlar, VGG 16 modelinin %99 doğruluk oranı ile en başarılı model olduğunu ve özellikle Tanh aktivasyon fonksiyonu ile Adam optimizasyon fonksiyonu ile uyumlu olduğunu vurgulamaktadır. Bu sonuç, VGG 16'nın ESA (Evrışimli Sinir Ağı) modeli ile mükemmel bir uyum sağlayarak veri setindeki desenleri en iyi şekilde çıkardığını göstermektedir.

Ayrıca, sigmoid aktivasyon fonksiyonu ve RMSProp optimizasyon fonksiyonunun kullanıldığı diğer ESA modellerinin de başarılı sonuçlar elde ettiği belirtilmektedir. Özellikle ResNet152V2 ESA mimarisi, bu aktivasyon ve optimizasyon kombinasyonu ile en iyi sonuca ulaşmıştır. Bununla birlikte, RELU aktivasyon fonksiyonu ve RMSProp optimizasyon fonksiyonu kullanıldığında, kullanılan modeller benzer düzeyde performans sergilemiştir. Sonuç olarak, bu çalışma, Tanh aktivasyon fonksiyonu ve Adam optimizasyon fonksiyonunun VGG 16 ESA modeli için en iyi performansı sağladığını göstermektedir. Bu bulgular, derin öğrenme modelleri için aktivasyon ve optimizasyon seçimlerinin sonuçlara önemli ölçüde etki edebileceğini vurgulamaktadır. Model 2-c-1'de elde edilen 0.99'lük doğruluk oranı, model 2-b-2, model 2-c-2 ve model 3-b-1'de elde edilen 0.96 doğruluk oranları ile ESA mimarilerinin MR görüntü verileriyle kullanılmasının doğru bir yaklaşım olduğunu kanıtlamaktadır.

Bu çalışma, gelecekteki benzer çalışmalar için bir rehber olabilir ve model tasarımı için uygun seçenekleri göstermektedir.


Bu çalışma kapsamında tümör işaretleme de yapılmıştır.



**Şekil 6.1:** Glioma Tümörün Adının Doğru Tahmini ve Yerinin Belirlenmesi



**Şekil 6.2:** Meningioma Tümörün Adının Doğru Tahmini ve Yerinin Belirlenmesi



**Şekil 6.3:** Pituitary Tümörün Adının Doğru Tahmini ve Yerinin Belirlenmesi



**Şekil 6.4:** Tümör Olmayan Verinin Adının Doğru Tahmini ve Yerinin Belirlenmesi

Şekil 6.1,6.2,6.3 ve 6.4’de yapılan tez çalışması kapsamında tümör adının doğru tahmin edildiği tümör yerinin işaretlendiği görülmektedir.

Modelin eğitiminde daha yüksek doğruluk elde etmek için daha çok sayıda daha net beyin MR görüntü verisi temin edilerek veri sınıf sayısının artırılması sağlanmalıdır. Öğrenme aktarımı yönetimi kullanılarak diğer ESA (DenseNet, Inception vb.) daha yüksek seviyede doğruluk oranı elde edilebilir.

Sağlıkta yapay zekâ da yapılan çalışmaların kapsamı genişlemeye devam etmektedir. Bu anlamda derin öğrenme teknikleriyle nitelikli beyin tümörü tespiti çalışmalarının artması bu alana olan ilgiyi arttıracaktır.

## KAYNAKLAR

- Abbood, A. A., Shallal, Q. M., Fadhel, M. A. ve Shallal, Q. M.** (2021). Automated brain tumor classification using various deep learning models: a comparative study. *Indonesian Journal of Electrical Engineering and Computer Science*, 22(1), 252.
- Abraham, A.** (2005). Artificial neural networks. *Handbook of measuring system design*.
- Akbulut, H. ve Aslantaş, V.** (2023). Evrişimli sinir ağı kullanarak çoklu-pozlamalı görüntü birleştirme. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(3), 1439-1452.
- Almadhoun, H. R. ve Abu-Naser, S. S.** (2022). Detection of brain tumor using deep learning.
- Alnemer, A. ve Rasheed, J.** (2021, October). An Efficient Transfer Learning-based Model for Classification of Brain Tumor. In *2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 478-482). IEEE.
- Amin, J., Sharif, M., Yasmin, M. ve Fernandes, S. L.** (2020). A distinctive approach in brain tumor detection and classification using MRI. *Pattern Recognition Letters*, 139, 118-127.
- Apicella, A., Donnarumma, F., Isgrò, F. ve Prevete, R.** (2021). A survey on modern trainable activation functions. *Neural Networks*, 138, 14-32.
- Asif, S., Zhao, M., Chen, X. Ve Zhu, Y.** (2023). BMRI-NET: A Deep Stacked Ensemble Model for Multi-class Brain Tumor Classification from MRI Images. *Interdisciplinary Sciences: Computational Life Sciences*, 1-16.
- Ataseven, B.** (2013). Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10(39), 101-115.
- Atlan, F. ve Peñçe, İ.** (2021). Yapay Zekâ ve Tıbbi Görüntüleme Teknolojilerine Genel Bakış. *Acta Infologica*, 5(1), 207-230.
- Ayawah, P. E., Sebbeh-Newton, S., Azure, J. W., Kaba, A. G., Anani, A., Bansah, S. ve Zabidi, H.** (2022). A review and case study of Artificial intelligence and Machine learning methods used for ground condition prediction ahead of tunnel boring Machines. *Tunnelling and Underground Space Technology*, 125, 104497.
- Aydemir, E.** (2019). Ders Geçme Notlarının Veri Madenciliği Yöntemleriyle Tahmin Edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (15), 70-76.

- Bangard, C., Paszek, J., Berg, F., Eyl, G., Kessler, J., Lackner, K. ve Gossmann, A.** (2007). MR imaging of claustrophobic patients in an open 1.0 T scanner: motion artifacts and patient acceptability compared with closed bore magnets. *European journal of radiology*, 64(1), 152-157.
- Bankman, I. (Ed.).** (2008). *Handbook of medical image processing and analysis*. Elsevier.
- Bengio, Y.** (2009). Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1), 1-127.
- Biau, G.ve Scornet, E.** (2016). A random forest guided tour. *Test*, 25, 197-227.
- Bilgin, M.** (2017). Gerçek veri setlerinde klasik makine öğrenmesi yöntemlerinin performans analizi. *Breast*, 2(9), 683.
- Bircan, H.** (2004). Lojistik regresyon analizi: Tıp verileri üzerine bir uygulama. *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*, (8), 185-208.
- Bushberg, J. T ve Boone, J. M.** (2011). *The essential physics of medical imaging*. Lippincott Williams & Wilkins.
- Büyükoğuz, F. N.** (2021). *Taktik Çevre Simülasyon Programlarında Sanal Varlıkların Pekiştirmeli Öğrenme İle Eğitilmesi*. (Yayımlanmamış Yüksek Lisans Tezi), KTO Karatay Üniversitesi, Konya.
- Chen, S., Webb, G. I., Liu, L. ve Ma, X.** (2020). A novel selective naïve Bayes algorithm. *Knowledge-Based Systems*, 192, 105361.
- Clevert, D. A., Unterthiner, T. ve Hochreiter, S.** (2015). Fast and accurate deep network learning by exponential linear units (elus). *arXiv preprint arXiv:1511.07289*.
- Cruz, F., Twiefel, J., Magg, S., Weber, C. ve Wermter, S.** (2015, July). Interactive reinforcement learning through speech guidance in a domestic scenario. In *2015 international joint conference on neural networks (IJCNN)* (pp. 1-8). IEEE.
- Çetin, O., Temurtaş, F. ve Gülgönül, Ş.** (2015). An application of multilayer neural network on hepatitis disease diagnosis using approximations of sigmoid activation function. *Dicle Tıp Dergisi*, 42(2), 150-157.
- Çiğdem, A. C. I. ve Çırak, A.** (2019). Türkçe haber metinlerinin konvolüsyonel sinir ağları ve Word2Vec kullanılarak sınıflandırılması. *Bilişim Teknolojileri Dergisi*, 12(3), 219-228.
- Çifçi, M. A. ve Üzülmez, S.** Derin öğrenme ve belirsizlik ölççeği ile akciğer kanserinin erken teşhisi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 39(1), 385-400.
- Çuhadar, M.** (2006). *Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış Turizm Talebinde Uygulama)*, (Yayımlanmamış Doktora Tezi), Süleyman Demirel Üniversitesi, Isparta.
- Demir, B., Okutan, M. ve Demir, M.** (2009). Pozitron emisyon tomografi ve radyoterapi tedavi planlama. *Türk Onkoloji Dergisi*, 24(2), 88-97.

- Dikici, S. ve Altuntaş, V.** (2023). Yapay Sinir Ağları Kullanılarak Protein Katlanması Tanıma. *Bilişim Teknolojileri Dergisi*, 16(2), 95-105.
- Ding, B., Qian, H., ve Zhou, J.** (2018, June). Activation functions and their characteristics in deep neural networks. In *2018 Chinese control and decision conference (CCDC)* (pp. 1836-1841). IEEE.
- Domingues, P., González-Tablas, M., Otero, Á., Pascual, D., Miranda, D., Ruiz, L. ve Tabernero, M. D.** (2016). Tumor infiltrating immune cells in gliomas and meningiomas. *Brain, behavior, and immunity*, 53, 1-15.
- Elmas, Ç.** (2021) *Yapay Zekâ Uygulamaları*. Ankara: Seçkin Yayıncılık
- Ersoy, E. ve Karal, Ö.** (2012). Yapay sinir ağları ve insan beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2), 188-205.
- Erilli, N. A., Eğrioğlu, E., Yolcu, U., Aladağ, Ç. H. Ve Uslu, V. R.** (2010). Türkiye’de Enflasyonun İleri Ve Geri Beslemeli Yapay Sinir Ağlarının Melez Yaklaşımı İle Öngörüsü. *Doğuş Üniversitesi Dergisi*, 11(1), 42-55.
- Fatima, A. ve Pethe, A.** (2022). Periodic Analysis of Resistive Random Access Memory (RRAM)-Based Swish Activation Function. *SN Computer Science*, 3(3), 202.
- Fırat, H. ve Hanbay, D.** (2022). Hiperspektral görüntüler kullanılarak 3B ESA tabanlı derin öğrenme mimarilerinin karşılaştırılması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(1), 521-534.
- Fischbach, F., Bunke, J., Thormann, M., Gaffke, G., Jungnickel, K., Smink, J. ve Ricke, J.** (2011). MR-guided freehand biopsy of liver lesions with fast continuous imaging using a 1.0-T open MRI scanner: experience in 50 patients. *Cardiovascular and interventional radiology*, 34, 188-192.
- Frank, E., Trigg, L., Holmes, G. ve Witten, I. H.** (2000). Naive Bayes for regression. *Machine Learning*, 41, 5-25.
- Gassert, R., Yamamoto, A., Chapuis, D., Dovat, L., Bleuler, H. ve Burdet, E.** (2006). Actuation methods for applications in MR environments. *Concepts in Magnetic*
- Gazel, S. E. R. ve Bati, C. T.** (2019). Derin sinir ağları ile en iyi modelin belirlenmesi: mantar verileri üzerine keras uygulaması. *Yuzuncu Yıl University Journal of Agricultural Sciences*, 29(3), 406-417.
- Gordon-Rodriguez, E., Loaiza-Ganem, G., Pleiss, G. ve Cunningham, J. P.** (2020). Uses and abuses of the cross-entropy loss: Case studies in modern deep learning.
- Goodfellow, I., Bengio, Y. ve Courville, A.** (2016). *Deep learning*. MIT press.
- Resonance Part B: Magnetic Resonance Engineering: An Educational Journal**, 29(4), 191-209.
- Gulli, A. ve Pal, S.** (2017). *Deep learning with Keras*. Packt Publishing Ltd.
- Hamet, P. ve Tremblay, J.** (2017). Artificial intelligence in medicine. *Metabolism*, 69, ss36-40.

- Han-Trong, T., Nguyen Van, H., Nguyen Thi Thanh, H., Tran Anh, V., Nguyen Tuan, D. ve Vu Dang, L.** (2022). An Efficient Method for Diagnosing Brain Tumors Based on MRI Images Using Deep Convolutional Neural Networks. *Applied Computational Intelligence and Soft Computing*, 2022
- Harahap, M., Husein, A. M., Deol, S. S., Singh, S., Situmorang, S. D. ve Saputra, J.** (2022, October). Comparative Analysis of Deep Learning Approach for Detection and Segmentation of Brain Tumor. In *2022 IEEE International Conference of Computer Science and Information Technology (ICOSNIKOM)* (pp. 01-05). IEEE.
- He, K., Zhang, X., Ren, S. ve Sun, J.** (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Heaton, J.** (2015). *Artificial intelligence for humans*. Heaton Research, Inc.
- Herek, D. ve Karabulut, N.** (2010). Manyetik rezonans görüntüleme. *TTD Toraks Cerrahisi Bülteni*, 1(3), 214-222.
- Hüseyin, Ü. Z. E. N. ve Hanbay, K.** (2020). Yaya özellik tanıma için LM filtre temelli derin evrimsel sinir ağı. *Politeknik Dergisi*, 23(3), 605-613.
- Hristev, R. M.** (1998). *The ANN book*. This book is released under the GNU Public License, Alındığı tarih: 13.05.2023, adres: [http://www.pdg.cnb.uam.es/cursos/Complutense/Complutense2004/pages/12\\_NeuralNetworks/Hritsev\\_The\\_ANN\\_Book.pdf](http://www.pdg.cnb.uam.es/cursos/Complutense/Complutense2004/pages/12_NeuralNetworks/Hritsev_The_ANN_Book.pdf)
- Gökalp, Ö. M.** Makine öğrenmesi. *Gazi Üniversitesi, Gazi Bilişim Enstitüsü, Adli Bilişim Bölümü*.
- Güçlü, E., Aydın, İ. Ve Erhan, A. K. I. N.** (2022). DCGAN ve Siyam Sinir Ağını Kullanarak Demiryolu Bağlantı Elemanlarındaki Kusurların Tespiti. *Demiryolu Mühendisliği*, (15), 46-59.
- Gör, İclal,** (2016). Çok katmanlı algılayıcı yapay sinir ağı ile lineer diferansiyel denklem sisteminin çözümü. 18. *Akademik Bilişim Konferansı*, 738-745.
- İmamoğlu, N., Eresen, A. ve Efe, M. Ö.** (2009). Döner Ters Sarkaç Sisteminin Pekiştirmeli Öğrenme Algoritmaları ile Kontrolü. *Otomatik Kontrol Türk Milli Komitesi, Otomatik Kontrol Ulusal Toplantısı TOK'09*.
- Janiesch, C., Zschech, P. ve Heinrich, K.** (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695.
- Jensen, W. A.** (2008). Decision Trees for Business Intelligence and Data Mining: Using SAS® Enterprise Miner (TM). *Technometrics*, 50(3), 409.
- Kara, A.,** (2019). Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini. *Gazi University Journal of Science Part C: Design and Technology*, 7(4), 882-892.
- Kara, P. Ö., Koç, Z. P., Köksel, M. O. ve Ayan, E.,** (2018). Mediastinal Kitle Nedeniyle Malignite Araştırılan Bir Hastada Retrokardiyak Alanda FDG PET-BT Tetkikinde Saptanan Gossipiboma Görünümü. *Acıbadem Üniversitesi Sağlık Bilimleri Dergisi*, (4), 475-477.

- Karakurt, M. ve İşeri, İ.** (2022). Patoloji Görüntülerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (33), 192-206.
- Kaya, A., Keceli, A. S., Catal, C., Yalic, H. Y., Temucin, H. ve Tekinerdoğan, B.** (2019). Analysis of transfer learning for deep neural network based plant classification models. *Computers and electronics in agriculture*, 158, 20-29.
- Kelleher, J. D.** (2019). *Deep learning*. Boston: MIT press.
- Kingma, D. P. ve Ba, J.** (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Klingenbeck-Regn, K., Schaller, S., Flohr, T., Ohnesorge, B., Kopp, A. F.ve Baum, U.** (1999). Subsecond multi-slice computed tomography: basics and applications. *European journal of radiology*, 31(2), 110-124.
- Kölmek, M. A.** (2012). *Türkiye elektrik dengeleme ve uzlaştırma piyasasındaki sistem gün öncesi fiyatının yapay sinir ağları kullanılarak modellenmesi* (Yayımlanmamış Yüksek Lisans Tezi) Ankara Üniversitesi, Ankara.
- Krizhevsky, A., Sutskever, I. Ve Hinton, G. E.** (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Kukreja, H., Bharath, N., Siddesh, C. S. ve Kuldeep, S.** (2016). An introduction to artificial neural network. *Int J Adv Res Innov Ideas Educ*, 1, 27-30.
- Kural, T.** (2022). *Android Kötücül Yazılım Analizinde Derin Öğrenme Modellerinin Performansının Karşılaştırılması* (Yayımlanmamış Yüksek Lisans Tezi), Gazi Üniversitesi, Ankara.
- Lau, M. M. ve Lim, K. H.** (2018, December). Review of adaptive activation function in deep neural network. In *2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)* (pp. 686-690). IEEE.
- Latifoğlu, L. ve Nuralan, K. B.** (2020). Tekil spektrum analizi ve uzun-kısa süreli bellek ağları ile nehir akım tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, 376-381.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P.** (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- LeCun, Y., Bengio, Y. ve Hinton, G.** (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lewis, N. D.** (2016). Deep learning made easy with R: a gentle introduction for data science. (*No Title*).
- Lin, T. Y., Goyal, P., Girshick, R., He, K. ve Dollár, P.** (2017). Focal loss for dense object detection. In *Proceedings of the IEEE international conference on computer vision* (pp. 2980-2988).
- Liu, Y., Zhao, T., Ju, W.ve Shi, S.** (2017). Materials discovery and design using machine learning. *Journal of Materiomics*, 3(3), 159-177.

- Mahesh, B.** (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], 9(1), 381-386.
- Mete, O. ve Lopes, M. B.** (2017). Overview of the 2017 WHO classification of pituitary tumors. *Endocrine Pathology*, 28, 228-243.
- Mehrotra, K., Mohan, C. K. ve Ranka, S.** (1997). *Elements of artificial neural networks*. Boston: MIT press.
- Michelucci, U.** (2018). Applied deep learning. *A Case-Based Approach to Understanding Deep Neural Networks*.
- Mohsen, H., El-Dahshan, E. S. A., El-Horbaty, E. S. M. ve Salem, A. B. M.** (2018). Classification using deep learning neural networks for brain tumors. *Future Computing and Informatics Journal*, 3(1), 68-71.
- Moser, E., Stadlbauer, A., Windischberger, C., Quick, H. H. ve Ladd, M. E.** (2009). Magnetic resonance imaging methodology. *European journal of nuclear medicine and molecular imaging*, 36, 30-41.
- Msonda, P.** (2020). *Derin öğrenme tekniklerini kullanarak otomatik tüberküloz teşhisi* (Yayımlanmamış Yüksek Lisans Tezi), Konya Teknik Üniversitesi, Konya.
- Mustafa, T. A. N. ve Emeksiz, C.** (2023). Yüz Tanıma Sistemleri İçin Geliştirilmiş Veri Artırma Temelli Adaptif Yüz Tanıma Modeli. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(2), 588-606.
- Nguyen, T. H., Nguyen, T. N. ve Ngo, B. V.** (2022). A VGG-19 Model with Transfer Learning and Image Segmentation for Classification of Tomato Leaf Disease. *AgriEngineering*, 4(4), 871-887.
- Qodri, K. N., Soesanti, I. ve Nugroho, H. A.** (2021). Image analysis for MRI-based brain tumor classification using deep learning. *IJITEE (International Journal of Information Technology and Electrical Engineering)*, 5(1), 21-28.
- Oyar, Orhan,** (2008). Magnetik Rezonans Görüntüleme Mrg Nin Klinik Uygulamaları Ve Endikasyonları. *Harran Üniversitesi Tıp Fakültesi Dergisi*, 5 (2), 31-40.
- Özaydın, K. Ç.** *Evrışimli sinir ağları yöntemlerini kullanarak bitki tohum ve fidelerini sınıflandırma* (Yayımlanmamış Yüksek Lisans Tezi), Ankara Üniversitesi, Ankara.
- Öztel, İ.** (2018). *Kısmi ve tam yüz görüntüleri üzerinde makine öğrenmesi yöntemleriyle yüz ifadesi tespiti* (Yayımlanmamış Doktora Tezi), Sakarya Üniversitesi, Sakarya.
- Özkan, İ. N. İ. K. ve Ülker, E.** (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Öztemel, E.** (2020). *Yapay Sinir Ağları* İstanbul: Papatya Yayıncılık
- Öztürk, K. ve Şahin, M. E.** (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.

- Patterson, J. ve Gibson, A.** (2017). *Deep learning: A practitioner's approach.* " O'Reilly Media, Inc."
- Ramachandran, P., Zoph, B. ve Le, Q. V.** (2017). Searching for activation functions. *arXiv preprint arXiv:1710.05941.*
- Ruder, S.** (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747.*
- Saleh, R. A. ve Saleh, A. K.** (2022). Statistical properties of the log-cosh loss function used in machine learning. *arXiv preprint arXiv:2208.04564.*
- Salouhou, A.** (2019). *El yazısı karakter tanıma ve resim sınıflandırmada derin öğrenme yaklaşımları* (Yayımlanmamış Yüksek Lisans Tezi), Fatih Sultan Mehmet Vakıf Üniversitesi, İstanbul.
- Salur, M. U., Aydın, İ. ve Karaköse, M.** (2019). Gömülü derin öğrenme ile tehdit içeren nesnelere gerçek zamanda tespiti. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 497-509.
- Sezer, M.** (2007). *Yapay Sinir Ağları (YSA) Kullanılarak KOİ Parametresinden BOİ Parametresinin Tahmin Edilmesi* (Yayımlanmamış Doktora Tezi), Sakarya Üniversitesi, Sakarya
- Seyyarer, E., Ayata, F., Uçkan, T. ve Karci, A.** (2020). Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması. *Computer Science*, 5(2), 90-98.
- Sethy, P. K. ve Behera, S. K.** (2020). Detection of coronavirus disease (covid-19) based on deep features.
- Sharma, S., Sharma, S. ve Athaiya, A.** (2017). Activation functions in neural networks. *Towards Data Sci*, 6(12), 310-316.
- Sharma, N., Sharma, R. ve Jindal, N.** (2021). Machine learning and deep learning applications-a vision. *Global Transitions Proceedings*, 2(1), 24-28.
- Sharma, S., Gupta, S., Gupta, D., Juneja, A., Khatter, H., Malik, S. ve Bitsue, Z. K.** (2022). Deep Learning Model for Automatic Classification and Prediction of Brain Tumor. *Journal of Sensors*, 2022.
- Shaik, N. S. ve Cherukuri, T. K.** (2022). Multi-level attention network: application to brain tumor classification. *Signal, Image and Video Processing*, 16(3), 817-824.
- Shi, B., Hou, R., Mazurowski, M. A., Grimm, L. J., Ren, Y., Marks, J. R., ... ve Lo, J. Y.** (2018, February). Learning better deep features for the prediction of occult invasive disease in ductal carcinoma in situ through transfer learning. In *Medical imaging 2018: computer-aided diagnosis* (Vol. 10575, pp. 620-625). SPIE.
- Swati Z N K, Zhao Q, Kabir M, Ali F, Ali Z, Ahmed S, Lu J.** Brain tumor classification for MR images using transfer learning and fine-tuning. *Computerized Medical Imaging and Graphics* 2019; 75: 34-46.
- Simonyan, K., Zisserman, A.**, Very deep convolutional networks for large-scale image recognition, arXiv Prepr. arXiv1409.1556, 2014.

- Srinivas, C., KS, N. P., Zakariah, M., Alothaibi, Y. A., Shaukat, K., Partibane, B. ve Awal, H.** (2022). Deep transfer learning approaches in performance analysis of brain tumor classification using MRI images. *Journal of Healthcare Engineering*, 2022.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R.** (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Song, Y., Goncalves, L.ve Perona, P.** (2003). Unsupervised learning of human motion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 25(7), 814-827.
- Sun, S. ve Huang, R.** (2010, August). An adaptive k-nearest neighbor algorithm. In *2010 seventh international conference on fuzzy systems and knowledge discovery* (Vol. 1, pp. 91-94). IEEE.
- Sürmen, H. K.** (2022). Bilgisayarlı Tomografi İle Üç Boyutlu (3B) Tarama. *Uluslararası Batı Karadeniz Mühendislik ve Fen Bilimleri Dergisi*, 4(2), 1-21.
- Szabo, T. L.** (2004). *Diagnostic ultrasound imaging: inside out*. Academic press.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A.** (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9). doi:10.1109/cvpr.2015.7298594
- A.Şener, B.Ergen** (2022). *Beyin MR Görüntüleri Üzerinde Tümör Tespitinde VGG-19 Model Tabanlı Yeni Bir Yaklaşım*, 6. Uluslararası Yapay Zekâ ve Veri İşleme Sempozyumu, Malatya
- Şeker, A., Diri, B., ve Balık, H. H.** (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Tasci, B.** (2022). Beyin Mr Görüntülerinden Mırmır Tabanlı Beyin Tümörlerinin Sınıflandırması. *Journal of Scientific Reports-B*, (006), 1-9.
- Taşar, B., Fatih, Ü. N. E. Ş., Demirci, M. ve Kaya, Y. Z.** (2018). Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 9(1), 543-551.
- Taunk, K., De, S., Verma, S. ve Swetapadma, A.** (2019, May). A brief review of nearest neighbor algorithm for learning and classification. In *2019 international conference on intelligent computing and control systems (ICCS)* (pp. 1255-1260). IEEE.
- Turhan, M. M. ve Talu, M. F.** (2022). Adaptif Sigmoid, Lojistik Sigmoid ve Tanjant Hiperbolik Aktivasyon Fonksiyonların Tam Bağlı ve Konvolüsyonel Sinir Ağlarında Kıyaslanması. *Muş Alparslan Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 3(2), 89-101.
- Uysal, N.** (2020). *Zeytin yaprağındaki hastalıkların derin öğrenme teknikleri kullanılarak sınıflandırılması* (Yayımlanmamış Yüksek Lisans Tezi), Lisansüstü Eğitim Enstitüsü), Isparta Uygulamalı Bilimler Üniversitesi
- Ünal, Z.** (2022) *Derin Öğrenme*. Ankara: Nobel Yayıncılık

- Valero-Carreras, D., Alcaraz, J. ve Landete, M.** (2023). Comparing two SVM models through different metrics based on the confusion matrix. *Computers & Operations Research*, 152, 106131.
- Van Tellingen, O., Yetkin-Arik, B., De Gooijer, M. C., Wesseling, P., Wurdinger, T. ve De Vries, H. E.** (2015). Overcoming the blood–brain tumor barrier for effective glioblastoma treatment. *Drug Resistance Updates*, 19, 1-12.
- Vande Berg, B. C., Malghem, J., Lecouvet, F. E. ve Maldague, B.** (1998). Magnetic resonance imaging of the normal bone marrow. *Skeletal radiology*, 27, 471-483.
- Varshney, M.ve Singh, P.** (2021). Optimizing nonlinear activation function for convolutional neural networks. *Signal, Image and Video Processing*, 15(6), 1323-1330.
- Wen, Q., Yang, Z., Song, Y. ve Jia, P.** (2010). Automatic stock decision support system based on box theory and SVM algorithm. *Expert systems with Applications*, 37(2), 1015-1022.
- Wu, Z., Shen, C. ve Van Den Hengel, A.** (2019). Wider or deeper: Revisiting the resnet model for visual recognition. *Pattern Recognition*, 90, 119-133.
- Xu, J., Li, Z., Du, B., Zhang, M. ve Liu, J.** (2020, July). Reluplex made more practical: Leaky ReLU. In *2020 IEEE Symposium on Computers and communications (ISCC)* (pp. 1-7). IEEE.
- Yağmur, N.** (2020). *Gradyan iniş yöntemi ve kontrol sistemlerinde uygulamaları* (Yayımlanmamış Yüksek Lisans Tezi, İnönü Üniversitesi Fen Bilimleri Enstitüsü).
- Yakıncı, Z. D.** (2013). Süper iletkenlik ve Maneytik Rezonans Cihazı. *İnönü Üniversitesi Sağlık Hizmetleri Meslek Yüksek Okulu Dergisi*, 1(2), 1-6.
- Yılmaz, A.** (2020) *Yapay Zekâ*. İstanbul: Kodlab Yayıncılık
- Yani, M., Budhi Irawan, S. S. M. ve Casi Setiningsih, S. M.** (2019, May). Application of transfer learning using convolutional neural network method for early detection of terry's nail. In *Journal of Physics: Conference Series* (Vol. 1201, No. 1, p. 012052). IOP Publishing.
- Yılmaz, A. ve Kaya, U.** (2019) *Derin Öğrenme*. İstanbul: KodlabYayıncılık
- Yücesoy, M.** (2011). *Temizlik kağıtları sektöründe yapay sinir ağları ile talep tahmini* (Yayımlanmamış Doktora Tezi), İ.T.Ü, Fen Bilimleri Enstitüsü).
- Zeiler, M. D.** (2012). Adadelata: an adaptive learning rate method. *arXiv preprint arXiv:1212.5701*.
- Zeiler, M. D. ve Fergus, R.** (2014). Visualizing and understanding convolutional networks. In *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I 13* (pp. 818-833). Springer International Publishing.
- Zhang, A., Lipton, Z. C., Li, M. ve Smola, A. J.** (2021). Dive into deep learning. arXiv 2021. *arXiv preprint arXiv:2106.11342*.

**Zhang, Q., Yu, H., Barbiero, M., Wang, B. ve Gu, M.** (2019). Artificial neural networks enabled by nanophotonics. *Light: Science & Applications*, 8(1), 42.

**Zorman, M., Podgorelec, V., Kokol, P., Peterson, M., Šprogar, M. ve Ojsteršek, M.** (2001). Finding the right decision tree's induction strategy for a hard real world problem. *International journal of medical informatics*, 63(1-2), 109-121.

### **İnternet**

**Url-1:** <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>, alındığı tarih:16.05.2023



## ÖZGEÇMİŞ

### ÖĞRENİM DURUMU:

- **Lisans:** 2016, İstanbul Üniversitesi Açık ve Uzaktan Eğitim Fakültesi, Endüstri Mühendisliği Bölümü

