



**AKCİĞER BT GÖRÜNTÜLERİNDEN TÜMÖRLÜ VERİLERİN
FARKLI DERİN ÖĞRENME MODELLERİYLE TAHMİNİ**

(Yüksek Lisans Tezi)

Volkan ÇETİN

Kütahya-2024

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

Yüksek Lisans Tezi

**AKCİĞER BT GÖRÜNTÜLERİNDEN TÜMÖRLÜ VERİLERİN
FARKLI DERİN ÖĞRENME MODELLERİYLE TAHMİNİ**

Danışman:
Dr. Öğr. Üyesi Çiğdem BAKIR

Hazırlayan:
Volkan ÇETİN

Kütahya-2024

Kabul ve Onay

KÜTAHYA DUMLUPINAR ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalında, 202285151037 öğrenci numaralı, Volkan ÇETİN'in hazırlamış olduğu “*AKCİĞER BT GÖRÜNTÜLERİNDEN TÜMÖRLÜ VERİLERİN FARKLI DERİN ÖĞRENME MODELLERİYLE TAHMİNİ*” başlıklı yüksek lisans tez çalışması ile ilgili tez savunma sınavı jüri tarafından yapılmış ve adayın tezinin OY BİRLİĞİ ile kabul edilmesine karar verilmiştir.

10/07/ 2024

Tez Jürisi	İmza	
	Kabul	Ret
Dr. Öğr. Üyesi Çiğdem BAKIR (Danışman)		
Dr. Öğr. Üyesi Soydan SERTTAŞ		
Dr. Öğr. Üyesi Emre GÜNGÖR		

Onay

Doç. Dr. Eray ACAR

Enstitü Müdürü

Bilimsel Etik Bildirimi

Yüksek Lisans tezi olarak hazırladığım “*Akciğer BT Görüntülerinden Tümörlü Verilerin Farklı Derin Öğrenme Modelleriyle Tahmini*” adlı çalışmanın öneri aşamasından sonuçlandığı aşamaya kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığımı, bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

10/07/2024

Volkan ÇETİN

Özgeçmiş

İlkokulu Eskişehir Ziya Gökalp ilköğretim okulunda, ortaokulu Eskişehir Murat Atılgan ilköğretim okulunda, lise eğitimini Eskişehir Cumhuriyet Lisesinde, lisans eğitimini Ahmet Yesevi Üniversitesi Mühendislik Fakültesi Yönetim Bilişim Sistemleri bölümünde tamamlamıştır.



ÖZET

AKCİĞER BT GÖRÜNTÜLERİNDEN TÜMÖRLÜ VERİLERİN FARKLI DERİN ÖĞRENME MODELLERİYLE TAHMİNİ

ÇETİN, Volkan

Yüksek Lisans Tezi, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Çiğdem BAKIR

Temmuz, 2024 148 sayfa

Günümüzde sıkça karşılaşılan akciğer tümörleri insanlarda ölümlere yol açabilen tehlikeli bir hastalıktır. Akciğer tümörlerine doğru ve erken teşhis koyulması akciğer kanserinin önlenmesinde ve tedavisinde oldukça önemlidir. Ayrıca erken ve doğru teşhis ile kansere yakalanan hastaların yaşama şansı artar. Bu kanser türü manyetik rezonans (MR), pozitron emisyon tomografisi (PET) ve bilgisayarlı tomografi (BT) gibi tıbbi görüntüleme yöntemleriyle tespit edilir ve doktorlar bu hastalığa yakalanan hastaların takibi ve tedavisini manuel bir şekilde gerçekleştirir. Ancak çoğu zaman manuel yapılan tetkikler yanlış teşhise sebep verebilir ve böylelikle kişilerin sağlığı riske girebilir. Bilgisayar destekli analizler erken kanser teşhisi için önemli bir yere sahiptir ve bu analizlerin doğru, hızlı ve ayrıntılı yapılması erken tanı ve tedavi süreçleri için oldukça önemlidir. Böyle bir uygulama aynı zamanda sağlıkta bu alanda çalışan doktorlara önemli katkılar sağlayabilir. Klasik yöntemler yerine derin öğrenme temelli bilgisayar destekli yapılan uygulamalar akciğer tümörlerinin bu alanda çalışan uzmanlar için büyük fayda sağlar. Bu çalışmada, akciğer hastalıkları üzerine yapılan araştırmalar detaylı bir şekilde ele alınmıştır.

Çalışmanın ilk aşamasında, 1190 akciğer tomografisi görüntüsü derin öğrenme modelleri için hazırlanmış ve ön işlemleri tamamlanmıştır. İkinci aşamada ise Evrişimli Sinir Ağı (CNN), Derin Sinir Ağları (DNN), ResNet, Xception, AlexNet, VGG16 ve MobileNet gibi farklı derin öğrenme modelleri kullanılarak normal akciğer görüntüleri ile çeşitli akciğer tümörlerinin tespiti yapılmıştır. Kullanılan derin öğrenme yöntemleri farklı ağ yapısı ile modellenmiştir ve farklı tümörler bu ağ yapısıyla hızlı ve doğru bir şekilde sınıflandırılmıştır.

Önerilen DNN, CNN, ResNet, Xception, AlexNet VGG16 ve MobileNet modelleri için kullanılan katmanlar, parametre değerleri, sınıflandırma doğruluğu ve kayıp grafikleri ayrı ayrı gösterilmiştir. Her bir modelin doğruluk, hassasiyet, kesinlik ve F1 skoru gibi çeşitli değerlendirme metrikleri kullanılarak performansı hesaplanmış ve

sonular karřılařtırılmıřtır. Ayrıca her model iin eēitim, test ve geerleme grntleri zerinde karmařıklık matrisleri ve ROC analizleri ile performans analizleri gerekleřtirilmiřtir. nerilen derin ērenme modellerinden DNN, CNN, ResNet, Xception, AlexNet, VGG16 ve MobileNet modellerinin test bařarıları sırasıyla %98.18, %98.18, %95.15, %89.09, %82.42, %92.12 ve %96.36 olarak bulunmuřtur.

Anahtar Kelimeler: Akciēer Kanseri, Derin ērenme, Doēruluk, Evriřimsel Sinir Aēı, Tmr



ABSTRACT**PREDICTION OF TUMOR DATA FROM LUNG CT IMAGES WITH
DIFFERENT DEEP LEARNING MODELS****ÇETİN, Volkan****Master Thesis, Department of Computer Engineering****Supervisor: Assis. Dr. Çiğdem BAKIR****July, 2024, 148 pages**

Lung tumors, which are frequently encountered today, are a dangerous disease that can lead to death in humans. Accurate and early diagnosis of lung tumors is very important in the prevention and treatment of lung cancer. In addition, with early and accurate diagnosis, the chances of survival of patients with cancer increase. This type of cancer is detected by medical imaging methods such as magnetic resonance (MR), positron emission tomography (PET) and computed tomography (CT), and doctors manually follow up and treat patients with this disease. However, manual examinations can often lead to incorrect diagnosis, thus putting people's health at risk. Computer-aided analyses have an important place in early cancer diagnosis, and accurate, rapid and detailed analyses are very important for early diagnosis and treatment processes.

Such an application can also make significant contributions to doctors working in this field of health. first stage of the study, 1190 lung tomography images were prepared for deep learning models and their pre-processing was completed. In the second stage, different deep learning models such as Convolutional Neural Network (CNN), Deep Neural Network (DNN), ResNet, Xception, AlexNet, VGG16 and MobileNet were used to detect various lung tumors with normal lung images.

The deep learning methods used were modeled with different network structures and different tumors were classified quickly and accurately with this network structure. The layers, parameter values, classification accuracy and loss graphs used for the proposed DNN, CNN, ResNet, Xception, AlexNet VGG16 and MobileNet models are shown separately. The performance of each model was calculated using various evaluation metrics such as accuracy, precision, accuracy and F1 score and the results were compared. In addition, performance analyses were performed with complexity matrices and ROC analyses on training, test and validation images for each model. The test successes of the proposed deep learning models DNN, CNN, ResNet, Xception, AlexNet,

VGG16 and MobileNet were found to be 98.18%, 98.18%, 95.15%, 89.09%, 82.42%, 92.12% and 96.36%, respectively.

Keywords: Lung Cancer, Deep Learning, Accuracy, Convolutional Neural Network, Tumor



ÖNSÖZ

Bu yüksek lisans tez çalışmasında verdikleri desteklerden ötürü, saygıdeğer danışman hocam Dr. Öğr. Üyesi Çiğdem BAKIR'a teşekkür ediyorum.

Aynı zamanda bu süreçte, hiçbir zaman yanımdan ayrılmayan, desteklerini esirgemeyen aileme beni bu süreçte destekledikleri ve her zaman yanımda oldukları için çok teşekkür ederim.

10/07/2024

Volkan ÇETİN



İÇİNDEKİLER

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

BİRİNCİ BÖLÜM

LİTERATÜR ARAŞTIRMASI

1.1. İLGİLİ ÇALIŞMALAR	6
------------------------------	---

İKİNCİ BÖLÜM

GENEL BİLGİLER

2.1. AKCİĞER KANSERİ	13
2.1.1. Akciğer Kanserinin Türleri	13
2.1.2. Akciğer Kanseri Belirtileri	14
2.1.3. Akciğer Kanseri Nedenleri.....	15
2.1.4. Akciğer Kanseri Evreleri.....	15
2.1.4.1. Küçük Hücreli Olmayan Akciğer Kanseri Evreleri	16
2.1.4.2. Küçük Hücreli Akciğer Kanseri Evreleri.....	17
2.1.5. Akciğer Kanserinde Görüntüleme Yöntemleri	18
2.1.6. Akciğer Kanserinde Tanı ve Tedavi	18
2.2. YAPAY ZEKA VE MAKİNE ÖĞRENİMİ YÖNTEMLERİ.....	20
2.2.1. Makine Öğrenimi	20
2.2.2.1. Denetimli Makine Öğrenimi (Kontrollü Öğrenme)	21
2.2.2.2. Denetimsiz Makine Öğrenimi (Kontrolsüz Öğrenme).....	21
2.2.2.3. Yarı Denetimli Makine Öğrenimi	22
2.2.2.4. Güçlendirme Öğrenimi	23
2.3. DERİN ÖĞRENME.....	24
2.3.1. Evrişimsel Sinir Ağları (CNN) Derin Öğrenme Modeli ve Çalışma Prensibi ..	25
2.3.2. DNN Derin Öğrenme Modeli ve Çalışma Prensibi.....	33
2.3.3. AlexNet Derin Öğrenme Modeli ve Çalışma Prensibi.....	34
2.3.4. VGG 19 Derin Öğrenme Modeli ve Çalışma Prensibi.....	38
2.3.5. VGG 16 Derin Öğrenme Modeli ve VGG 19 ile Arasındaki Farklar	40
2.3.6. YOLO Derin Öğrenme Modeli ve Çalışma Prensibi	42
2.3.7. YOLOv2 Derin Öğrenme Modeli ve Çalışma Prensibi	43
2.3.8. YOLOv3 Derin Öğrenme Modeli ve Çalışma Prensibi	44
2.3.9. YOLOv4 Derin Öğrenme Modeli ve Çalışma Prensibi	46
2.3.10. YOLOv5 Derin Öğrenme Modeli ve Çalışma Prensibi	47

2.3.11. YOLOv6 Derin Öğrenme Modeli ve Çalışma Prensibi	49
2.3.12. YOLOv7 Derin Öğrenme Modeli ve Çalışma Prensibi	51
2.3.13. YOLOv8 Derin Öğrenme Modeli ve Çalışma Prensibi	51
2.3.14. Mask R-CNN Derin Öğrenme Modeli ve Çalışma Prensibi	52
2.3.15. SSD Derin Öğrenme Modeli ve Çalışma Prensibi	54
2.3.16. ResNet Derin Öğrenme Modeli ve Çalışma Prensibi	56
2.3.17. Xception Derin Öğrenme Modeli ve Çalışma Prensibi	57
2.3.18. MobileNet Derin Öğrenme Modeli ve Çalışma Prensibi	58

ÜÇÜNCÜ BÖLÜM

MATERYAL VE METOT

3.1. VERİ SETİ VE ÖNERİLEN MODEL.....	61
3.2. OLUŞTURULAN MODELLER.....	64
3.2.1. DNN	64
3.2.2. CNN	65
3.2.3. ResNET	67
3.2.4. Xception	68
3.2.5. AlexNET	69
3.2.6. VGG16	71
3.2.7. MobileNetV2.....	72
3.3. DEĞERLENDİRME METRİKLERİ.....	74

DÖRDÜNCÜ BÖLÜM

BULGULAR VE DENEYSEL SONUÇLAR

4.1. DENEYSEL ÇALIŞMA	77
4.1.1. DNN Sonuçları.....	77
4.1.2. CNN Sonuçları	82
4.1.3. ResNET101 Sonuçları.....	88
4.1.4. Xception Sonuçları.....	94
4.1.5. AlexNET Sonuçları	100
4.1.6. VGG16 Sonuçları.....	106
4.1.7. MobileNet Sonuçları	112

BEŞİNCİ BÖLÜM

SONUÇ VE TARTIŞMA

5.1. SONUÇ VE TARTIŞMA.....	120
KAYNAKÇA	123
DİZİN	128

TABLolar LİSTESİ

Sayfa

Tablo 2.1: Darknet-19 Mimarisi	44
Tablo 3.1: DNN, CNN, AlexNet, VGG16 ve MobileNet için Tüm Sınıflara Ait Eğitim, Test ve Doğrulama Verileri.....	63
Tablo 3.2: ResNet, Xception Modeli için Tüm Sınıflara Ait Eğitim, Test ve Doğrulama Verileri	63
Tablo 3.3: Önerilen DNN Modeli Parametleri.....	65
Tablo 3.4: Önerilen CNN Modeli Parametreleri.....	66
Tablo 3.5: Önerilen Resnet Modeli Parametreleri	67
Tablo 3.6: Önerilen Xception Modeli Parametreleri.....	68
Tablo 3.7: Önerilen Alexnet Modeli Kullanılan Katmanlar	71
Tablo 3.8: Önerilen Alexnet Modeli Parametreleri.....	71
Tablo 3.9: Önerilen VGG 16 Modeli Parametreleri.....	72
Tablo 3.10: Önerilen Mobilenet Modeli Parametreleri.....	73
Tablo 4.1: Önerilen DNN Derin Öğrenme Modelinin Sınıflandırma Başarısı (%)	77
Tablo 4.2: Eğitim ve Valid İçin Sınıflandırma Raporu	80
Tablo 4.3: Önerilen CNN Derin Öğrenme Modelinin Sınıflandırma Başarısı (%)	83
Tablo 4.4: Eğitim ve Valid İçin Sınıflandırma Raporu	86
Tablo 4.5: Önerilen Resnet101 Derin Öğrenme Modelinin Sınıflandırma Başarısı (%).....	88
Tablo 4.6: Eğitim ve Valid İçin Sınıflandırma Raporu	92
Tablo 4.7: Önerilen Xception Derin Öğrenme Modelinin Sınıflandırma Başarısı (%).....	94
Tablo 4.8: Eğitim ve Valid İçin Sınıflandırma Raporu	98
Tablo 4.9: Önerilen Alexnet Derin Öğrenme Modelinin Sınıflandırma Başarısı (%).....	100
Tablo 4.10: Eğitim ve Valid İçin Sınıflandırma Raporu	104
Tablo 4.11: Önerilen VGG16 Derin Öğrenme Modelinin Sınıflandırma Başarısı (%).....	106
Tablo 4.12: Eğitim ve Valid İçin Sınıflandırma Raporu	110
Tablo 4.13: Önerilen Mobilenet Derin Öğrenme Modelinin Sınıflandırma Başarısı (%).....	112
Tablo 4.14: Eğitim ve Valid İçin Sınıflandırma Raporu	116

Tablo 5.1: Önerilen Tüm Derin Öğrenme Modellerinin Sınıflandırma Başarısı (%) ..120

Tablo 5.2: Önerilen Modeller İle Literatürde Yapılan Bazı Çalışmaların Sonuçları ...121



ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1: Akciğer Kanseriyle Uyumlu Kitlesel Lezyonlar Görülen Bir Akciğer	
Grafisi.....	13
Şekil 2.2: Akciğer Kanseri Evreleri.....	16
Şekil 2.3: Denetimli Makine Öğrenimi	21
Şekil 2.4: Denetimsiz Makine Öğrenimi	22
Şekil 2.5: Yarı Denetimli Makine Öğrenimi	23
Şekil 2.6: Güçlendirme Öğrenimi.....	24
Şekil 2.7: Evrişimli Sinir Ağları Yapısı.....	25
Şekil 2.8: CNN Mimarisi ve Katmanları	26
Şekil 2.9: Evrişimli Katman Çalışma Prensibi	27
Şekil 2.10: Evrişimli Katman Çalışma Prensibi	27
Şekil 2.11: Doğrulama İşlemi	28
Şekil 2.12: Havuzlama Katmanı Çalışma Prensibi.....	31
Şekil 2.13: Tam Bağlantı Katmanı Çalışma Prensibi	32
Şekil 2.14: VGG 16 Katmanlı Mimari Yapısı.....	41
Şekil 2.15: YOLO Mimarisi	43
Şekil 2.16: YOLOv3 Mimarisi	45
Şekil 2.17: YOLOv4 Mimarisi	46
Şekil 2.18: Gerçek Zamanlı Çoklu Obje Takipçisi (Multi Object Tracker)	
Oluşturabilmek İçin Örnek Kod Satırı	49
Şekil 2.19: YOLOv6 Decoupled Head	50
Şekil 2.20: Mask-RCNN Mimarisi	53
Şekil 2.21: ResNet50 Mimarisi	56
Şekil 2.22: Xception Mimarisi.....	58
Şekil 3.1: Akciğer Kanseri İçin Kullanılan Verilerden Görüntüler	62
Şekil 3.2: Akciğer Görüntülerin Sınıflar İçerisinde Dağılımları	62
Şekil 3.3: Önerilen Modellerin İş Akış Bloğu	64
Şekil 3.4: Önerilen DNN Modeli.....	65
Şekil 3.5: Önerilen CNN Modeli	66
Şekil 3.6: Önerilen ResNet101 Modeli.....	67
Şekil 3.7: Önerilen Xception Modeli.....	68
Şekil 3.8: Önerilen AlexNet Modeli.....	70

Şekil 3.9: Önerilen VGG 16 Modeli.....	72
Şekil 3.10: Önerilen MobileNetV2 Modeli	73
Şekil 4.1: Önerilen DNN İçin Cross Entropy Loss.....	77
Şekil 4.2: Önerilen DNN İçin Classification Accuracy.....	78
Şekil 4.3: Tüm Veri İçin Karmaşıklık Matrisi.....	78
Şekil 4.4: Eğitim Verisi İçin Karmaşıklık Matrisi.....	79
Şekil 4.5: Valid Verisi İçin Karmaşıklık Matrisi.....	79
Şekil 4.6: Test Verisi İçin Karmaşıklık Matrisi.....	80
Şekil 4.7: Tüm Veri İçin ROC Analizi	81
Şekil 4.8: Eğitim Verisi İçin ROC Analizi	81
Şekil 4.9: Valid İçin ROC Analizi.....	82
Şekil 4.10: Test Verisi İçin ROC Analizi	82
Şekil 4.11: Önerilen CNN için Cross Entropy Loss	83
Şekil 4.12: Önerilen CNN İçin Classification Accuracy	83
Şekil 4.13: Tüm Veri İçin Karmaşıklık Matrisi.....	84
Şekil 4.14: Eğitim Verisi İçin Karmaşıklık Matrisi.....	84
Şekil 4.15: Valid İçin Karmaşıklık Matrisi	85
Şekil 4.16: Test Verisi İçin Karmaşıklık Matrisi.....	85
Şekil 4.17: Tüm Veri İçin ROC Analizi	86
Şekil 4.18: Eğitim Verisi İçin ROC Analizi	87
Şekil 4.19: Valid İçin ROC Analizi.....	87
Şekil 4.20: Test Verisi İçin ROC Analizi	88
Şekil 4.21: Önerilen Resnet101 İçin Cross Entropy Loss	89
Şekil 4.22: Önerilen Resnet101 İçin Classification Accuracy.....	89
Şekil 4.23: Tüm Veri İçin Karmaşıklık Matrisi.....	90
Şekil 4.24: Eğitim Verisi İçin Karmaşıklık Matrisi.....	90
Şekil 4.25: Valid Verisi İçin Karmaşıklık Matrisi.....	91
Şekil 4.26: Test Verisi İçin Karmaşıklık Matrisi.....	91
Şekil 4.27: Tüm Veri İçin ROC Analizi	92
Şekil 4.28: Eğitim Verisi İçin ROC Analizi	93
Şekil 4.29: Valid İçin ROC Analizi.....	93
Şekil 4.30: Test Verisi İçin ROC Analizi	94
Şekil 4.31: Önerilen Xception İçin Cross Entropy Loss.....	95
Şekil 4.32: Önerilen Xception İçin Classification Accuracy.....	95

Şekil 4.33: Tüm Veri İçin Karmaşıklık Matrisi.....	96
Şekil 4.34: Eğitim Verisi İçin Karmaşıklık Matrisi.....	96
Şekil 4.35: Valid İçin Karmaşıklık Matrisi	97
Şekil 4.36: Test Verisi İçin Karmaşıklık Matrisi.....	97
Şekil 4.37: Tüm Veri İçin ROC Analizi	98
Şekil 4.38: Eğitim Verisi İçin ROC Analizi	99
Şekil 4.39: Valid İçin ROC Analizi	99
Şekil 4.40: Test Verisi İçin ROC Analizi	100
Şekil 4.41: Önerilen Alexnet İçin Cross Entropy Loss	101
Şekil 4.42: Önerilen Alexnet İçin Classification Accuracy.....	101
Şekil 4.43: Tüm Veri İçin Karmaşıklık Matrisi.....	102
Şekil 4.44: Eğitim Verisi İçin Karmaşıklık Matrisi.....	102
Şekil 4.45: Valid İçin Karmaşıklık Matrisi	103
Şekil 4.46: Test Verisi İçin Karmaşıklık Matrisi.....	103
Şekil 4.47: Tüm Veri İçin ROC Analizi	104
Şekil 4.48: Eğitim Verisi İçin ROC Analizi	105
Şekil 4.49: Valid İçin ROC Analizi.....	105
Şekil 4.50: Test Verisi İçin ROC Analizi	106
Şekil 4.51: Önerilen VGG16 İçin Cross Entropy Loss	107
Şekil 4.52: Önerilen VGG16 İçin Classification Accuracy.....	107
Şekil 4.53: Tüm Veri İçin Karmaşıklık Matrisi.....	108
Şekil 4.54: Eğitim Verisi İçin Karmaşıklık Matrisi.....	108
Şekil 4.55: Valid İçin Karmaşıklık Matrisi	109
Şekil 4.56: Test Verisi İçin Karmaşıklık Matrisi.....	109
Şekil 4.57: Tüm Veri İçin ROC Analizi	110
Şekil 4.58: Eğitim Verisi İçin ROC Analizi	111
Şekil 4.59: Valid İçin ROC Analizi.....	111
Şekil 4.60: Test Verisi İçin ROC Analizi	112
Şekil 4.61: Önerilen Mobilenet İçin Cross Entropy Loss.....	113
Şekil 4.62: Önerilen Mobilenet İçin Classification Accuracy	113
Şekil 4.63: Tüm Veri İçin Karmaşıklık Matrisi.....	114
Şekil 4.64: Eğitim Verisi İçin Karmaşıklık Matrisi.....	114
Şekil 4.65: Valid Verisi İçin Karmaşıklık Matrisi.....	115
Şekil 4.66: Test Verisi İçin Karmaşıklık Matrisi.....	115

Şekil 4.67: Tüm Veri İçin ROC Analizi	116
Şekil 4.68: Eğitim Verisi İçin ROC Analizi	117
Şekil 4.69: Valid İçin ROC Analizi	117
Şekil 4.70: Test Verisi İçin ROC Analizi	118
Şekil 5.1: Önerilen Modellerin Başarısı (%)	120



KISALTMALAR

CNN	Convolutional Neural Network
DNN	Deep Neural Network
VGG	Visual Geometry Group
YOLO	You Only Look Once
SSD	Single Shot Detector
NAS	Neural Architecture Search
ResNet	Residual Networks
BT	Bilgisayarlı Tomografi
PET	Pozitron Emisyon Tomografisi
ROC	Receiver Operating Characteristic
KOAH	Kronik Obstrüktif Akciğer Hastalığı
TP	True Positives
TN	True Negatives
FP	False Positives
FN	False Negatives



TEZ METNİ

GİRİŞ

Akciğerler, vücuda oksijen alınmasını ve yaşamsal faaliyetler esnasında oluşan gaz değişiminde karbondioksitin vücuttan atılmasını sağlayan, insan vücudunun en önemli organlarından biridir. Akciğerlerdeki hücre ve dokuların kontrolsüz bir biçimde çoğalması akciğer kanserine sebep olmaktadır. Kontrolsüz çoğalan bu hücreler çevredeki dokuları sararak veya başka bir organa sıçrayıp yayılarak ciddi hasarlara yol açabilir. Dünya Sağlık Örgütü'nün yayımladığı rapora göre akciğer kanseri dünya genelinde en çok ölümle sonuçlanan kanser türüdür ve her yıl yaklaşık 1.6 milyon insanın ölümüne neden olmaktadır (Ayayna, 2023).

Akciğer kanseri ve diğer akciğer hastalıkları uzmanlar tarafından görsel olarak tespit edilebileceği gibi bilgisayar destekli de yapılabilir (Chaudhary ve Singh, 2012). Sigara, pipo ve puro kullanımı, uzun süre zararlı gazlara maruz kalma, asbest, hava kirliliği gibi çevresel etkenlerin yanı sıra geçirilmiş diğer akciğer hastalıkları da kanser riskini artırmaktadır. Örneğin tüberküloz hastalığı geçirmiş biri kişinin akciğer kanserine yakalanma olasılığı daha fazladır.

Akciğerde kötü huylu tümörler hücrelerin hızlı ve dengesiz bir şekilde çoğalmasıyla oluşur. Zamanla çoğalarak tüm doku ve organlara yayılan kötü huylu tümörler kanser gibi ciddi ve ölümcül hastalıklara neden olmaktadır (Thakur, vd., 2020). Bu sebeple akciğer kanserinin erken evrelerinde teşhis edilmesi kişinin hayatta kalması için oldukça önemlidir. Akciğer kanseri BT, PET ve MR gibi patolojik incelemeler sonucu tespit edilir. Ancak çoğu zaman erken evrelerinde akciğer kanseri radyolojik muayenede teşhis edilemeyebilir ya da manuel olarak uzmanlar tarafından konulan tanı yanlış olabilir. Günümüzde manuel yapılan tetkikler yerine son yıllarda yapay zeka teknolojileri ile geliştirilen karar destek mekanizmaları oluşturulmuştur. Böyle bir uygulama aynı zamanda sağlıkta bu alanda çalışan doktorlara önemli katkılar sağlayabilir.

Klasik yöntemler yerine derin öğrenme temelli bilgisayar destekli yapılan uygulamalar akciğer tümörlerinin bu alanda çalışan uzmanlar için büyük fayda sağlar. Bu sebeple bu tez kapsamında akciğer hastalıkları ile yapılan çalışmalar ayrıntılı bir şekilde incelenmiştir. Tez kapsamında akciğer BT görüntülerinden tümörlü verilerin tespiti için yapay zeka yöntemleri kullanılmıştır.

Yapay zekâ, bilgisayar sistemlerinin insan gibi düşünebilme ve öğrenebilme yetilerine sahip olma prensibini benimseyen bir bilim alanıdır (De Margerie-Mellon ve Chassagnon, 2023). Bu sistemler, karmaşık görevleri öğrenip yürütebilen ve kararlar alabilen entegre bir prensipte çalışır. Yapay zeka birçok farklı uygulama ve alan içerisinde kullanılır. Tıbbi teşhis ve görüntüleme, örneğin radyoloji bunlardan biridir. Yapay zeka sistemleri, tıbbi görüntüler üzerinde çalışarak hastalıkları teşhis ve analiz etme konusunda oldukça başarılıdır. Derin öğrenme yöntemleri ise makine öğrenimi, bilgi çıkarımı ve doğal dil işleme gibi yapay zekanın bir alt kümesini oluşturur. Radyoloji alanında, özellikle X-ray ve MRI görüntüleri üzerinde derin öğrenme yöntemleri sıklıkla kullanılmaktadır.

Bizim çalışmamızda, uzmanların akciğer kanserini BT görüntüleri üzerinden teşhis etmesine yardımcı olmak amacıyla derin öğrenme modellerini kullanan bilgisayar destekli yaklaşımlar üzerinde çalışmalar yapılmıştır. Çünkü çoğu zaman uzmanlar akciğer grafilerine manuel olarak bakıldığında bazen yanlış teşhisler koyulabilmektedir. Ayrıca manuel yapılan değerlendirmeler maliyet ve zaman açısından da erken ve doğru teşhis koyulmasını zorlaştırmaktadır. Bu problemler göz önüne alınarak çalışmamız ile bu yöntemlerden Derin Sinir Ağları (DNN), Evrişimsel Sinir Ağları (CNN), ResNet, Xception, AlexNet, VGG16 ve MobileNet ile akciğer görüntülerinden tümörlü veriler (iyi huylu, kötü huylu ve normal) hastalığın erken evresinde tespit edilerek kişilerin ölüm riskinin azaltılması hedeflenmiştir. Çok sınıflı hastalık tespiti ve tahmini için farklı ağ yapısına sahip modeller oluşturulmuştur ve kullanılan yöntemler için en uygun hiper parametreler optimizasyon yöntemleri ile çalışmamızda detaylı bir şekilde ele alınmıştır. Önerilen yöntemlerin sonuçları farklı değerlendirme kriterleri ile karşılaştırılarak ileride diğer akciğer hastalıkları için de bilgisayar destekli hastalık tespiti sağlayan karar destek sistemlerinin oluşturulması için zemin hazırlanması gerçekleştirilmiştir. Çünkü akciğer kanseri de diğer kanser türleri gibi erken tanı ve teşhis edilmesiyle hastaların yaşama şansını arttırmakta ve kansere yakalanan kişilerin yaşam kalitesinin arttırılmasını sağlamaktadır.

Bizim çalışmamızın bilimsel katkısı farklı ağ yapısına sahip derin öğrenme modelleri oluşturmak ve bu modellerin özellikle de tıbbi alanlarda uzmanlara yardımcı olmasını sağlamaktır. Önerilen derin öğrenme modellerinde önemli özelliklerin çıkarılması ile başarı ve performans arttırılmıştır ve gelecekte farklı kanser türlerinin tanı

ve tedavisinde önemli katkılar sağlanması hedeflenmektedir. Çalışmamızda ele aldığımız problemler aşağıda sunulmuştur:

- Akciğer kanserini otomatik olarak doğru, hızlı ve maliyet açısından uygun bir şekilde tespit edilmesi bilgisayar destekli uygulamalar ile sağlanabilir mi?
- Kullanılacak derin öğrenme yöntemlerinin parametreleri performans ve doğruluğu en başarılı verebilecek şekilde ayarlanabilir mi?
- Önerilecek yöntemler literatürde aynı verisetini kullanan çalışmalarla karşılaştı mı?
- Önerilen derin öğrenme modelleri büyük veriler için diğer kanser ve hastalık türlerinde de aynı başarıyı sağlar mı?

Çalışmamızda ele aldığımız problemlere yönelik geliştirdiğimiz çözümler aşağıda sunulmuştur:

- Akciğer kanserinin otomatik olarak hızlı, doğru ve maliyet açısından uygun bir şekilde tespit edilmesini sağlayan yöntemler derin öğrenme modelleri (DNN, CNN ResNet, Xception, AlexNet, VGG16 ve MobileNet) oluşturulmuştur.
- Hiper parametreler otomatik olarak optimizasyon algoritmaları ile başarıyı arttıracak şekilde ayarlanmıştır.
- Literatürde aynı verisetini kullanan yöntemlere göre daha başarılı sonuçlar verdiği sonuç bölümünde ele alınmıştır.
- İleride yapılacak ve büyük veri kümeleri için geliştirilecek yöntemlere zemin hazırlanması hedeflenmektedir.

Tez çalışmasının ilk aşamasında 1190 akciğer tomografi görüntüsü önerilen derin öğrenme modelleri için hazırlanmış ve ön işleme gerçekleştirilmiştir. İkinci aşamasında ise derin öğrenme modellerinden Evrişimsel Sinir Ağı (Convolutional Neural Network – CNN), Derin Sinir Ağları (Deep Neural Network – DNN), ResNet, Xception, AlexNet, VGG16 ve MobileNet kullanılarak farklı akciğer tümörleri ile normal akciğer görüntülerinin tespiti gerçekleştirilmiştir. Kullanılan derin öğrenme yöntemleri farklı ağ yapısı ile modellenmiştir ve farklı tümörler bu ağ yapısıyla hızlı ve doğru bir şekilde sınıflandırılmıştır. Önerilen DNN, CNN, ResNet, Xception, AlexNet, VGG16 ve MobileNet modelleri için kullanılan katmanlar, parametre değerleri, sınıflandırma doğruluğu ve kayıp grafikleri ayrı ayrı gösterilmiştir. Oluşturulan her model farklı

değerlendirme kriterleri (doğruluk, kesinlik, duyarlılık, F1-Skor) ile sonuçları alınmıştır ve elde edilen sonuçlar karşılaştırmalı bir şekilde sunulmuştur. Oluşturulan her model için ROC ve karmaşıklık matrisleri gösterilerek elde edilen bulgular gösterilmiştir. Oluşturulan derin öğrenme modellerinden DNN, CNN, ResNet, Xception, AlexNet, VGG16 ve MobileNet modellerinin test başarıları sırasıyla %98.18, %98.18, %95.15, %89.09, %82.42, %92.12 ve %96.36 olarak bulunmuştur.





BİRİNCİ BÖLÜM
LİTERATÜR ARAŞTIRMASI

1.1. İLGİLİ ÇALIŞMALAR

Akciğer kanseri, kansere bağlı ölümlerin %17-28'ini oluşturarak kadın ve erkeklerde kansere bağlı ölümlerde ilk sıradadır. Çünkü hızla başka organlara ve yakın bölgelerdeki lenf düğümlerine yayılabiliyor. Başta sigara içmek olmak üzere, genetik yatkınlık, KOAH gibi akciğer hastalıkları, hava kirliliği, radyasyon, silika, arsenik, nikel gibi metaller akciğer kanserine neden olmaktadır (Bayram, 2019). Çok ciddi ve ölümcül bir kanser türü olması sebebiyle kanserin ilk evrelerinde erken tanı ve tedavi kansere yakalanan kişilerin yaşama şansını arttırmaktadır. Hırıltılı solunum, uzun süren öksürük, ateş, kilo kaybı, omuz ile sırt ağrısı, kemik ile baş ağrısı, nefes darlığı ve halsizlik akciğer kanserinin belirtileridir. Ancak kanserin ilk evrelerinde bu bulgulara pek rastlanmaz. Akciğer grafisi, MRI, PET, BT, biyopsi, bronşların endoskopik incelemesi, lenf bezlerinin mediastinoskopi ve torakoskopik cerrahi gibi değerlendirmesi sonucu akciğer kanserinin erken tanı ve teşhisi yapılmaktadır. Ayrıca bu tetkik ve muayeneler akciğer hastalıklarına bağlı başka hastalıkların tespitine de imkan tanımaktadır. Ancak çoğu zaman yapılan bu tetkik ve muayenelerin uzmanlarca yanlış yorumlanması hastalığın erken evrelerinde tespitini zorlaştırmaktadır. Bu sebeple son yıllarda akciğer hastalıklarının erken tanı ve teşhisi için yapay zeka yöntemleri kullanılmakta ve bu yöntemlerle karar destek mekanizmaları oluşturulmaktadır. Son yıllarda yapılan literatür çalışmaları aşağıda özetlenmiştir:

İbrahim ve arkadaşları, göğüs X-ışını ve BT görüntülerinin bir kombinasyonundan COVID-19, zatürre ve akciğer kanserini teşhis etmek için çok sınıflı bir derin öğrenme modeli önerilmişlerdir (İbrahim, vd., 2021). Bu kombinasyon, göğüs X-ışınının hastalığın erken evrelerinde daha az etkili olmasına rağmen, göğüs BT taraması semptomlar ortaya çıkmadan önce bile kullanışlıdır ve BT, görüntülerde tanımlanan anormal özellikleri kesin bir şekilde tespit edebilir. Ayrıca, bu iki tür görüntünün kullanılması, veri kümesi boyutunu artırarak sınıflandırma doğruluğunu artırabilir. Bu çalışmada, dört mimarinin performansı değerlendirilmiştir: VGG19-CNN, ResNet152V2, ResNet152V2 + Kapalı Yinelemeli Birim (GRU) ve ResNet152V2 + İki Yönlü GRU (Bi-GRU). Dört sınıflı (Normal, COVID-19, Zatürre ve Akciğer Kanseri) halka açık dijital göğüs X-ışını ve BT veri setleri kullanılarak farklı derin öğrenme mimarilerinin kapsamlı bir değerlendirmesi sunulmaktadır. Uygulama sonuçlarına göre, VGG19 + CNN modelinin diğer üç önerilen modele göre daha iyi bir performans

sergilediği bulunmuştur. VGG19+CNN modeli ile, %98.05 doğruluk (ACC), %98.05 geri çağırma, %98.43 hassasiyet, %99.5 özgüllük (SPC), %99.3 negatif öngörü değeri (NPV), %98.24 F1 puanı, %97.7 Matthew's korelasyon katsayısı elde edilmiştir.

Alshmrani ve arkadaşları, pnömoni, akciğer kanseri, tüberküloz (verem), akciğer opakitesi ve en son COVID-19 gibi çoklu sınıf sınıflandırması için bir derin öğrenme (DL) mimarisi önerilmişlerdir (Alshmrani, vd., 2023). 3615 COVID-19, 6012 Akciğer opakitesi, 5870 Pnömoni, 20.000 akciğer kanseri, 1400 tüberküloz ve 10.192 normal görüntünün olduğu büyük bir CXR görüntü veri kümesi kullanılmıştır. Söz konusu veriler, önerilen modele uygun şekilde yeniden boyutlandırılmıştır, normalize edilmiştir ve rastgele olarak bölünmüştür. Sınıflandırma aşamasında, önceden eğitilmiş bir VGG19 modeli, özellik çıkarma için üç bloklu bir Evrişimsel Sinir Ağı (CNN) ve sınıflandırma aşamasında tam bağlantılı bir ağ kullanılmıştır. Önerilen VGG19 + CNN modeli diğer modellere göre daha başarılı sonuçlar vermiştir. Önerilen model, %96.48 doğruluk, %93.75 hatırlama, %97.56 kesinlik, %95.62 F1 skoru ve %99.82 eğri altındaki alan (AUC) ile mükemmel bir sınıflandırma performansı sergilemiştir.

Masood ve arkadaşları, yeni bir derin öğrenme modeli ve MBAN metastaz bilgisi kullanarak bilgisayar destekli bir akciğer kanseri değerlendirme destek sistemi oluşturmuşlardır (Masood, vd., 2018). Önerilen metodoloji, DFCNet adını taşımaktadır ve her bir akciğer nodülünü dört farklı kanser evresinden birine sınıflandıran derin bir tam konvolüsyonel sinir ağı (FCNN) üzerine kurulmuştur. Deneysel sonuçlar, önerilen yöntemin akciğer nodüllerini tanıma ve sınıflandırmada etkili olduğunu göstermektedir. Bu bulgular, önerilen teknik sayesinde radyologların nodül tespitinin doğruluğunu artırma yeteneğini ortaya koymaktadır. Önerilen test metodolojisi, LIDC/IDRI veri seti, RIDER, LungCT Diagnosis ve Lung Nodule Analysis (LUNA) 2016 veri seti dahil olmak üzere farklı veri setleri kullanılarak değerlendirilmiştir. Ayrıca, transkribe edilmemiş olan SPIE Test Veritabanı, DFCNet'in bir nodülü (iyi huylu veya kötü huylu) ve işaretleme olmaksızın bir nodül olmayanı ayırt edip edemediğini test etmek için başlıca kullanılan bir veri setidir. CNN ve DFCNet'in ortalama doğrulukları sırasıyla %77.6 ve %84.58'dir.

Jaiswal ve arkadaşları, akciğer röntgen görüntülerinde (CXR) zatürre tespiti ve karakterizasyonu için bir derin öğrenme tabanlı teknik benimsemişlerdir (Jaiswal, vd., 2019). Öğrenme sürecine yönelik kritik iyileştirmeler ve çeşitli yapıları içeren bir yenilikçi son işleme aşaması ile çalışma, sağlamlık elde edilmiştir. Önerilen tanı modeli, olası zatürre nedenlerini gösteren göğüs radyografi veri setinde daha iyi bir çıktı

sağlamaktadır. Zatürreyi temsil etme olasılığı bulunan akciğer geçirgenliğini sınıflandırmak için Mask-RCNN tabanlı bir modelleme yaklaşımının kullanılması önerilmiştir. Mask-RCNN, özellikle nesne tespiti için geliştirilmiş bir derin öğrenme ağıdır. Çalışmada RSNA zatürre veri seti 5 kullanılmıştır, bu veri seti NIH CXR14 veri setinin bir alt kümesidir ve toplamda 112,000 X-ışını görüntüsünden 30,000 örnek içermektedir. Bu çalışmada elde edilen doğruluk oranı %97'dir.

Turkoglu, COVID - 19 teşhisi için CT tarama görüntülerini kullanarak Çok Çekirdekli ELM tabanlı DNN (MKs—ELM—DNN) yaklaşımı önermiştir (Turkoglu, 2021). Önerilen yöntemde, CT tarama verilerinden derin özellikler, bir CNN kullanılarak elde edilmiştir. Bu görev için bir transfer öğrenme metodolojisi olan önceden eğitilmiş DenseNet201 CNN tabanlı bir sistem kullanılmaktadır. Önerilen MKs – ELM - DNN modelinin etkinliğini kontrol etmek için COVID - 19 ve NON - COVID - 19 kategorilerinden oluşan bir veri seti üzerinde uygulama gerçekleştirilmiştir. DenseNet201 mimarisi için mevcut analizde transfer öğrenme yaklaşımı kullanılmıştır. Bu strateji, önceden eğitilmiş mimari tasarımın tam bağlantılı katmanını kullanarak derin özelliklerin toplanmasına dayanmaktadır. MKs—ELM—DNN çerçevesi kullanılarak %98.36'lık bir doğruluk puanı elde edilmiştir.

He ve arkadaşları, 3-boyutlu CT veri görüntüleri üzerinde, akciğer lobu bölümlendirme ve çoklu görev (M-2 UNet) sınıflandırma işlemlerini bir araya getirerek, COVID - 19 'un otomatik bir şekilde tespiti için bir işbirlikçi sistem önermişlerdir (He, vd., 2021). Çoklu görev, COVID - 19 vakalarının ciddiyetini ölçmeyi ve aynı anda akciğer lobunu bölümlendirmeyi amaçlamaktadır. M-2 UNet, yama aşamasında bir kodlayıcı, bir bölümlendirme yarı-ağı ve bir sınıflandırma yarı-ağından oluşmaktadır. Deneyler, 666 göğüs veri görüntüsünden oluşan COVID - 19 CT görüntü veritabanında gerçekleştirilmiştir. Bu çalışmada %98.50 doğruluk elde edilmiştir.

Zhou ve arkadaşları, ensemble modeli ile COVID - 19 hastalarını tespit etmişlerdir (Zhou, vd., 2021). Çalışmada, geçmiş raporlardan, ve çevrimiçi veritabanlarından elde edilen 2933 COVID - 19 CT veri fotoğrafı kullanılmıştır. 2500 yüksek kaliteli görüntü elde etmek için bu görüntüler normalize edilmiştir. 2500 akciğer kanseri ve 2500 akciğer kanseri olmayan CT verisi alınmıştır. Giriş değişkenlerini yapılandırmak ve CNN modelini önceden eğitmek için AlexNet, ResNet ve GoogleNet olmak üzere 3 transfer öğrenme yöntemi kullanılmıştır. Bu modeller, tüm görüntülerde özellik çıkarmak için kullanılmıştır. Çalışma, ensemble çerçevesinin tam modelden daha

yüksek bir tanıma doğruluğuna sahip olduğunu göstermektedir. Tam bağlı katman için tanımlayıcı model olarak Soft-max kullanılmıştır. Çalışmada elde edilen doğruluk oranı %99.44'tir.

Ezzat ve Ella, çeşitli akciğer hastalıklarını tespit etmek amacıyla GSA DenseNet121 yeni bir yaklaşım geliştirmişlerdir (Ezzat ve Ella, 2020). Bu yöntem, DenseNet121 adlı bir CNN modelini kullanmaktadır ve optimizasyon tekniği olarak genelleştirilmiş bir arama motoru (GSA) içermektedir. GSA, DenseNet121 modeli için optimal maliyet fonksiyonu değerlerini seçmek amacıyla kullanılmaktadır. Bu tasarım, x-ray taramalarını kullanarak akciğer hastalığını doğru bir şekilde tanımlamayı desteklemektedir. Eğitim verisinin miktarını artırmak amacıyla çeşitli veri artırma yöntemleri kullanılmış ve ardından bu artırılmış veri seti ikinci seviyede doğrulama paketi ile birlikte kullanılmıştır. Elde edilen sonuçlarda, önerilen yöntemin test veri setinin doğruluk oranı %98.38'dir.

Bharati ve arkadaşları, VGG, veri artırma ve uzaysal dönüştürücü ağı (STN) ile CNN modellerini entegre ederek etkili bir hibrit derin öğrenme (DL) sistemi oluşturan bir teknik olan VDSNet yöntemini önermişlerdir (Bharati, vd., 2020). Bu model, VGG-Data-STN ile CNN modelinin birleşimi olan VDSNet'tir. Önerilen model, VDS-Net tekniğini kullanarak akciğer hastalığı değerlendirmek ve akciğer hastalıklarını tahmin etmek için uygulanmıştır. Çalışmada kullandıkları NIH akciğer X-ışını görüntüsü veri setinin giriş özellikleri (olgunculuk seviyesi, X-ışını fotoğrafları, cinsiyet ve görüntü durumu gibi) ikili sınıflandırma yapmak için normalize edilmiştir. Bu veri seti, 112,120 göğüs veya akciğer X-ışını görüntüsü ile birlikte 30,805 farklı hastanın hastalık listelerini içeren büyük bir veri setidir. Tüm veri seti için VDSNet, %73 doğruluk oranına sahiptir. Ayrıca gri, düzenli (R/G/B), hibrit CNN modeli ve VGG, güncellenmiş modül sistemine sahip sırasıyla %67.8, %69.5, %69.5 ve %63.8 doğruluk oranlarına sahiptir.

Canayaz, farklı derin öğrenme yaklaşımları ile COVID - 19 grupları, sağlıklı ve zatürreli akciğer röntgen fotoğraflarını içeren üç veri setini eğitmişlerdir (Canayaz, 2021). Bu veri setlerinin herbiri yaklaşık 364 fotoğraf içermektedir. Bu veri setlerinde özellik çıkarımları Alex-Net, VGG-19, Google-Net ve Res-Net gibi derin öğrenme yaklaşımları kullanılarak yapılmıştır. En iyi özellikler, ikili tanecik ve ikili gri kurt gibi iki meta-sezgisel yöntem kullanılarak seçilmiştir. Elde edilen özellikler, özellik çıkarımı ve seçimi gibi yapılan ön işleme aşamalarından sonra Destek Vektör Makineleri (SVM) kullanılarak sınıflandırılmıştır. Veri setinin oluşturulma sürecinde, görüntü kontrast artırma

algoritması (ICEA) kullanılarak kaynak veri setindeki her bir görüntü için ayrı ayrı opaklık artırma işlemi gerçekleştirilmiştir. Verilerin %70'i eğitim verisi olarak kullanılırken, %30'u test verisi olarak kullanılmıştır. VGG19 modelinden türetilen fonksiyonu seçmek ve tanımlamak için ise BPSO algoritması kullanılmış ve yaklaşık %99.38 doğruluk elde edilmiştir.

Yu ve arkadaşları, göğüs X-ray veri görüntülerini sağlıklı ve zatürree olarak iki kategoriye ayırmak için CGNet adlı bir derin öğrenme modeli önermişlerdir (Yu, vd., 2021). Bu model, özellik çıkarma, grafik yöntemi kullanarak özelliklerin yeniden yapılandırılması ve sınıflandırıcı algoritmalar olmak üzere üç aşamadan oluşmaktadır. İlk aşamada CNN kullanarak önemli özellikleri çıkarılmıştır. Ardından, özelliklerin yeniden yapılandırılması için grafik tabanlı bir yaklaşım kullanılmış ve son olarak, tanımlama işlemi için GNet adlı sığ bir sinir ağı kullanılmıştır. Bu model açık zatürree veri setinde elde ettiği doğruluk oranı %98,72 iken, COVID-19 CT veri setinde yapılan testte elde edilen sonuç %99 olmuştur.

Das ve arkadaşları, göğüs X-ray görüntülerini kullanarak COVID -19 vakalarını taramak için VGG 16, CNN ve Res-Net-50 algoritmaları kullanmışlardır (Das, vd., 2021). Bu yöntem, görüntüleri pozitif vakalar, diğer zatürree enfekte vakaları ve enfekte olmayan vakalar olma üzere üç gruba ayırmayı amaçlamaktadır. Normal ve COVID -19 radyografi veri setinde doğrulama analizleri yapılarak önerdikleri modelin sonuçlarını değerlendirmişlerdir. VGG-16 modeli %97,67 ile diğer derin öğrenme modellerinden daha iyi başarı sağlamıştır.

Hussain ve arkadaşları, Covid-19 vakalarını teşhis etmek için CoroDet adlı bir model önermişlerdir (Hussain, vd., 2021). Bu model, CNN modeli ile hastaların göğüs görüntülerini (X-ışını veya BT taraması vs.) kullanarak COVID -19 vakalarını tespit edilmesi sağlanmıştır. Bu çalışma ile, mevcut BT görüntülerinin iki sınıfa, yani Covid-19 pozitif veya normal, üç sınıfa, yani Covid-19 pozitif, normal vakalar ve non-Covid-19 pnömoni, ve dört saf sınıfa, yani Covid-19 vakaları, non-Covid-19 bakteriyel pnömoni vakaları ve non-Covid-19 viral pnömoni, ayrılması amaçlanmaktadır. Bu çalışma ile elde edilen sonuçlar, iki sınıf için %95,1, üç sınıf için %94,2 ve dört sınıf için %91,2 doğruluk elde edildiğini göstermektedir.

Al Mamlook ve arkadaşları, göğüs röntgeni tıbbi görüntülerinin normal (sağlıklı) ve anormal (hasta) olarak sınıflandırılmasına yardımcı olacak bir model geliştirmeyi

amaçlamışlardır (Al Mamlook, vd., 2020). Bu çalışmada, değişen görüntülerle eğitilen sınıflandırma için birden fazla ön işleme adımından oluşan verisetine makine öğrenimi ve derin öğrenme modelleri uygulanmıştır. Sonuçlar karşılaştırıldığında, derin öğrenme modelleri diğer makine öğrenimi modellerine göre daha iyi performans sağlamıştır. CNN modeli göğüs röntgeni görüntülerinde göğüs enfeksiyonunu %98,46 genel doğrulukla makine öğrenimi yöntemlerine göre daha başarılı bir şekilde sınıflandırmıştır.

Sirazitdinov ve arkadaşları, göğüs röntgeni görüntülerinde pnömoninin otomatik olarak algılanması ve lokalizasyonu için makine öğrenimi çözümlerinin uygulanmasına yönelik bir çalışma yapmışlardır (Sirazitdinov, vd., 2019). Pnömoni tespiti ve lokalizasyonu için RetinaNet ve Mask R-CNN olmak üzere iki evrişimli sinir ağından oluşan bir topluluk kullanılmıştır. Kaggle pnömoni tespit yarışmasından kısa süre önce yayımlanan 26.684 görüntüden oluşan veri kümesi üzerinde önerilen modelin sonuçları analiz edilmiştir ve bu çalışma sunulan çözümler arasında ilk %3'lük puan arasında yer almıştır. Ayrıca 0,793 geri çağırma ile otomatik pnömoni tanısı için güvenilir bir çözüm geliştirilmiştir.

Çalışmalara bakıldığında literatürde akciğer kanserinin tanı ve teşhisine yönelik birçok çalışma yapılmıştır. Bu çalışmalarda yapay zeka temelli yöntemler önerilmiştir ve tıp alanında bu çalışmalar son yıllarda her geçen gün artmaktadır. Ancak yapa zeka yöntemlerinin sağlık alanında kullanılmasına ilişkin son yıllarda yaşanan gelişmelere rağmen hastalık türlerinin artması ve hızlı bir şekilde yayılması sebebiyle bilgisayar destekli analiz ve uygulamalara duyulan ihtiyaç her geçen gün daha da artmaktadır. Bizim çalışmamızın özgün değeri diğer çalışmalardan farklı olarak önerilen yöntemlerde özgün ağ yapıları kullanarak akciğer kanserinin erken tanı ve teşhisinde çoklu sınıflandırma yapılarak performans ve başarının artırılmasını sağlamaktadır. Akciğer kanserinin neden ciddi ölüm oranını azaltarak hastaların yaşam kalitesinin artırılması amacıyla derin öğrenme temelli modeller geliştirilerek çoklu sınıflandırma yapılmıştır. Çalışmamız ayrıca akciğer kanserinin tespitine yönelik doğru, hızlı ve düşük maliyetli çözümler sunmuştur. Önerdiğimiz modeller ile akciğer kanseri ve farklı akciğer hastalıklarının erken teşhisine yönelik bir çalışan uzmanlara yardımcı olması amaçlanmıştır. Böylelikle uzmanlar tarafından yapılan manuel değerlendirmelerde ortaya çıkabilecek yanlış ve olası teşhislerin azaltılması sağlanacaktır.




İKİNCİ BÖLÜM
GENEL BİLGİLER

2.1. AKCİĞER KANSERİ

Akciğer kanseri, akciğer dokusundaki hücrelerin düzensiz ve anormal bir şekilde çoğalması sonucu gelişen bir tür kanserdir. Akciğerler, solunum sisteminin kritik bir parçasıdır ve vücudun oksijen almasını ve karbondioksit atmasını sağlar. Kanser, sağlıklı hücrelerin kontrolsüz bir şekilde büyüyüp çoğalması sonucu oluşur. Bu anormal hücreler zaman içinde normal dokuları istila eder ve vücutta yayılabilirler. Akciğer kanseriyle uyumlu kitlesel lezyonlar görülen bir akciğer grafisi Şekil 2.1’de gösterilmiştir.

Şekil 2.1: Akciğer Kanseriyle Uyumlu Kitlesel Lezyonlar Görülen Bir Akciğer Grafisi



Kaynak:https://tr.wikipedia.org/wiki/Akci%C4%9Fer_kanseri#/media/Dosya:LungCancer-Xray-01.jpg

2.1.1. Akciğer Kanserinin Türleri

Akciğer kanseri, kontrolsüz şekilde büyüyen tümörlerin akciğer dokusunda yayılması ve çevredeki dokulara zarar vermesiyle tanımlanır. Bu kanser türü, iki ana kategoriye ayrılır ve bunlar küçük hücreli ve küçük hücreli olmayan olarak tanımlanır.

Küçük hücreli akciğer kanseri genellikle sigara içen bireylerde görülür. Bu kanser türü hızla yayılma eğilimindedir ve çoğu zaman teşhis edildiğinde ileri evrede olur.

Küçük hücreli olmayan akciğer kanserinin ise çeşitli alt türleri mevcuttur. Her alt türün kanser hücreleri farklı özelliklere sahiptir ve bu da büyüme ve yayılma şekillerini etkiler. Bu alt türler, mikroskop altında incelendiğinde kanser hücrelerinin görünüm ve karakteristik özelliklerine göre sınıflandırılır. Bu alt türler şunlardır:

Skuamöz hücreli karsinom: Epidermoid karsinom olarak da bilinen bu tür, balık pulu gibi ince ve düz hücrelerden kaynaklanır.

Adenokarsinom: Salgı bezleri gibi özellikler gösteren hücrelerden oluşan bu kanser türü, bezsel özellikler taşır.

Büyük hücreli karsinom: Mikroskop altında büyük ve anormal hücrelerin tespit edildiği bir kanser türüdür.

Adenoskuamöz karsinom: Hem düz hem de bezsel özellikler taşıyan hücrelerden oluşan bir kanser türüdür.

Pleomorfik, sarkomatoid veya sarkomatöz karsinom: Farklı türde kanser hücrelerini içeren bir kanser grubudur.

Karsinoid tümör: Sinir hücrelerinden kaynaklanarak hormon salgılayan, yavaş büyüyen nöroendokrin bir tümör türüdür.

2.1.2. Akciğer Kanseri Belirtileri

Akciğer kanserinin belirtileri arasında şunlar sayılabilir:

- Sürekli yorgunluk hissi
- Sürekli öksürük
- Balgam kan görülmesi veya kan tükürme
- Kilo kaybı
- Nefes darlığı
- Yutma güçlüğü
- Göğüs ağrısı
- Ses kısıklığı
- İştah kaybı

Sigara kullanımı, pasif sigara içiciliği, hava kirliliği, radyasyona maruz kalma, asbestle temas ve genetik etkenler gibi çeşitli risk unsurları akciğer kanserine neden olabilir. Erken teşhis, tedavi seçeneklerinin etkinliğini artırabilir. Radyoterapi, cerrahi müdahale ve kemoterapi gibi tedavi yöntemleri mevcuttur. Ancak, akciğer kanseri genellikle erken evrelerde belirti göstermez ve çoğu zaman hastalık yayıldığında fark

edilir, bu da tedaviyi oldukça zorlaştırır. Bu nedenle, akciğer kanserinin risk faktörlerini ve belirtilerini bilmek, erken teşhis için son derece önemlidir.

2.1.3. Akciğer Kanseri Nedenleri

Akciğer kanseri, çeşitli faktörlerin etkileşimiyle ortaya çıkabilen karmaşık bir hastalıktır. Kesin nedeni tam olarak bilinmemekle birlikte, aşağıdaki unsurlar riski artırabilir:


- Sigara içme ve pasif içicilik: Sigara kullanımı, akciğer kanserinin en önemli risk faktörüdür. Sigara içen kişiler, içmeyenlere göre yaklaşık 20 kat daha fazla risk altındadır. Benzer şekilde, pasif içicilik de bu riski artırır.
- Kronik obstrüktif akciğer hastalığı (KOAH): KOAH, akciğerlerin hava yollarını daraltan ve hasara uğratan bir hastalıktır. KOAH'lı bireylerde akciğer kanseri gelişme olasılığı daha yüksektir.
- Radyasyona maruz kalma: İyonize radyasyona maruz kalma, akciğer kanseri riskini artırabilir. Bu, nükleer olaylar, radyoterapi veya mesleki maruziyet gibi çeşitli sebeplerle olabilir.
- Aşırı hava kirliliği: Hava kirliliği, akciğer kanseri riskini artırabilir.
- Radon gazı maruziyeti: Radon, doğal olarak oluşan radyoaktif bir gazdır. Evlerde ve diğer yapılarda bulunabilir. Radon gazına maruz kalmak, akciğer kanseri riskini artırabilir.
- Aile öyküsü: Ailede akciğer kanseri öyküsü bulunan kişilerde, akciğer kanseri geliştirme riski artabilir.

2.1.4. Akciğer Kanseri Evreleri

Akciğer kanseri, dört farklı evreye ayrılır. Kanser sadece akciğer içindeyse birinci evre olarak adlandırılır, lenf düğümlerine yayıldığında ise ikinci evreye geçer. Eğer kanser akciğerler arasındaki boşluğa veya akciğer zarına yayılırsa üçüncü evre olarak sınıflandırılır. Kanser kemik, böbrek üstü bezleri, karaciğer gibi diğer organlara yayılırsa dördüncü evre olarak kabul edilir. Akciğer kanserinin evreleri, tedavi stratejilerinin belirlenmesinde kritik öneme sahiptir. Birinci evrede tespit edilen akciğer kanseri genellikle daha başarılı bir şekilde tedavi edilebilir. Bu evrede, kanserli akciğer

dokusu cerrahi olarak çıkarılır ve ardından doktorun önerdiği koruyucu tedavi uygulanır. Hastalık ilerlemiş evrelerde ise kemoterapi ve radyoterapi gibi tedavi yöntemleri kullanılır. Kullanılacak ilaçlar ve tedavi süresi, genellikle kanserin türüne ve yayılım derecesine bağlı olarak belirlenir. Akciğer kanseri evreleri Şekil 2.2’de gösterilmiştir.

Şekil 2.2: Akciğer Kanseri Evreleri



Kaynak:<https://www.emseyhospital.com.tr/tr/blog/saglikli-yasam/akciger-kanseri-nedir-belirtileri-evreleri-ve-tedavisi>

2.1.4.1. Küçük Hücreli Olmayan Akciğer Kanseri Evreleri

Akciğer kanserinde evreleme, hastalığın tedavi yöntemlerini belirlemek için kritik bir öneme sahiptir. Kanserın tümör boyutuna ve yayılma durumuna bağlı olarak belirlenen evreler şu şekildedir:

Evre 1: Tümör 5 cm veya daha küçükse ve lenf bezlerine yayılmamışsa, bu evrede kabul edilir. Kanser bu aşamada kontrol edilebilir durumdadır.

Evre 2: Tümör 5 cm'den büyükse veya göğüs kafesine ya da diyaframa yakın bir konumdaysa, ikinci evrede yer alır. Ayrıca, tümör 7 cm'den küçükse ve lenf düğümlerine veya bronşların yakınına yayılmışsa, yine ikinci evre olarak kabul edilir.

Evre 3A: Tümör, akciğerler arasındaki lenf düğümlerine yayılmışsa veya soluk borusunun ikiye ayrıldığı bölgeye yakın bir konumdaysa, üçüncü evre olarak kabul edilir. Ayrıca, kanser lenf düğümlerine veya bronşlara yakın organlara yayılmadan kalp, nefes borusu veya diğer akciğer lobları gibi organlara yayılabilir.

Evre 3B: Kanser, göğsün karşı tarafındaki lenf düğümlerinde veya köprücük kemiğinin üstünde, ya da göğsün ortasındaki daha geniş lenf düğümlerinde veya soluk

borusunun ikiye ayrıldığı bölgeye yakın bir konumda görülüyorsa, üçüncü evre olarak kabul edilir.

Evre 4: Kanseri her iki akciğere, akciğerleri ve kalbi çevreleyen sıvıya veya vücudun diğer bölgelerine yayılmışsa, dördüncü evre olarak kabul edilir. Bu aşama, kanserin metastaz yaparak en tehlikeli ve ölümcül hale geldiği kritik evredir.

Tedavi seçenekleri hastalığın evresine bağlı olarak değişir. Birinci ve ikinci evrelerde genellikle cerrahi müdahale tercih edilirken, üçüncü evrede tedavi seçimi 3A ve 3B evrelerine göre değişiklik gösterebilir. 3A evresi, ayrıntılı bir değerlendirmenin gerektiği önemli bir aşamadır. Bu evrede, PET-BT sonuçlarına dayanarak mediastinoskopi veya bronkoskopi gibi yöntemlerle lenf düğümlerinden örnek alınır ve tedaviye yönelik kararlar verilir. 3B evresinde olan hastalara ise radyoterapi, tek başına veya kemoterapi ile birlikte önerilebilir. Dördüncü evrede ise radyoterapi veya kemoterapi, hastalığın ilerlemesini yavaşlatmak ve semptomları kontrol altında tutmak amacıyla kullanılabilir.

Son yıllarda önemli bir gelişme, hastalarda hedefe yönelik tedavilerin (akıllı ilaçlar) kullanılmasıdır. Bu ilaçların etkinliği, hastanın tümörüne yönelik detaylı patolojik incelemeler sonucunda belirlenmektedir. Özellikle ileri evre küçük hücreli olmayan akciğer kanserinde, bireye özgü tedavilerin her hasta için uygunluğunun test edilmesi ve gerektiğinde uygulanması son derece önemlidir.

2.1.4.2. Küçük Hücreli Akciğer Kanseri Evreleri

Küçük hücreli akciğer kanserinin uygun tedavi yöntemini belirlemek için hastalığın evresi tespit edilir. Evreleme, kanserin sınırlı mı yoksa akciğer dışına mı yayıldığına göre yapılır. Sınırlı ve yaygın küçük hücreli akciğer kanseri, farklı tedavi stratejileri gerektirir. Hastalığın evresi, belirli test sonuçlarına dayanarak belirlenir ve tedavi bu bilgilere göre planlanır. Tek taraflı akciğer tutulumu sınırlı evreyi, her iki akciğerde veya diğer organlarda yayılım ise ileri (yaygın) evreyi ifade eder. Hastalığın tekrarlama riski vardır. Kemoterapi, akciğerdeki veya vücudun diğer bölgelerindeki tümörlere yönelik olarak kullanılabilir. Bazı hastalara, beyinde kanser olmasa bile koruyucu amaçla beyin radyoterapisi uygulanabilir. Bu tedavi yöntemi "beyin koruyucu ışınlama" olarak adlandırılır ve beyinde görünmeyen kanser hücrelerini yok ederek tümör oluşumunu önlemek amacıyla kullanılır. Küçük hücreli akciğer kanserinde cerrahi tedavi genellikle tercih edilmez.

2.1.5. Akciğer Kanserinde Görüntüleme Yöntemleri

Akciğer kanserinin teşhisinde yaygın olarak kullanılan görüntüleme yöntemleri arasında akciğer grafisi, bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRI) ve pozitron emisyon tomografisi (PET) bulunmaktadır. Ayrıca, kemik sintigrafisi de teşhiste kullanılabilir.

Akciğer Grafisi: Hasta öyküsü ve fizik muayeneyi takiben genellikle ilk adım olarak iki yönlü akciğer grafisi çekilir. Bu yöntem, akciğerlerdeki hasarı belirlemek için kullanılır. Ancak, akciğer grafisi her zaman kesin bir tanı sağlamayabilir, bu nedenle herhangi bir anormallik durumunda akciğer tomografisi gibi daha ayrıntılı incelemeler yapılması önerilir.

Bilgisayarlı Tomografi (BT): Tümörün boyutu, şekli ve yerleşimi hakkında ayrıntılı bilgi verir. Ayrıca, akciğer kanserinin yayılması sonucu büyümüş lenf düğümlerini de gösterebilir. BT, erken evre akciğer kanserinin tanısında ve diğer iç organlara yayılımın belirlenmesinde kullanılır.

Manyetik Rezonans Görüntüleme (MRI): Akciğerin kesitler halinde görüntülenmesini sağlar ve radyasyon içermez. Bu nedenle, MRI taramaları radyasyon riski olmadan gerçekleştirilir.

Pozitron Emisyon Tomografisi (PET): Kanserli dokularda biriken şeker moleküllerini tespit etmek amacıyla düşük dozda radyoaktif bir madde kullanır. PET, kanserin yayılma durumunu belirlemede ve tedavi planlamasında önemli bir rol oynar.

Kemik Sintigrafisi: Radyoaktif bir madde kullanılarak kemiklerdeki kanser hücrelerini tespit etmek için uygulanır. Özellikle kemik metastazı şüphesi olan durumlarda rutin olarak kullanılır ve hem küçük hücreli hem de küçük hücreli olmayan akciğer kanseri vakalarında uygulanabilir.

2.1.6. Akciğer Kanserinde Tanı ve Tedavi

Akciğer kanserinin teşhisinde öncelikle röntgen çekilerek olası bir kitlenin varlığı araştırılır. Hastanın tıbbi geçmişi, sigara kullanımı, maruz kaldığı çevresel ve mesleki faktörler ile ailedeki kanser öyküsü gibi unsurlar değerlendirilir. Akciğer kanseri şüphesi varsa, doktorlar balgam testi gibi ek tetkikler isteyebilir. Kanser şüphesi devam ederse, doktorlar akciğer dokusunu incelemek üzere biyopsi yapabilir. Bu inceleme, kanserin tipini (küçük hücreli veya küçük hücreli olmayan) ve yayılma durumunu

(metastaz) belirlemek için yapılır. Ardından, bilgisayarlı tomografi kullanılarak kitlenin en uygun şekilde nasıl ulaşılacağı belirlenir. İğne biyopsisi veya bronkoskopi gibi yöntemlerle kitleden örnek alınır ve biyopsi sonuçlarına dayanarak akciğer kanseri tanısı konur. Eğer hastalık diğer organlara yayılmışsa, bu organlardan da örnek alınarak tanı doğrulanır. Tanı konduktan sonra akciğer kanserinin evresi belirlenir.

Akciğer kanseri genellikle erken dönemde, yani lenflere veya diğer organlara yayılmadan önce tespit edilmez. Bu nedenle, erken evrede yakalanma oranı düşüktür ve çoğunlukla hastalık ilerlemiş evrede teşhis edilir. Lenflere yayılmamış vakalarda 5 yıllık sağ kalım oranı yaklaşık %50 civarındadır, ancak çoğu zaman hastalık ileri evrede olduğu için bu oran düşer. Akciğer kanserinin erken teşhisi, rutin kontroller veya başka sağlık sorunları için yapılan tetkikler sırasında ortaya çıkabilir.

Akciğer kanseri tedavisi, hastanın genel sağlık durumu, kanserin evresi ve tipine bağlı olarak çeşitlilik gösterir. Farklı evrelerde, bireye özgü tedaviler ve çeşitli tedavi kombinasyonları uygulanabilir. Bu yüzden, akciğer kanseri tedavisinde doğru hastane seçimi ve deneyimli doktorun rolü büyük önem taşır.

Ameliyat sonrası, adjuvan tedavi ile olası geride kalmış kanser hücreleri hedef alınır. Bu tedavi, hastanın tanı raporu, yaş ve genel sağlık durumuna göre belirlenir. Adjuvan tedavi, kemoterapi, radyoterapi veya her ikisinin kombinasyonu şeklinde olabilir. Erken evre hastalarda ise adjuvan tedavi gerekmeyebilir.

Cerrahi müdahale, akciğer kanserinin tedavi seçeneklerinden biridir. Ameliyat tipi, tümörün yerleşimine göre belirlenir. Küçük bir parça alınması, lobektomi veya pnömonektomi gibi operasyonlar yapılabilir. Ancak bazı durumlarda tümörün yerleşimi veya hastanın sağlık durumu ameliyatı engelleyebilir.

Kemoterapi, kanser hücrelerini yok etmek için ilaçların kullanılmasıdır. Genellikle 2 ilaçtan oluşan kemoterapi kürleri, belirli aralıklarla tekrarlanır. Kemoterapi genellikle damardan veya ağızdan alınır ve tedavi sürecinde hastalar düzenli olarak kontrol edilir.

Hastanın kemoterapi alıp almayacağı ve kaç kür alacağı, patoloji raporu ve hastanın genel durumu göz önünde bulundurularak belirlenir. Hastanın yaş ve genel sağlık durumu, bu kararın alınmasında önemli bir rol oynar. Ayrıca, hastaların kemoterapi sırasında yan etkileri izlemek ve gerektiğinde doz ayarlaması yapmak önemlidir.

Son yıllarda, akciğer kanseri tedavisinde immünoterapi gibi yeni yöntemler önem kazanmıştır. Bu tedavi, hastanın kendi bağışıklık sistemini kullanarak kanser hücrelerine saldırmasını sağlar. Özellikle dördüncü evre hastalarda immünoterapi, diğer tedavi seçenekleri başarısız olduğunda kullanılabilir.

Radyoterapi, yüksek enerjili ışınların kullanılmasıyla kanser hücrelerinin hedef alınmasıdır. Radyoterapi, cerrahi müdahaleden önce veya sonra uygulanabilir ve belirli semptomların tedavisinde de kullanılabilir.

Aşı tedavisi, akciğer kanseri tedavisinde yeni bir yaklaşım sunar. Özellikle dördüncü evre hastalarda kullanılan bu tedavi, hastanın yaşam süresini uzatmaya yöneliktir. Aşı tedavisi için hastanın tetkiklerden geçirilmesi ve uygun aday olup olmadığının belirlenmesi önemlidir. Aşı tedavisi, yan etkileri minimal olan bir seçenektir ve hastaların yaşam kalitesini artırabilir.

2.2. YAPAY ZEKA VE MAKİNE ÖĞRENİMİ YÖNTEMLERİ

Yapay zekâ, bilgisayar sistemlerinin insan gibi düşünebilme ve öğrenebilme yetilerine sahip olma prensibini benimseyen bir bilim alanıdır. Bu sistemler, karmaşık görevleri öğrenip yürütebilen ve kararlar alabilen entegre bir prensipte çalışır.

Yapay zeka birçok farklı uygulama ve alan içerisinde kullanılır. Tıbbi teşhis ve görüntüleme, örneğin radyoloji bunlardan biridir. Yapay zeka sistemleri, tıbbi görüntüler üzerinde çalışarak hastalıkları teşhis ve analiz etme konusunda oldukça başarılıdır. Radyoloji alanında, özellikle X-ray ve MRI görüntüleri üzerinde yapay zeka ve derin öğrenme sistemleri kullanılmaktadır.

Yapay zeka sistemleri bir çok alt dal içerir. Bu alt dallar daha çok spesifik olarak belli görevler üzerinde odaklanmıştır. Makine Öğrenimi, Derin Öğrenme, Doğal Dil İşleme, Görüntü İşleme, Makine Görüşü, Bilgi Çıkarma bunlardan bazılarıdır.

2.2.1. Makine Öğrenimi


Makine öğrenimi, tükettikleri verilere dayalı olarak öğrenen ya da performanslarını geliştiren sistemler oluşturmayı amaçlayan bir yapay zeka alt alanını temsil eder (El Naga ve Murphy, 2015). Yapay zeka, geniş anlamıyla, insan zekasını taklit eden sistemleri veya makineleri ifade eden kapsamlı bir kavramdır. Makine öğrenimi ve yapay zeka yaklaşımları sıklıkla birbirine karıştırılır. Ara sıra ikisi birbirinin yerine kullanılır, ancak bu terimler aynı anlama gelmez. Bütün makine öğrenimi çözümleri

yapay zekâdır, ancak bütün yapay zekâ çözümleri makine öğrenimi olmak zorunda değildir; bu önemli bir ayrımı ortaya koyar. Makine öğrenimi, bilgisayar sistemlerinin algoritmalar kullanarak veri setlerinden öğrenme yeteneği kazandığı bir yapay zeka alt kategorisidir. Klasik programlamadan farklı olarak, makine öğrenimi modelleri, veri üzerindeki desenleri tanıyarak öğrenir ve tahminlerde bulunabilir, kararlar alabilir. Özellikle büyük ve karmaşık veri setleriyle çalışabilme, desenleri tanıma ve tahmin yeteneğiyle bilinir.

2.2.2.1. Denetimli Makine Öğrenimi (Kontrollü Öğrenme)

Denetimli makine öğrenimi, makine öğrenmesi modelleri arasında yer alan bir paradigmadır (Gökalp, 2022). Bu algoritmalar, makinelerin öğrenmesini sağlamak için etiketlenmiş veri kullanır. Denetlenen öğrenme modelleri, girdi ve çıktı veri çiftlerini kullanarak öğrenme sürecini gerçekleştirir. Denetimli öğrenme sürecinde, algoritma, bir çocuğun resimli bir kitaptan meyveleri öğrenmeye çalıştığı gibi daha önceden etiketlenmiş ve tanımlanmış çıktıları sahip veri kümeleri ile eğitilir. Denetimli makine öğrenimindeki temel amaç, belirli bağımsız değişkenler aracılığıyla tanımlanan bir fonksiyonu kullanarak hedef değişkeni öngörmektir.

Şekil 2.3: Denetimli Makine Öğrenimi



2.2.2.2. Denetimsiz Makine Öğrenimi (KontROLSÜZ Öğrenme)

Denetlenmemiş makine öğrenimi, bilgisayarın karmaşık süreçleri ve modelleri öğrenmek için insan tarafından sürekli ve yakın rehberlik olmadan daha bağımsız bir

yaklaşımı benimser (Gökalp, 2022). Bu yaklaşım, verilerdeki etiketlerin veya belirli, tanımlanmış çıktıların olmamasına dayanarak eğitimi gerçekleştirir (Şekil 2.4).

Şekil 2.4: Denetimsiz Makine Öğrenimi



2.2.2.3. Yarı Denetimli Makine Öğrenimi

Hem denetimli hem de denetimsiz algoritmaların özelliklerini birleştiren yöntemlerdir (Gökalp, 2022). Eğitim verilerinin tamamı etiketlenmemiş olabilir ve algoritma başlatıldığında tüm kurallar belirlenmemiş olabilir (Şekil 2.5).

Yarı denetimli makine öğrenimi algoritmaları, eğitim için etiketli ve etiketlenmemiş verileri bir araya getirir. Genellikle sınırlı sayıda etiketli veri ve geniş bir etiketlenmemiş veri seti kullanarak, sistemlerin öğrenme doğruluğunu önemli ölçüde artırabilir. Bu yöntem, makine öğrenme modelleri arasında üçüncü sırada yer alır.

İdeal bir durumda, sisteme giriş yapmadan önce tüm veriler düzenlenir ve etiketlenirdi. Ancak bu genellikle mümkün olmadığı için, yarı denetimli öğrenme, büyük miktarda ham ve düzenlenmemiş veri bulunduğu etkili bir çözüm olarak ortaya çıkar. Bu model, sisteme az miktarda etiketli veri vererek etiketlenmemiş veri kümelerini artırma amacını taşır. Temelde, etiketli veriler, sistemde çalışan bir başlangıç noktası sağlamak için kullanılır ve öğrenme hızını ve doğruluğunu önemli ölçüde iyileştirebilir. Yarı denetimli öğrenme algoritması, etiketli verileri analiz ederek makineye uygulanabilecek bağıl özellikleri etiketlenmemiş verilere genişletme talimatı verir.

Şekil 2.5: Yarı Denetimli Makine Öğrenimi




2.2.2.4. Güçlendirme Öğrenimi

Bu metodoloji, makinelerin ve yazılım araçlarının belirli bir bağlamda ideal davranışı otomatik olarak belirleyerek performanslarını en üst düzeye çıkarmasına olanak tanır. Güçlendirme öğrenmesi, dördüncü makine öğrenmesi modelidir. Denetlenen öğrenme modellerinden farklı olarak, güçlendirme öğrenme modeli cevap anahtarını içermez. Bunun yerine, belirli eylemler, kurallar ve potansiyel bitiş durumları kümesini içerir. Algoritma, hedefin sabit veya ikili olmadığı durumlarda deneyim ve ödüllerle öğrenmeyi sağlar (Şekil 2.6).

Bu tip algoritmalar, keşif olarak adlandırılan bir teknik kullanarak işler; makine çevresiyle etkileşime girer, eylemler gerçekleştirir, sonuçları gözlemler ve bu sonuçları dikkate alarak bir sonraki adıma geçer. Bu süreç, algoritmanın gelişip doğru stratejiyi seçene kadar devam eder.

Şekil 2.6: Güçlendirme Öğrenimi



2.3. DERİN ÖĞRENME


Derin Öğrenme, gerçek insan beyni gibi çalışacak biçimde modellenen algoritmalar bütünüdür, yani kısaca yapay sinir ağlarının büyük çapta veriden elde ederek öğrendiği, yapay zeka alanında oldukça kritik bir alt dalı temsil eden makine öğrenimi tekniğidir. Bu teknik, çok katmanlı yapay sinir ağlarından faydalanarak karmaşık yapıları çözmekle ilgilenir. Derin öğrenme, büyük veri setlerinden öğrenme kapasitesi ve karmaşık problemlerle başa çıkma becerisi ile öne çıkmaktadır. Derin öğrenme tekniklerinin, yapay sinir ağları, katmanlar, aktivasyon fonksiyonları, ağırlık ve bias ve öğrenme algoritmaları gibi temel kavramları ve yapıları vardır (LeCun, vd., 2015).

Derin öğrenmenin çalışma prensibi ise şu şekildedir: Yukarıda da değindiğimiz gibi bu yöntem insan beyninin işleyişini taklit eden sinir ağı adlı algoritmaların katmanlar arasındaki desteklediği bir öğrenme yöntemidir. Bu algoritmalar, düzenlenmiş katmanlar halinde yerleştirilen sinir ağlarıyla işlev gösterirler. Yoğun veri setleriyle eğitilen derin öğrenme modelleri, sinir ağlarındaki nöronları konfigure ederek bilgi edinirler. Eğitildikten sonra, bu modeller yeni verileri işleyebilir hale gelir. Derin öğrenme modelleri, farklı veri kaynaklarından bilgi çeker ve bu bilgileri insan müdahalesine ihtiyaç duymadan anlık olarak analiz ederler. Derin öğrenme sürecinde, grafik işleme birimleri yani GPU, özellikle eğitim modellerini hızlı bir şekilde işleyebilmeleri nedeniyle optimize edilmiştir.

2.3.1. Evrişimsel Sinir Ağları (CNN) Derin Öğrenme Modeli ve Çalışma Prensibi


Convolutional Neural Networks (CNN), derin öğrenme alanında kullanılan bir algoritmadır ve genellikle görüntülerle çalışır. Bu algoritma, görüntülerin özelliklerini kullanarak sınıflandırma görevini gerçekleştirir. Diğer sınıflandırma algoritmalarına göre, CNN için gerekli olan veri ön işleme daha azdır. Bu, CNN'nin filtreleri öğrenme yeteneğine sahip olmasından kaynaklanır, bu da onu diğer sınıflandırma algoritmalarından ayırır. Şekil 2.7'de de görüldüğü üzere CNN mimarisi, temelde üç ana katmandan oluşur: Convolutional Layer (Evrişimli Katman), Pooling Layer (Havuzlama Katmanı) ve Fully Connected Layer (Tam Bağlantılı Katman). Görüntü, bu katmanlardan geçerken çeşitli işlemlerden geçirilir ve derin öğrenme modeline uygun hale gelir (Provath, vd., 2023).

Şekil 2.7: Evrişimli Sinir Ağları Yapısı



CNN, görsel veri analizi ve tanıma gibi uygulamalarda çok etkili olan bir derin öğrenme modelidir. Özellikle görüntü tanıma, nesne tespiti, yüz tanıma gibi alanlarda başarılı sonuçlar elde edebilmek için yaygın bir şekilde kullanılır.

Şekil 2.8: CNN Mimarisi ve Katmanları



Evrişim Katmanı: CNN'nin temel bileşeni olan evrişim, girdi veri (örneğin, bir görüntü) üzerinde belirli boyutlardaki filtreleri hareket ettirerek hesaplamalar yapar (Şekil 2.8). Bu filtreler, görüntü üzerinde belirli desenleri tespit etmek amacıyla kullanılır (Swain, vd., 2024).

Evrişim İşlemi (Convolution Operation): Şekil 2.9'da evrişim işlemi gösterilmiştir. Evrişim katmanı, görüntü veya başka türden veriler üzerinde evrişim işlemi uygular. Evrişim işlemi, bir görüntü veya veriye belirli bir boyut ve şekle sahip bir filtre (kernel) ile kaydırma yaparak uygulanır. Bu filtre, görüntü üzerinde belirli özellikleri (örneğin kenarlar, köşeler, desenler) tespit etmek için kullanılır.

Çekirdekler (Kernels): Evrişim katmanı içinde kullanılan çekirdekler, özellik çıkarımını yapmak için tasarlanmış matrislerdir. Çekirdekler, tipik olarak 3x3 veya 5x5 boyutlarındadır, ancak boyutları değişebilir. Bu çekirdekler, görüntü üzerinde kaydırılarak evrişim işlemi gerçekleştirir. Her çekirdek, görüntünün belirli bir özelliğini tanımak veya çıkarmak için tasarlanır.

Şekil 2.9: Evrişimli Katman Çalışma Prensibi



Şekil 2.10: Evrişimli Katman Çalışma Prensibi



Evrişim Sonucu (Feature Map): Evrişim işlemi sonucunda oluşturulan yeni görüntüler veya matrisler, "özellik haritası" veya "evrişim sonucu" olarak adlandırılır (Şekil 2.10). Her çekirdek, görüntü üzerinde kaydırıldıkça bir evrişim sonucu üretilir. Bu sonuçlar, görüntüdeki belirli özellikleri temsil eder. Bir evrişim katmanı genellikle birden fazla çekirdek kullanarak bir dizi evrişim sonucu üretir.

Adım (Stride) ve Dolgu (Padding): Filtre işlemleri sırasında dikkate almamız gereken iki önemli terim daha vardır: Adım (Stride) ve Dolgu (Padding). Bu terimleri kısaca şu şekilde açıklanmaktadır (Naseri ve Mehrdad, 2023):

Adım değeri, CNN modellerinde ayarlanabilen bir parametredir. Bu değer, filtrenin görüntü üzerinde kaç piksel boyunca hareket edeceğini belirler. Örneğin, yukarıda ele aldığımız örnekte adım değeri bir olarak belirlenmişti. Bu da demek oluyor ki filtremiz, görüntü üzerinde bir piksel kayarak işlemini gerçekleştirir. Eğer adım değeri daha büyük bir değere sahip olsaydı, filtrenin görüntü üzerindeki kayma miktarı da artacağından dolayı elde edilen öznetelik haritasının boyutu daha küçük olacaktı.

Elde edilen görüntüye filtre uygulanırsa, asıl görüntüden daha küçük bir görüntü elde edilebilir (Şekil 2.11). Bu durumu önlemek için ise padding yani dolgu kullanabiliriz. Dolgu işlemi, görsele sanki bir çerçeve eklenmiş gibi her iki taraftan sıfırlar eklemek anlamına gelir. Filtrenin boyutuna bağlı olarak, bu dolgu sıfırları eklenen katman sayısı artırılabilir.

Şekil 2.11: Doğrulama İşlemi



Evrişim katmanları, ağırlıklarını paylaşır, bu da ağırlık öğrenme sürecini hızlandırır ve daha az parametre gerektirir. Evrişim katmanları, verilerin özelliklerini öğrenme yeteneği ile bilinir. Özellikle, evrişim işlemi ile belirli özelliklerin tespit edilmesi ve daha yüksek düzeyde özelliklerin birleştirilmesi sağlanır. Evrişim katmanları, görüntü boyutunu küçültmek için kullanılan havuzlama (pooling) katmanları ile sıklıkla bir araya getirilir.

Ağın İleri Yayılımı (Forward Propagation): Evrişim katmanı, ağın girdisini alır ve evrişim işlemi ile özellikleri çıkarır. Bu özellik haritaları, daha sonra aktivasyon fonksiyonlarına geçirilir ve ardından diğer katmanlara iletilir.

Evrişim katmanları, özellik çıkarımı için mükemmel bir araçtır ve bu, görüntü işleme, nesne tespiti ve diğer görsel tanıma görevlerinde büyük bir etki yaratır. Evrişim katmanları sayesinde ağlar, görüntülerdeki desenleri ve özellikleri öğrenebilir, böylece karmaşık görevleri başarabilirler.

Aktivasyon Fonksiyonları (Activation Functions): Evrişim katmanından elde edilen sonuçlara aktivasyon fonksiyonları (örneğin, ReLU - Rectified Linear Unit) uygulanır. Aktivasyon fonksiyonları, evrişim sonuçlarının doğrusal olmayan bir dönüşümünü sağlar. Aktivasyon fonksiyonları, yapay sinir ağlarında kullanılan ve bir hücrenin (nöronun) çıkışını belirleyen matematiksel fonksiyonlardır. Bu fonksiyonlar, nöronların girdi toplamını alır ve çıkışı belirler. Aktivasyon fonksiyonlarının amacı, ağın non-lineerlik öğrenmesini sağlamaktır, yani basit doğrusal ilişkilerin ötesinde daha karmaşık ilişkileri ifade edebilirler.

Bazı yaygın aktivasyon fonksiyonları ve özellikleri:

Sigmoid Fonksiyonu: Sigmoid fonksiyonu, yaygın bir aktivasyon fonksiyonudur ve çıkışı 0 ile 1 arasında sıkıştırır. Yani, bir nöronun çıkışı olasılık değeri olarak yorumlanabilir. Ancak, büyük girdi değerlerinde (pozitif veya negatif) sıkışma problemine yol açabilir ve bu da "gradientsizlik" sorununa neden olabilir.

$$\text{Formül: } S(x) = 1 / (1 + e^{(-x)})$$

ReLU (Rectified Linear Unit): ReLU fonksiyonu, x değeri pozitifse doğrudan çıkışı alır ve negatifse sıfır yapar. Yani, doğrusal bir işleme dayalı ve non-lineerliği basitçe tanımlayan bir fonksiyondur. ReLU, özellikle derin sinir ağlarında tercih edilir ve daha hızlı öğrenmeye yardımcı olabilir.

$$\text{Formül: } R(x) = \max(0, x)$$

Leaky ReLU: Leaky ReLU, ReLU'nun bir varyasyonudur. Leaky ReLU, negatif girdi değerlerinde küçük bir eğim (örneğin 0.01) kullanırken, pozitif girdi değerlerini doğrudan alır. Bu, negatif girdi değerlerine karşı daha toleranslıdır ve gradiensizlik sorununu hafifletmeye yardımcı olabilir.

$$\text{Formül: } L(x) = x, x > 0; L(x) = 0.01x, x \leq 0$$

Tanh (Hiperbolik Tanjant): Tanh fonksiyonu, sigmoid fonksiyonuna benzer, ancak çıkışı -1 ile 1 arasında sıkıştırır. Tanh fonksiyonu, 0 merkezli olduğu için, daha simetrik bir çıkışa sahiptir.

$$\text{Formül: } \tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x})$$

Swish: Swish, son zamanlarda popüler hale gelmiş bir aktivasyon fonksiyonudur. Swish, ReLU ile benzerdir, ancak daha yumuşak bir geçiş sağlar ve bazı görevlerde daha iyi sonuçlar verebilir.

$$\text{Formül: } \text{Swish}(x) = x * \text{sigmoid}(x)$$

Aktivasyon fonksiyonları, sinir ağlarının öğrenme yeteneğini etkiler ve doğru bir aktivasyon fonksiyonu seçimi, ağın performansını artırabilir. Hangi aktivasyon fonksiyonunun kullanılacağı, problem türüne, veriye ve ağ yapısına bağlı olarak seçilmelidir. Bu nedenle, aktivasyon fonksiyonlarını seçerken deneme yanılma yaklaşımı sıkça kullanılır.


Havuzlama Katmanı: Havuzlama katmanı, boyut küçültmek ve hesaplama maliyetini azaltmak için kullanılır (Gopinath, vd., 2023). Bu katmanda, evrişim sonuçları üzerinde belirli bölgeler seçilir ve bu bölgelerin en büyük veya ortalama değeri alınarak boyut küçültülür.

Havuzlama İşlemi (Pooling Operation): Havuzlama katmanının çalışma prensibi Şekil 2.12'de gösterilmiştir. Girdi olarak aldığı görüntü veya özellik haritası (feature map) gibi verileri daha küçük bir boyuta sıkıştırmak amacıyla kullanılır. Bu işlem, özelliklerin yerel yoğunluğunu ve önemini korumaya yardımcı olur. Havuzlama işlemi, genellikle alt örnekleme (subsampling) veya toplamaya (pooling) dayalıdır. Max Pooling ve Average Pooling olmak üzere iki havuzlama türü vardır:

Max Pooling: Max pooling, her havuzlama bölgesi içindeki en büyük değeri seçerek çalışır. Bu, bölge içindeki en belirgin özelliği korur. Genellikle 2x2 veya 3x3 boyutunda bir pencere (window) kullanılır.

Average Pooling: Average pooling, havuzlama bölgesi içindeki değerlerin ortalamasını alır. Bu, verilerin daha pürüzsüz bir şekilde azalmasını sağlar ve daha az belirgin özellikleri koruyabilir.

Şekil 2.12: Havuzlama Katmanı Çalışma Prensibi



Havuzlama katmanı, ağın boyutunu küçültmek ve hesaplama yükünü azaltmak için kullanılır. Bu, modelin daha hızlı öğrenmesine yardımcı olabilir. Havuzlama işlemi, translasyon invariansını (bir nesnenin farklı konumlarını tanıma yeteneği) artırabilir. Çünkü havuzlama, belirli bir özellik veya desenin farklı konumlarında bulunmasına rağmen onu tanıma yeteneği sağlar. Havuzlama katmanı, ağın karmaşıklığını azaltırken özelliklerin daha yüksek seviyelerde temsil edilmesine yardımcı olabilir. Bu, daha az parametre kullanımı ile ağın öğrenmesini iyileştirebilir.

CNN yöntemi aşağıdaki alanlarda kullanılmaktadır:


Görüntü Sınıflandırma: Havuzlama katmanları, görüntülerden önemli özellikleri çıkararak sınıflandırma işlemi için kullanılır.

Nesne Tespiti: Havuzlama, nesne tespiti görevlerinde özellik haritalarının boyutunu küçültmek için kullanılır.

Evrişimli Sinir Ağları (CNNs): Havuzlama katmanları, CNN yönteminin önemli bir bileşeni olarak özellik çıkarım aşamasında kullanılır. Havuzlama katmanları, veri boyutunu azaltırken önemli özelliklerin korunmasını sağlayarak modelin genellikle daha etkili ve hızlı çalışmasına katkı sağlar. Hangi havuzlama türünün kullanılacağı ve havuzlama penceresinin boyutu, veri seti ve problem türüne bağlı olarak belirlenir.

Tam Bağlantılı Katman: Tam bağlantılı katman, evrişim ve havuzlama katmanlarından gelen özellik haritasını düzleştirir ve genellikle sınıflandırma için kullanılan geleneksel yapay sinir ağı (fully connected neural network) yapısına geçiş yapar (Şekil 2.13). Bu katmanda, her nöron, önceki katmandaki tüm nöronlarla bağlantılıdır. Sınıflandırma görevleri için bu katmanda softmax aktivasyonu gibi uygun aktivasyon fonksiyonları kullanılır.

Şekil 2.13: Tam Bağlantı Katmanı Çalışma Prensibi



Tam bağlantılı katman, bir önceki katmandaki tüm nöronlarla bağlantılıdır, yani her nöronun çıkışı bu katmandaki tüm nöronlara gider. Bu nedenle "tam bağlantılı" olarak adlandırılır. Bu katman, özellik çıkarımı ve işleme aşamalarının sonunda genellikle kullanılır ve ağıın çıkışını üretir.

Tam bağlantılı katmanlarda, genellikle aktivasyon fonksiyonları kullanılır. Bu aktivasyon fonksiyonları, katmanın non-lineerlik öğrenmesine yardımcı olur. Yaygın olarak kullanılan aktivasyon fonksiyonları ReLU, sigmoid, tanh veya Swish gibi fonksiyonlardır.

Her nöronun tam bağlantılı katmanda bir dizi ağırlığı (weights) ve bir bias değeri vardır. Bu ağırlıklar ve biaslar, önceki katmandan gelen girdilerle çarpılır ve nöronun aktivasyon fonksiyonuna gönderilir. Bu işlem, nöronların girdilere nasıl tepki vereceğini belirler ve ağı özelliklerin nasıl birleştirildiğini kontrol eder.

Tam bağlantılı katmanlar, ağı sonunda sınıflandırma veya regresyon işlemleri için kullanılır. Özellikle sınıflandırma görevlerinde, her sınıf için bir nöron bulunan bir tam bağlantılı katman kullanılabilir. Nöronların çıkışları, sınıf olasılıklarını temsil eder ve en yüksek olasılığa sahip sınıf tahmini olarak kabul edilir.

Tam bağlantılı katmanlar, problem türüne ve ağı tasarımına bağlı olarak farklı şekillerde kullanılabilir. Örneğin, birçok sınıflı sınıflandırma görevinde, softmax aktivasyon fonksiyonu ile sonuç üreten bir tam bağlantılı katman kullanılabilir. Regresyon problemlerinde ise doğrusal bir çıkış katmanı kullanılabilir.

Tam bağlantılı katmanlar, ağı öğrenilen özelliklerini ve nihai sonuçları bir araya getirir. Bu katmanlar, girdi verisini daha yüksek seviyeli bir temsile dönüştürmek için kullanılır ve ağı öğrenme sürecinin sonucunu üretmek için kullanılırlar.

Yani, tam bağlantılı katmanlar, birçok derin öğrenme modelinin temel bir bileşenidir ve genellikle sınıflandırma, regresyon ve diğer görevlerde kullanılırlar.

CNN, bu temel yapı bloklarını bir araya getirerek birçok katmandan oluşan derin bir ağ yapısı oluşturur. Bu ağ, girdi görüntülerden başlayarak katman katman özellikler çıkarır ve nihayetinde sınıflandırma veya diğer görevler için sonuç üretir.

Öğrenme süreci, ağı eğitmek için geriye doğru yayılım (backpropagation) algoritması kullanılarak gerçekleşir. Ağı eğitirken, ağırlıklar ve filtreler, kayıp fonksiyonu aracılığıyla belirli bir hedefe doğru güncellenir ve optimize edilir. Bu sayede ağ, veriler üzerinde daha doğru ve etkili sonuçlar üretecek şekilde özellikler öğrenir.

2.3.2. DNN Derin Öğrenme Modeli ve Çalışma Prensibi

Yapay Sinir Ağları içinde öne çıkan bir tür olan Derin Sinir Ağları (DNN), özellikle derin öğrenme konsepti içinde kullanılır (Mothkur ve Veerappa, 2023). Derin öğrenme, çok katmanlı ve karmaşık bir sinir ağı mimarisi kullanarak öğrenme yeteneklerini geliştirmeye odaklanır.

DNN, genellikle birden fazla gizli katman içeren bir yapıya sahiptir ve bu katmanlar arasında bağlantılar kurulur (Prasad, vd., 2023). Her bir gizli katman, önceki katmandan gelen çıktıları alır ve bu bilgileri kullanarak daha sofistike özellikleri öğrenir. Tipik olarak, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur (Deepa, vd., 2023).

BatchNormalization Layer: DNN modelinin eş zamanlı olarak çalışması istenirse yani sonraki katmanların önceki katmanların eğitilmesinin bekletilmesi istenmezse bu katman kullanılır (Deepa, vd., 2023). Herhangi bir katmanda yapılan güncelleme diğer katmanlara da aktarılır. Katmanların ağırlıklarında meydana gelen kayıplar azaltılarak ağ daha düzenli hale getirilir. Böylelikle modelin performansı artırılır.

Düzleştirici Katman (Flatten Layer): Tam bağlantı katmanı için evrişim ve havuzlama katmanından gelen verileri hazırlar. Bu katman diğer katmanlardan farklı olarak verileri tek boyutlu hale getirir.

Yoğunluk Katmanı (Dense Layer): Sigmoid, relu ve tanh gibi çeşitli aktivasyon fonksiyonlarıyla çıkış hesaplanır. Herbir düğümün girdisi bir önceki katmanın çıkışına göre belirlenir.

Dropout Layer: Aşırı öğrenmeyi azaltmak amacıyla modeldeki bazı nöronların (düğümlerin) atılmasını amaçlamaktadır. Sıfır ile bir arasında bir değer alır ve bazı nöronların atılmasıyla öğrenme hızlandırılır ve daha iyi bir öğrenme gerçekleştirilir.

2.3.3. AlexNet Derin Öğrenme Modeli ve Çalışma Prensibi

AlexNet, 2012 senesinde Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından geliştirilen ve o yıl düzenlenen ImageNet Large Scale Visual Recognition Challenge (ILSVRC) yarışmasında büyük bir başarı sağlayan derin öğrenme modelidir. Bu model, derin öğrenme alanında bir dönüm noktası olarak kabul edilmiş ve CNN yönteminin popülerliğini daha da artırmıştır.

AlexNet modelinin temel özellikleri ve çalışma prensibi;

AlexNet, toplamda 8 katman içerir. 5 evrişim-katmanı ve 3 tam-bağlantılı katmandan oluşur (Agarwal ve Rajeswari, 2021). Evrişim katmanlarından sonra ReLU aktivasyon fonksiyonu kullanılır ve ardışık evrişimlerle özellikler çıkarılır. Evrişim katmanları ve tam bağlantılı katmanlar arasında max-pooling katmanları bulunur.

Evrişim Katmanları:

Evrişim Katmanı 1 (Conv1);

Boyut: 11x11 filtrelerle, adım (stride) boyutu 4x4 ile işlenir.

Kanal Sayısı: 96 adet filtre kullanılır.

Aktivasyon: ReLU (Rectified Linear Unit) aktivasyonu uygulanır.

Bu katman, giriş görüntüsündeki yüksek frekansta düşük seviyeli özellikleri çıkarmak için kullanılır. Örneğin, kenarlar, renk geçişleri ve benzeri özellikleri algılamak için 11x11 filtreler kullanılır.

Evrişim Katmanı 2 (Conv2);

Boyut: 5x5 filtrelerle, adım boyutu 1x1 ile işlenir.

Kanal Sayısı: 256 adet filtre kullanılır.

Aktivasyon: ReLU aktivasyonu uygulanır.

Bu katman, Conv1'den gelen özellikleri daha da işleyerek daha karmaşık ve soyut özellikleri çıkarmaya yardımcı olur. Daha küçük 5x5 filtreler kullanılır, böylece daha ince ayrıntıları algılayabilir.

Evrişim Katmanı 3 (Conv3);

Boyut: 3x3 filtrelerle, adım boyutu 1x1 ile işlenir.

Kanal Sayısı: 384 adet filtre kullanılır.

Aktivasyon: ReLU aktivasyonu uygulanır.

Bu katman, Conv2'den gelen özellikleri daha da işleyerek daha yüksek seviyeli özellikleri çıkarmak için kullanılır. 3x3 filtreler, daha ince ayrıntıları algılamaya devam eder.

Evrişim Katmanı 4 (Conv4);

Boyut: 3x3 filtrelerle, adım boyutu 1x1 ile işlenir.

Kanal Sayısı: 384 adet filtre kullanılır.

Aktivasyon: ReLU aktivasyonu uygulanır.

Conv3 gibi, bu katman da yüksek seviyeli özellikleri çıkarmak için kullanılır ve Conv3'ten gelen özellikleri daha da işler.

Evrişim Katmanı 5 (Conv5);

Boyut: 3x3 filtrelerle, adım boyutu 1x1 ile işlenir.

Kanal Sayısı: 256 adet filtre kullanılır.

Aktivasyon: ReLU aktivasyonu uygulanır.

Son evrişim katmanı olan Conv5, Conv4'ten gelen özellikleri daha da işleyerek en yüksek seviyeli özellikleri çıkarmak için kullanılır.

Bu evrişimli katmanlar, görüntüdeki farklı özellikleri hiyerarşik olarak çıkarmak için sıralanır. Her bir katman, önceki katmandan gelen özellikleri daha da soyutlaştırarak nihai sınıflandırma için kullanılan özellikleri elde etmeye yardımcı olur. AlexNet, bu evrişim katmanları ve ardışık tam bağlantılı katmanlarının birleşimi sayesinde büyük veri setleri üzerinde başarılı bir şekilde görsel tanıma görevlerini gerçekleştirir.

Havuzlama Katmanları: AlexNet, maksimum havuzlama (max-pooling) katmanlarını kullanır. Havuzlama katmanı, belirli bir bölgenin en büyük özelliğini korurken diğer bölgeleri atma işlemidir. Bu, özellik haritasının boyutunu azaltırken en belirgin özelliklerin korunmasına yardımcı olur.

AlexNet'te iki havuzlama katmanı bulunur;

Havuzlama Katmanı 1 (Pool1);

Boyut: 3x3 pencere boyutu ile ve adım boyutu 2x2 ile işlenir.

Max-pooling: Her 3x3 pencere içindeki en büyük özellik seçilir ve diğerleri atılır. Bu katman, Conv1 ve Conv2'den gelen özellik haritalarının boyutunu yarı yarıya küçültür.

Havuzlama Katmanı 2 (Pool2);

Boyut: 3x3 pencere boyutu ile ve adım boyutu 2x2 ile işlenir.

Max-pooling: Her 3x3 pencere içindeki en büyük özellik seçilir ve diğerleri atılır. Bu katman, Conv4 ve Conv5'den gelen özellik haritalarının boyutunu yarı yarıya küçültür.

Havuzlama katmanları, görüntü boyutunu azaltarak daha yüksek seviyeli özellikleri çıkarmadan önce hesaplama maliyetini düşürmek için kullanılır. Ayrıca, havuzlama işlemi, modelin küçük çeşitlilikler karşısında daha toleranslı olmasına yardımcı olabilir.

Tam Bağlantılı Katmanlar: Evrişim ve havuzlama katmanlarından sonra gelen çıktılar tam bağlantılı katmanlara beslenir. Son tam bağlantılı katman, sınıflandırma görevi için softmax aktivasyon fonksiyonu kullanır.

Tam Bağlantılı Katman 1 (Fully Connected Layer 1);

Boyut: 4096 nöron içerir.

Aktivasyon: ReLU (Rectified Linear Unit) aktivasyonu kullanılır.

Bu katman, havuzlama katmanlarından gelen özellik haritalarını düzleştirir ve yoğun bir bağlantılı katmandır. Yani, her nöron, önceki katmandan gelen tüm özellikleri alır. 4096 nöronlu bu katman, yüksek seviyeli özellikleri yakalamak ve daha da soyutlaştırmak için kullanılır.

Tam Bağlantılı Katman 2 (Fully Connected Layer 2);

Boyut: 4096 nöron içerir.

Aktivasyon: ReLU aktivasyonu kullanılır.

İkinci tam bağlantılı katman, bir önceki katmandan gelen 4096 nöronun çıkardığı özellikleri daha da işler. Bu katman, nesne sınıflandırma görevi için kullanılan nihai özellikleri oluşturur.

Çıkış katmanı, sonuçları sınıflandırmak için kullanılır. Softmax aktivasyonu, her sınıf için bir olasılık dağılımı üretir, böylece hangi sınıfa ait olduğu belirlenebilir.

Boyut: Sınıf sayısı kadar nöron içerir. AlexNet genellikle 1000 sınıf içeren ImageNet veri kümesi için eğitilmiştir.

Aktivasyon: Softmax aktivasyonu kullanılır.

AlexNet, tam bağlantılı katmanları kullanarak özellikleri daha yüksek seviyelere taşır ve nihai sınıflandırma işlemini gerçekleştirir. İkinci tam bağlantılı katman özellikle yüksek düzeyli özelliklerin öğrenilmesine yardımcı olurken, çıkış katmanı, sınıflandırma sonuçlarını üretir. Bu sonuçlar, görüntünün hangi sınıfa ait olduğunu belirlemek için kullanılır.

AlexNet, ImageNet gibi büyük veri setlerinde yüksek doğruluk elde etmek için bu tam bağlantılı katmanları ve genel CNN mimarisini başarıyla kullanmıştır.

AlexNet, önceki dönemlerdeki derin öğrenme modellerinden daha büyük ve derin olması, daha fazla veri kullanması ve daha etkili aktivasyon fonksiyonları (ReLU)

kullanması gibi faktörler nedeniyle büyük bir etki yaratmış ve derin öğrenme modellerinin gelişimine önemli katkılar sağlamıştır. Ayrıca, paralel hesaplamalar için GPU'lar gibi yüksek performanslı donanımların kullanımı da AlexNet'in başarısında kritik bir rol oynamıştır.

AlexNet, günümüzde derin öğrenme modellerinin temelini oluşturan birçok ileri teknik için temel teşkil eden önemli bir dönüm noktasıdır.

2.3.4. VGG 19 Derin Öğrenme Modeli ve Çalışma Prensibi

VGG-19 (Visual Geometry Group-19), Oxford Üniversitesi'ndeki Visual Geometry Group tarafından geliştirilen ve 2014 senesinde ILSVRC (ImageNet Large Scale Visual Recognition Challenge) yarışmasında önemli bir başarı elde eden bir derin öğrenme modelidir. İsmi 19 katmanından alır ve bu katmanlar, evrişim katmanları ve tam bağlantılı katmanlar olarak düzenlenir. VGG-19 modeli, 16 evrişim katmanı ve 3 tam bağlantılı katman olmak üzere toplam 19 katmandan oluşur (Kandhro, vd., 2024). Evrişim katmanlarının ardından havuzlama katmanları gelir. Bu sıralı evrişim ve havuzlama katmanları, girdi görüntüsünden başlayarak özelliklerin hiyerarşik bir şekilde çıkarılmasına olanak tanır. Son üç katman, tam bağlantılı katmanlardır ve sınıflandırma görevi için kullanılır.

Evrişim Katmanları: Evrişim katmanlarında, 3x3 boyutundaki küçük filtrelerle evrişim işlemi uygulanır (Kandhro, vd., 2024). Her evrişim katmanından sonra ReLU aktivasyon fonksiyonu kullanılır. Evrişim katmanlarının sayısı ve filtrelerin sayısı, özelliklerin çeşitli karmaşıklık seviyelerini temsil etmesi açısından artarak devam eder (Kansal ve Sharma, 2023).

VGG-19 modelinin evrişimli katmanları, görüntüdeki lokal özellikleri tanımak ve öğrenmek için kullanılır (Hişam, 2021). Bu katmanlar, giriş görüntüsünü daha küçük ve daha özet bir özellik haritasına dönüştürür. Her bir evrişimli katman, birçok filtre (kernel) içerir ve her filtre, görüntü üzerinde farklı özellikler (kenarlar, köşeler, dairesel desenler vb.) tanımak için kullanılır.

Evrişimli katmanlar aynı zamanda evrişim işlemi sırasında filtrelerin ağırlıklarını öğrenirler. Bu, görüntülerin içerdikleri özelliklere göre özelleştirilmiş filtrelerin oluşturulmasını sağlar. Daha yüksek katmanlarda daha soyut özellikler (örneğin yüzler veya nesneler) tanımlanabilir.

Evrişimli katmanlar arasına ReLU (Rectified Linear Unit) gibi aktivasyon fonksiyonları eklenir. Bu fonksiyonlar, modelin doğrusal olmayan ilişkileri öğrenmesine yardımcı olur. ReLU, negatif giriş değerlerini sıfıra dönüştürürken pozitif değerleri değiştirmeyen basit bir aktivasyon fonksiyonudur.

Havuzlama Katmanları: Havuzlama katmanları, evrişimli sinir ağlarının (CNN) önemli bileşenlerinden biridir ve görüntülerin boyutunu küçültmek ve özelliklerin çeşitli çözünürlük seviyelerinde öğrenilmesine yardımcı olur. VGG-19 modelindeki havuzlama katmanları şu şekilde çalışır:

Havuzlama katmanları, görüntünün boyutunu küçültme ve özetleme işlevini yerine getirir. Bu işlem, aynı zamanda modelin translasyon (yer değiştirme) invariyanasını artırarak belirli bir nesneyi farklı konumlarında tanıyabilmesini sağlar. Havuzlama, özellikle evrişimli katmanlardan (convolutional layers) elde edilen özellik haritalarının boyutunu azaltmak için kullanılır.

VGG-19 modelinde yaygın olarak kullanılan havuzlama türü "maksimum havuzlama" veya "max pooling"dir. Maksimum havuzlama işlemi, her bölgeden yalnızca en büyük piksel değerini seçer. Örneğin, 2x2 piksellik bir pencereyle maksimum havuzlama uygulandığında, her 2x2 piksellik bölgeden en büyük piksel değeri alınır ve sonuçta görüntü boyutu küçülür.

Havuzlama katmanlarının genellikle öğrenilmiş parametreleri yoktur. Maksimum havuzlama işlemi, yalnızca görüntünün çeşitli bölgelerinden en büyük piksel değerini seçme işlemi ile sınırlıdır. Bu nedenle havuzlama katmanları, CNN içinde daha hafif ve hesaplama açısından verimli katmanlardır.

VGG-19 modelinde havuzlama katmanları, evrişimli katmanlar arasında yer alır. Yani, evrişimli katmanlardan gelen özellik haritaları, havuzlama katmanlarına verilir ve bu katmanlar arasında havuzlama işlemi uygulanır.

Havuzlama katmanları, modelin daha önce öğrenilen özellikleri daha küçük boyutta ve daha özet bir temsil haline getirerek, daha yüksek katmanlarda daha soyut ve genel özelliklerin öğrenilmesine olanak tanır. Bu, görüntü sınıflandırma, nesne tanıma ve diğer görsel tanıma görevlerinde modelin başarısını artırır.

Tam Bağlantılı Katmanlar: Evrişim ve havuzlama katmanlarından gelen çıktılar, tam bağlantılı katmanlara beslenir. VGG-19 modelinin tam bağlantılı katmanları,

evrişimli katmanlardan gelen özellikleri kullanarak sınıflandırma işlemi için sonuçları üreten katmanlardır.

Tam bağlantılı katmanlar, öğrenilen özellikleri bir araya getirerek giriş görüntüsünün hangi sınıfa ait olduğunu tahmin eder. Bu katmanlar, evrişimli katmanlardan gelen özellik haritalarını düzleştirir ve ardışık tam bağlantılı katmanlardan geçirir.

Evrişimli katmanlar, görüntünün farklı özelliklerini çıkarmak için tasarlanmıştır ve bu özellikler sınıflandırma görevi için oldukça soyut olabilir. Tam bağlantılı katmanlar, bu soyut özellikleri kullanarak nihai sınıflandırma yapar. Her tam bağlantılı katman, önceki katmanın çıktılarını alır ve bu çıktıları ağırlıklarla çarpıp sınıf tahminlerini üretir.

Tam bağlantılı katmanlar genellikle softmax aktivasyon fonksiyonu ile sona erer. Softmax, sınıf tahminlerini olasılık dağılımına dönüştürür, böylece her sınıf için bir olasılık değeri elde edilir ve en yüksek olasılığa sahip sınıf tahmini seçilir.

VGG-19 modelinde birden fazla tam bağlantılı katman bulunur. İlk tam bağlantılı katmanlar, daha düşük seviyedeki özellikleri kullanarak sınıf tahminlerini üretir. Ardışık tam bağlantılı katmanlar, daha karmaşık ve soyut özellikleri bir araya getirerek daha yüksek düzeyde sınıflandırma yapar.

Tam bağlantılı katmanlar, evrişimli katmanlar gibi öğrenilebilir ağırlıklar içerir. Bu ağırlıklar, eğitim süreci sırasında belirli bir görevi en iyi şekilde yerine getirmek için optimize edilir. Geri yayılma (backpropagation) algoritması kullanılarak, modelin hata miktarı hesaplanır ve bu hata, ağırlıkların güncellenmesi için kullanılır.

VGG-19 modelinin tam bağlantılı katmanları, görüntü sınıflandırma görevleri için son derece etkilidir. Bu katmanlar, evrişimli katmanlardan gelen özellikleri kullanarak nesneleri veya sınıfları tanımlama yeteneğine sahiptir.

2.3.5. VGG 16 Derin Öğrenme Modeli ve VGG 19 ile Arasındaki Farklar

VGG-16, 2014'te gerçekleşen ImageNet Large Scale Visual Recognition Challenge (LSVRC) yarışmasında önemli bir başarı elde etti ve görsel tanıma alanında etkileyici sonuçlar sergiledi. Şekil 2.14'te VGG16 katman yapısı gösterilmiştir. Bu derin öğrenme modeli, karmaşık görsel özellikleri öğrenmek için tasarlanmış 16 katmanlı bir evrişimli sinir ağı (CNN) mimarisine sahiptir.

Şekil 2.14: VGG 16 Katmanlı Mimari Yapısı



Mimarisi, ardışık olarak sıralanmış evrişim ve tam bağlantılı katmanlardan oluşur. Her evrişim katmanı, ReLU (Rectified Linear Unit) gibi bir aktivasyon fonksiyonunu izler ve ardından bir pooling katmanı gelir. Bu mimari, önceki derin öğrenme modellerinden daha derin ve daha fazla parametreye sahiptir, bu da daha karmaşık ve çeşitli görsel özelliklerin öğrenilmesini sağlar.

VGG-16, nesne tanıma ve sınıflandırma görevlerinde yaygın olarak kullanılmaktadır. Ayrıca, önceden eğitilmiş ağırlıkların transfer öğrenme uygulamalarında kullanılabilmesi, onu tercih edilen bir seçenek haline getirir.

VGG-16 ve VGG-19 arasındaki esas fark, katman sayılarıdır. Adlarından da anlaşılacağı gibi, VGG-16 16 katman içerirken, VGG-19 ise 19 katmandan oluşur. Bu temel ayrımın yanı sıra, diğer farklar da mevcuttur. Hem VGG-16 hem de VGG-19, evrişimli sinir ağı (CNN) tabanlıdır. Her ikisi de ardışık olarak evrişim ve havuzlama katmanlarından oluşur, ardından tam bağlantılı katmanlar gelir. VGG-19, VGG-16'nın mimarisine ek olarak daha fazla evrişim ve tam bağlantılı katmanlar ekler.

VGG-19, VGG-16'ya kıyasla daha fazla parametreye sahiptir. Bu, daha fazla evrişim filtresi ve tam bağlantılı ağırlık demeti anlamına gelir. Daha fazla parametre genellikle modelin daha karmaşık ve genelde daha detaylı özellikleri öğrenmesine izin verir. VGG-19'un daha fazla parametreye sahip olması, daha fazla hesaplama maliyeti gerektirir. Bu da eğitim ve tahmin sürelerini artırabilir. VGG-16, daha az parametre sayesinde VGG-19'a kıyasla daha hızlı çalışabilir.

VGG-19'un daha fazla parametreye sahip olması, aynı zamanda aşırı uyum riskini de artırabilir. Daha büyük modeller, eğitim verilerine daha fazla uyum sağlama eğilimindedir ve bu da genelleme yeteneğini zorlaştırabilir.


2.3.6. YOLO Derin Öğrenme Modeli ve Çalışma Prensibi

YOLO (You Only Look Once), nesne algılama için kullanılan bir derin öğrenme modelidir. YOLO'nun önemli bir özelliği, tek bir adımda bir görüntünün tamamını analiz edebilmesidir. Bu, nesne algılama ve konumlandırma işlemlerini aynı anda gerçekleştirebilme yeteneği sağlar.

Giriş görüntü, model tarafından işlenir ve belirli bir boyuta (örneğin, 416x416 piksel) yeniden boyutlandırılır. Görüntü, modelin girdi olarak kullanabileceği özellik vektörüne dönüştürülür. YOLO genellikle önceden eğitilmiş bir evrişimli sinir ağı (CNN) kullanır (Şekil 2.15). Bu ağ, giriş görüntüsünden özellik haritaları çıkarır. Özellik haritaları, farklı nesnelerin özelliklerini temsil eden özellikler içerir. Görüntü, bir ızgara sistemi içinde bölünür. Her bir hücre, belirli bir bölgeyi temsil eder. Her hücre, belirli bir sayıda kutunun ve bu kutuların içinde olası nesnelerin olup olmadığını tahmin eder. Her hücre, nesnenin sınıfını ve konumunu içeren bir vektör üretir. Bu vektörler, nesnenin özelliklerini tanımlar. Sınıf tahminleri, nesnenin hangi sınıfa ait olduğunu belirler. Konum tahminleri, nesnenin ızgara hücresi içindeki konumunu ifade eder.

YOLO, çıktıdaki olası nesneleri filtrelemek için non-maximum suppression kullanır (Jiang, vd., 2022). Bu, çakışan tahmin kutularını temizleyerek en güvenilir tahminleri elde etmeye yardımcı olur. YOLO'nun bu "tek bakışta" yaklaşımı, diğer nesne algılama yöntemlerine göre daha hızlıdır ve gerçek zamanlı uygulamalar için uygundur. Aynı zamanda birden çok nesneyi aynı anda algılayabilir, bu da onu çoklu nesne algılama görevlerinde etkili kılar.

Şekil 2.15: YOLO Mimarisi



2.3.7. YOLOv2 Derin Öğrenme Modeli ve Çalışma Prensibi

YOLO (You Only Look Once), nesne tespiti için kullanılan bir derin öğrenme modelidir ve YOLO'nun ikinci versiyonu YOLOv2 veya YOLO9000 olarak bilinmektedir. YOLO, bir görüntüyü tek bir geçişte analiz ederek nesneleri tespit etme fikrine dayanan bir nesne tespiti algoritmasıdır.

Nesne tespiti görevlerine ek olarak, YOLOv2 aynı zamanda görüntüyü farklı sınıflara ayrılmış bölgelere bölme ve her pikselin hangi sınıfa ait olduğunu tahmin etme amacıyla kullanılan bir anlam segmentasyonu özelliği içerir.

YOLOv2, YOLO9000 adlı bir sınıflandırıcıyı içerir. Bu, 9000'den fazla sınıfı tanıma yeteneği sağlar. Mimari olarak Darknet-19'u kullanır (Tablo 2.1).

Tablo 2.1: Darknet-19 Mimarisi

Türü	Filtreler	Boyut /Stride	Çıkış
Convolutional	32	3x3	224x224
MaxPool		2x2/2	112x112
Convolutional	64	3x3	112x112
MaxPool		2x2/2	56x56
Convolutional	128	3x3	56x56
Convolutional	64	1x1	56x56
Convolutional	128	3x3	56x56
MaxPool		2x2/2	28x28
Convolutional	256	3x3	28x28
Convolutional	128	1x1	28x28
Convolutional	256	3x3	28x28
MaxPool		2x2/2	14x14
Convolutional	512	3x3	14x14
Convolutional	256	1x1	14x14
Convolutional	512	3x3	14x14
Convolutional	256	1x1	14x14
Convolutional	512	3x3	14x14
MaxPool		2x2/2	7x7
Convolutional	1024	3x3	7x7
Convolutional	512	1x1	7x7
Convolutional	1024	3x3	7x7
Convolutional	512	1x1	7x7
Convolutional	1024	3x3	7x7
Convolutional	1000	1x1	7x7
AvgPool		Global	1000
Softmax			

YOLO algoritmaları genellikle gerçek zamanlı nesne tespiti için optimize edilmiştir ve yüksek hızda çalışma imkânı sağlar. YOLOv2, birden fazla nesne sınıfını tanıma yeteneğiyle dikkat çeker.

Kullanım alanlarına değinmek gerekirse; Hızlı çalışan algoritmalar, özellikle otomotiv sistemlerinde nesne tespiti görevlerinde tercih edilir. Gerçek zamanlı video analizi ve gözetim uygulamalarında yaygın olarak kullanılır. YOLOv2, genel nesne tanıma görevlerinde kullanılabilir.

2.3.8. YOLOv3 Derin Öğrenme Modeli ve Çalışma Prensibi

YOLOv3, YOLO'nun üçüncü versiyonudur ve önceki sürümlere kıyasla bir dizi yenilik ve gelişmeyi içinde barındırır (Li, vd., 2020). Bu yeni versiyon, önceki kısıtlamalara ve performans zorluklarına çeşitli çözümler sunar. Bu versiyonla birlikte gelen en temel yenilik; bounding boxların farklı boyutlar için tespit edilebilmesidir. Temel katman yapısı ise 53'e çıkarılmıştır.


YOLOv3, algılamada üç farklı ölçek (13x13, 26x26 ve 52x52) kullanarak farklı boyuttaki nesneleri doğru bir şekilde tespit etmeyi sağlar. Bu, algılama doğruluğunu önemli ölçüde artırır. Ayrıca, her bir sınırlayıcı kutu için birden fazla etiketli tahmin ve daha gelişmiş bir özellik çıkarıcı ağ gibi özellikler sunar.

YOLOv3-Ultralytics, orijinal modele benzer performans sunar, ancak daha fazla önceden eğitilmiş model, ek eğitim teknikleri ve daha kolay özelleştirme seçenekleri ile birlikte gelir. Bu, uygulama esnekliğini ve kullanıcı dostluğunu artırır.

YOLOv3, önceden tanımlanmış sınırlayıcı kutulara ve nesne güven puanlarına olan ihtiyacı ortadan kaldırarak, farklı boyut ve şekillerdeki nesneleri daha iyi algılayabilir. Bu özellik, YOLOv3u'nun nesne algılama görevleri için daha güvenilir ve hassas olmasını sağlamaktadır.

YOLOv3, nesneleri tanımak için üç farklı ölçekteki özellik haritalarını kullanarak farklı boyutlardaki nesneleri algılar (YOLOv2'den farklı olarak). YOLOv3, YOLO9000 adlı sınıflandırıcıyı bünyesinde barındırarak geniş bir nesne sınıf yelpazesini kapsayabilir (Şekil 2.16). YOLOv3, daha önceki sürümlerde kullanılan Darknet-19 mimarisine göre daha derin olan Darknet-53 mimarisini kullanır.

Şekil 2.16: Yolov3 Mimarisi



YOLOv3 serisi, nesne algılama görevleri için özel olarak tasarlanmış bir dizi model içerir, bunlar arasında YOLOv3, YOLOv3-Ultralytics ve YOLOv3u bulunmaktadır. Bu modeller, doğruluk ile hızı başarıyla dengeleyerek farklı gerçek dünya

senaryolarında etkili bir performans sergilerler. Her bir versiyon, benzersiz özellikler ve optimizasyonlar sunar, böylece çeşitli uygulamalara uygun hale gelirler.


Her üç model de çeşitli aşamalarda model dağıtım ve geliştirme için geniş bir mod yelpazesi sunar. Bu modlar arasında Çıkarım, Doğrulama, Eğitim ve Dışa Aktarma bulunur; bu da kullanıcılara eksiksiz bir nesne tespit aracı seti sağlar.

YOLOv3, önceki sürümlere göre genellikle daha yüksek nesne algılama doğruluğuna sahiptir. Farklı boyutlardaki nesneleri daha iyi algılamak için ölçekli nesne algılama yeteneklerini içerir.

2.3.9. YOLOv4 Derin Öğrenme Modeli ve Çalışma Prensipleri

YOLOv4, nesne tespiti için kullanılan son teknoloji bir derin öğrenme modelidir. Bu model, görüntülerdeki nesneleri tespit etmek için geliştirilmiş bir algoritma sunar (Şekil 2.17).

Şekil 2.17: YOLOv4 Mimarisi



YOLOv4, çeşitli yenilikçi özelliklerin bir araya getirilmesiyle performansını optimize eder. Bunlar arasında Ağırlıklı-Arızi Bağlantılar (WRC), Çapraz Aşamalı-Kısmi Bağlantılar (CSP), Çapraz mini-Yığın Normalleştirme (CmBN), Kendinden-adversarial-eğitim (SAT), Yanlış-aktivasyon, Mozaik veri artırımı, DropBlock düzenlemesi ve CIOU kaybı yer alır. Bu özellikler, son teknoloji ürünü sonuçlar elde etmek için bir araya getirilmiştir.

Bir nesne detektörü, girdi, omurga, boyun ve kafa gibi çeşitli bileşenlerden oluşur. YOLOv4'ün omurgası, ImageNet üzerinde önceden eğitilmiştir ve nesnelerin sınıflarını ve sınırlayıcı kutularını tahmin etmek için kullanılır. Omurga, VGG, ResNet, ResNeXt veya DenseNet gibi çeşitli modellerden seçilebilir. Dedektörün boyun kısmı, farklı aşamalardan özellik haritalarını toplamak için kullanılır ve genellikle birkaç aşağıdan yukarıya yol ve birkaç yukarıdan aşağıya yol içerir. Baş kısmı, nihai nesne tespitlerini ve sınıflandırmalarını yapmak için kullanılır.

YOLOv4, farklı özellik çıkarma katmanlarından oluşan bir sinir ağıdır. Bu katmanlar, görüntüdeki nesne özelliklerini öğrenmek için kullanılır ve daha sonra bu özellikler nesne konumları ve sınıfları belirlemek için kullanılan bir detektör katmanına aktarılır.

YOLOv4'ün performansını artırmak için çeşitli teknikler kullanılır. Örneğin, model CSP (Cross Stage Partial) bağlantıları adı verilen bir bağlantı mekanizması kullanır, bu da özellik çıkarma katmanlarını daha etkili hale getirir. Ayrıca, model Çoklu Yönlü Çıktı (Multi-Head Output) adı verilen bir çıktı mekanizması kullanır, bu da farklı ölçeklerdeki nesneleri daha iyi tespit etmeye yardımcı olur.

YOLOv4, YOLOv3'te kullanılan tekniklerin yanı sıra yeni geliştirmeler de içerir. Örneğin, model eğitim verimliliğini artırmak için Bag of Freebies (BOF) adı verilen bir dizi teknik kullanır. Bu teknikler arasında çeşitli veri artırma yöntemleri, öğrenme hızını artıran optimizasyon algoritmaları ve eğitim verimliliğini artıran bir eğitim planı bulunur.

Tüm bunların ışığında, YOLOv4, hızlı ve doğru nesne tespiti için en son teknolojiyi sunar. Bu özellikleri sayesinde, özellikle gerçek zamanlı uygulamalarda kullanımı yaygındır ve otomotiv endüstrisinden güvenlik sistemlerine kadar birçok alanda başarıyla kullanılmaktadır.

2.3.10. YOLOv5 Derin Öğrenme Modeli ve Çalışma Prensibi

YOLOv5, nesne tespiti alanında oldukça etkili olan son nesil bir derin öğrenme algoritmasıdır. İlk kez Joseph Redmon tarafından 2016'da geliştirilen YOLO ("You Only Look Once") algoritmasının daha yeni bir versiyonudur. YOLOv5, PyTorch kütüphanesiyle geliştirilmiş olup, araştırma ve endüstri uygulamalarında geniş çapta kullanılmaktadır.

YOLOv5, nesne tespit görevlerini hızlı bir şekilde gerçekleştirirken yüksek doğruluk sağlar. Bu, gerçek zamanlı uygulamalar için idealdir. YOLOv5, kullanıcıların kendi veri kümeleri üzerinde modeli yeniden eğitmesini kolaylaştıran açık kaynaklı bir yapıya sahiptir. YOLOv5, farklı boyutlarda ve karmaşıklıkta modelleri içerir, bu da çeşitli ihtiyaçlara uygun modellerin kullanılabilmesini sağlar. YOLOv5, birçok farklı nesne sınıfını algılayabilir ve sınıflandırabilir.

YOLOv5'in çalışma prensibine değinecek olursak;

İlk olarak, nesne tespiti için giriş olarak alınan görüntü işlenir. Görüntü, genellikle standart boyutlara yeniden boyutlandırılır ve ön işleme adımları (örneğin normalizasyon) uygulanır.

YOLOv5, görüntüyü bir ağa besler ve bu ağ, nesne algılama işlemini gerçekleştirir. Model, görüntü üzerinde nesnelerin konumunu, boyutunu ve sınıfını tahmin etmek için içinde bir dizi katmanı (convolutional layer) kullanır.

Görüntü, bir ızgara olarak adlandırılan bir yapıya bölünür. Her bir hücre, belirli bir alanı temsil eder ve bu alanlardaki potansiyel nesnelerin varlığını belirlemek için kullanılır.

Her bir ızgara hücresi, o hücrede bulunan nesnelerin varlığına dair olasılık tahminlerini yapar. Bu tahminler, bir nesnenin ızgaranın hangi bölgesinde olduğu, nesnenin boyutları ve sınıfı gibi bilgileri içerir.

Modelin çıkardığı tahminler genellikle örtüşen veya aynı nesneyi temsil eden çoklu tahminleri içerir. Bu aşamada, NMS algoritması kullanılarak en güvenilir tahminler seçilir ve diğerleri elemine edilir.

Nihai olarak, algılanan nesnelerin koordinatları, sınıfları ve güven skorları gibi bilgilerle birlikte sonuçlar elde edilir. Bu bilgiler, genellikle kullanıcıya sunulacak veya başka bir işlemde kullanılacak şekilde düzenlenir.

YOLOv5, end-to-end bir mimariye sahiptir, bu da giriş görüntüsünden başlayarak nesne algılama sonuçlarını doğrudan üretebilir. Bu nedenle, gerçek zamanlı uygulamalar için uygun ve etkilidir.

Şekil 2.18: Gerçek Zamanlı Çoklu Obje Takipçisi (Multi Object Tracker) Oluşturabilmek İçin Örnek Kod Satırı

```

1  model = YOLO()
2
3  for input_path in args.files:
4      video = Video(input_path=input_path)
5      tracker = Tracker(
6          distance_function=euclidean_distance,
7          distance_threshold=max_distance_between_points,
8      )
9
10     for frame in video:
11         yolo_detections = model(frame)
12         detections = yolo_detections_to_norfair_detections(yolo_detections)
13         tracked_objects = tracker.update(detections=detections)
14         norfair.draw_points(frame, detections)
15         norfair.draw_tracked_objects(frame, tracked_objects)
16         video.write(frame)

```

Kaynak: <https://github.com/tryolabs/norfair/tree/master/demos/yolov5>

2.3.11. YOLOv6 Derin Öğrenme Modeli ve Çalışma Prensibi

YOLOv6, YOLO mimarisine dayalı tek aşamalı bir nesne algılama modelidir ve genellikle MT-YOLOv6 olarak da adlandırılır. Bu model, Meituan tarafından geliştirilmiştir ve YOLOv5'e kıyasla daha güçlü bir performans sergilerken MS COCO veri setinde test edilmiştir.

Meituan Teknik Ekibi, şirket içinde araştırma ve geliştirme faaliyetleri yürüten bir ekiptir. Meituan, çeşitli sektörlerde faaliyet gösteren bir Çin merkezli teknoloji şirkettir ve özellikle online yemek siparişi, seyahat hizmetleri ve diğer alanlarda hizmet sunmaktadır. Teknik ekip, yapay zeka ve derin öğrenme gibi alanlarda çalışarak şirketin ürün ve hizmetlerini geliştirmeyi amaçlar.

YOLOv6, çift yönlü birleştirme (BiC) modülünü kullanır. Bu modül, dedektörün lokalizasyon sinyallerini iyileştirir ve performans artışı sağlar, ancak hızda önemli bir düşüş olmaz.


YOLOv6, çapa destekli eğitim (AAT) stratejisini izler. Bu strateji, çapa tabanlı ve çapasız paradigma avantajlarını birleştirerek çıkarım verimliliğini artırır.

YOLOv6, daha derin bir omurga ve boyun tasarımına sahiptir, bu da yüksek çözünürlüklü girdilerde en son teknolojiye sahip performans sunar.

Daha küçük modellerin performansını artırmak için, eğitim sırasında yardımcı regresyon dalını geliştiren ve çıkarımda belirgin bir hız düşüşünü önlemek için yeni bir damıtma stratejisi kullanılır.

Bu özellikler, endüstriye yeni ve etkili çözümler sunarak nesne algılama teknolojisinin gelişimine katkıda bulunabilir.

Şekil 2.19: YOLOv6 Decoupled Head



YOLO modellerinde YOLOv5'e kadar olan sürümlerde, sınıflandırma ve kutu regresyonu başlıkları aynı özellikleri paylaşır. Ancak YOLOx ve YOLOv6'da başlık ayrılmıştır. Bu, ağıın bu özellikleri nihai başlıktan ayıran ek katmanlara sahip olduğu anlamına gelir. Bu değişikliğin model performansını artırdığı deneysel olarak gösterilmiştir. Mimarideki bu değişikliklere ek olarak, YOLOv6 deposu eğitim işlemine bazı geliştirmeler de uygular. Bu geliştirmeler arasında çapa bağımsız (NMS bağımsız değil) eğitim, SimOTA etiketi atama ve SIOU kutu regresyon kaybı bulunmaktadır.

YOLOv6, YOLOv5, YOLOX ve PPE-YOLOE gibi modellere kıyasla, çeşitli FPS hızlarında COCO veri kümesinde daha yüksek bir mAP elde eder. Ancak, COCO veri kümesinin bu modellerin kendi veri kümenizde nasıl performans göstereceği konusunda mükemmel bir model olmadığını belirtmek önemlidir.

YOLOv6 modeli, Tesla V100 GPU üzerinde test edilmiş ve benzer çıkarma hızlarıyla YOLOv5'e göre COCO veri kümesini daha doğru bir şekilde modellediği gösterilmiştir.

2.3.12. YOLOv7 Derin Öğrenme Modeli ve Çalışma Prensipleri

YOLOv7, gerçek zamanlı nesne algılama alanında son teknoloji ürünü bir modeldir ve hız ile doğruluk açısından bilinen diğer tüm nesne dedektörlerini geride bırakacak düzeyde performans sunar. Bu model, Meituan'daki araştırmacılar tarafından geliştirilmiş olup GPU V100 gibi yüksek performanslı donanımlarda 30 FPS veya daha yüksek hızlarda çalışarak en yüksek doğruluğa sahiptir.

Geleneksel gerçek zamanlı nesne algılama modellerinin aksine, YOLOv7 eğitim sürecinin optimizasyonuna odaklanır. Bu da "eğitilebilir ücretsiz torba" kavramını kullanarak nesne algılama doğruluğunu artırmayı hedeflerken çıkarım maliyetini artırmadan çalışır.

YOLOv7, farklı ağırlardaki katmanlara gradyan yayılım yoluyla uygulanabilen bir strateji olan planlı bir yeniden parametrelili model önerir. Birden fazla çıktı katmanı olan modelin eğitiminde yeni bir sorunu çözmek için kılavuzlu etiket ataması adı verilen bir yöntem sunar. Parametreleri ve hesaplamayı etkin bir şekilde kullanarak gerçek zamanlı nesne dedektörü için önerilen yöntemlerdir. Yaklaşık %40 parametre ve %50 hesaplama azaltımıyla daha hızlı çıkarım hızı ve yüksek tespit doğruluğu sağlar.

YOLOv7'nin kullanım örnekleri arasında gerçek zamanlı nesne algılama, çoklu nesne takibi, otonom sürüş, robotik ve tıbbi görüntü analizi gibi birçok bilgisayarla görme sistemine katkı sağlamak yer alır. Ancak, yazının yazıldığı tarihte Ultralytics tarafından YOLOv7 modellerinin desteklenmediği belirtilmektedir, bu nedenle YOLOv7'yi kullanmak isteyenlerin doğrudan YOLOv7 GitHub deposuna başvurmaları gerekmektedir.

2.3.13. YOLOv8 Derin Öğrenme Modeli ve Çalışma Prensipleri

YoloV8, gerçek zamanlı nesne dedektörlerinin en yeni versiyonudur ve hem doğruluk hem de hız açısından üstün performans sunar. Önceki sürümlerdeki geliştirmelerin üzerine inşa edilmiş olup çeşitli nesne algılama görevleri için ideal bir seçim sunar.

Temel özellikler arasında gelişmiş omurga ve boyun mimarileri bulunmaktadır. YoloV8, son teknoloji omurga ve boyun mimarilerini kullanarak gelişmiş özellik çıkarma ve nesne algılama performansı elde eder. Ayrıca, çapasız bölünmüş Ultralytics başlığı

gibi yeni özelliklerle donatılmıştır, bu da daha iyi doğruluk ve daha verimli bir algılama sürecine katkı sağlar.

YoloV8, doğruluk ve hız arasında optimize edilmiş bir denge sunar. Bu özellik, çeşitli uygulama alanlarındaki gerçek zamanlı nesne algılama görevlerinde kullanım için idealdir. Ayrıca, çeşitli önceden eğitilmiş modeller sunarak kullanıcıların özel gereksinimlerine uygun modeli seçmelerini sağlar.

YOLOv8 serisi, bilgisayarla görme alanındaki çeşitli görevlere uzmanlaşmış farklı modeller sunar. Bu modeller, nesne algılama, örnek segmentasyon, poz/anahtar nokta algılama, yönlendirilmiş nesne algılama ve sınıflandırma gibi çeşitli görevleri karşılamak üzere tasarlanmıştır.

Her bir YOLOv8 modeli, belirli bir görev için optimize edilmiş olup yüksek performans ve doğruluk sağlar. Ayrıca, çeşitli operasyonel modlarla uyumludur ve dağıtım ve geliştirmenin farklı aşamalarında kullanımlarını kolaylaştırır, bu da kullanıcıların ihtiyaçlarına göre esneklik sağlar.

YOLOv8, geliştiricilerin kendi gereksinimlerine uyacak şekilde özelleştirebilecekleri esnek bir mimari sunar. YOLOv8'in adaptif eğitim yetenekleri, yeni tekniklerle eğitim sırasında kayıp dengesini sağlayarak öğrenme oranını artırır. Bu, daha iyi doğruluk, hızlı yakınsama ve genel olarak daha iyi model performansına katkıda bulunur.

Yeni semantik segmentasyon ve sınıf tahmin yetenekleri, temel nesne algılama yeteneklerinin yanı sıra etkinlikleri, renkleri, dokuları ve hatta nesneler arasındaki ilişkileri bile algılayabilir. Yeni veri artırma teknikleri, gerçek dünya koşullarında ideal olmayan nesne algılama senaryolarında, düşük çözünürlük, kapanma gibi görüntü varyasyonlarının üstesinden gelmeye yardımcı olur.


YOLOv8, CSPDarknet (varsayılan omurga), EfficientNet (hafif omurga) ve ResNet (klasik omurga) gibi farklı omurgalar için destek sunar. Kullanıcılar, CSPDarknet53'ü YOLOv8'in giriş ve çıkış boyutlarıyla uyumlu herhangi bir CNN mimarisiyle değiştirerek omurgayı özelleştirebilirler.

2.3.14. Mask R-CNN Derin Öğrenme Modeli ve Çalışma Prensibi

Mask R-CNN (Region-based Convolutional Neural Network) bir nesne tespiti ve görüntü segmentasyonu yöntemidir ve 2017 yılında Facebook AI Research (FAIR)

tarafından geliştirilmiştir. Mask R-CNN, Faster R-CNN yapısını kullanarak, nesne tespiti ve bölümlendirme problemlerini tek bir end-to-end ağda çözer.

Şekil 2.20: Mask-R CNN Mimarisi



Mask R-CNN, görüntülerde nesneleri tanımlama ve piksel düzeyinde nesne ayırma amacıyla geliştirilen derin öğrenme modelidir (Xu, vd., 2022). Bu teknik, R-CNN modelinin evrim geçirmiş bir türevidir ve nesne tanımlama ile segmentasyon görevlerinde daha yüksek doğruluk sağlar.

Mask R-CNN, bir dizi farklı konvolüsyonel sinir ağı (CNN) katmanını bir araya getiren bir yapıya sahiptir. İlk olarak, nesneleri tespit etmek için Faster R-CNN modeli kullanılır (Şekil 2.20). Bu model, görüntüdeki nesneleri tespit etmek için öncelikle bölgesel özellik haritaları oluşturur. Bu haritalar, bölgesel öneriler adı verilen potansiyel nesne alanlarının belirlenmesinde kullanılır. Bölgesel öneriler, olası nesne bölgelerini sınırlayan dikdörtgen kutular olarak temsil edilir.

Daha sonra, Mask R-CNN, her bölgesel öneri için bir maske tahmin ağı kullanarak piksel bazında nesne segmentasyonu gerçekleştirir. Bu ağ, her bölgesel önerinin içindeki nesne piksellerini belirlemek için kullanılır. Bölgesel önerilerin sınıflandırılması ve konumlarının belirlenmesinin ardından, piksel bazlı segmentasyon ağı, bölgesel önerilerin içindeki nesne piksellerini ayırt etmeye çalışır.

Mask R-CNN'yi eğitirken, modelin hem nesne tespiti hem de piksel bazlı segmentasyonu başarılı bir şekilde gerçekleştirebilmesi için hem bölgesel öneri sınıflandırma hem de maske tahmini görevleri optimize edilir. Bölgesel öneri sınıflandırma görevi, önerilen bölgelerin nesne veya arka plana ait olup olmadığını

belirlerken, maske tahmini görevi, bölgesel önerilerin içindeki nesne piksellerini doğru bir şekilde tahmin etmeye çalışır.

Mask R-CNN yaklaşımı, özellikle birden fazla nesnenin olduğu durumlarda nesne tespiti ve piksel bazlı segmentasyon için oldukça etkilidir. Bu teknik, görüntü işleme ve yapay zeka alanlarında geniş bir kullanım alanına sahiptir.

Mask R-CNN, bölgesel önerilerin oluşturulması için Faster R-CNN'in RPN (Region Proposal Network - Bölgesel Öneri Ağı) mekanizmasını kullanır. RPN, görüntüdeki olası nesne bölgelerini önerir.

Bölgesel öneriler elde edildikten sonra, her bir bölge için nesnenin kesin konumunu ve sınıfını belirlemek için bir nesne tanıma ağı kullanılır. Bu aşamada, her bir bölgedeki nesne olasılıkları hesaplanır, benzer şekilde Faster R-CNN'de olduğu gibi.

Mask R-CNN'nin belirgin özelliği, her bir bölge için piksel bazında maske tahmini yapmasıdır. Maske tahmini için, her bir bölgeye özel bir ağ gönderilir ve bu ağ, bölgeyi kaplayan nesnenin hangi pikselleri içerdiğini tahmin eder.

Mask R-CNN'nin eğitimi için farklı kayıp fonksiyonları kullanılır. Konum ve sınıflandırma görevleri için genellikle regresyon ve softmax fonksiyonlarına dayalı kayıp hesaplamaları yapılır. Maske tahmini için ise piksel bazında bir kayıp fonksiyonu kullanılır, genellikle çapraz entropi temellidir.

Mask R-CNN, gerçek veri üzerinde etiketlenmiş örneklerle eğitilir. Eğitimde kullanılan kayıp fonksiyonlarına göre ağı güncellemek için bir optimizasyon algoritması kullanılır. Adam veya SGD (Stokastik Gradyan İniş) gibi popüler optimizasyon algoritmalarından biri tercih edilebilir.

Tüm bunların ışığında, Mask R-CNN, nesne tanıma ve segmentasyonunu aynı anda gerçekleştirebilen güçlü bir derin öğrenme modelidir. Bölgesel öneriler, nesne tanıma ve maske tahmini aşamalarını içeren bu model, özellikle karmaşık ve detaylı nesne segmentasyonu görevlerinde etkileyici sonuçlar sunmaktadır.

2.3.15. SSD Derin Öğrenme Modeli ve Çalışma Prensibi

SSD (Tek Atışlı Çoklu Kutu Algılayıcı), görüntüde nesne tespiti için geliştirilmiş bir derin öğrenme modelidir. Diğer nesne tespiti sistemleri gibi, SSD de

görüntüdeki nesneleri tespit etmek için özellik çıkarma ve algılayıcı katmanlarını kullanır.

SSD, isminde de belirtildiği gibi, bir görüntüyü tek bir aşamada analiz ederek nesneleri tespit eder (Li, vd., 2018). Diğer nesne tespiti modellerinin aksine, SSD ağı aynı anda farklı ölçeklerdeki nesneleri algılayabilir.

SSD, nesne tespiti performansını artırmak için çeşitli stratejiler kullanır. Örneğin, özellik çıkarma katmanlarından elde edilen özellikleri kullanarak nesne konumlarını ve sınıflarını belirlemek için çeşitli boyutlarda ve en-boy oranlarında kutular oluşturur. Bu kutulara "bağlama kutuları" adı verilir.

SSD ayrıca, özellik çıkarma katmanlarından elde edilen özellikleri daha etkili bir şekilde kullanmak için "özellik piramidi" gibi teknikleri kullanır. Bu yaklaşım, özellikleri farklı ölçeklerdeki konumlarda birleştirerek daha detaylı bir nesne tespiti yapılmasını sağlar.

Kısaca SSD, hızlı ve etkili bir şekilde nesne tespiti yapabilen ve aynı anda farklı ölçeklerdeki nesneleri algılayabilen bir derin öğrenme modelidir. SSD'nin yüksek performansı, özellikle gerçek zamanlı uygulamalar için idealdir ve otomotiv sektörü, güvenlik sistemleri, nesne takibi gibi birçok alanda kullanılmaktadır.

SSD, adında da belirtildiği gibi, tek bir adımda nesne tespiti ve sınıflandırma işlemlerini gerçekleştirir. Bu özelliği, diğer geleneksel nesne tespiti modellerine göre daha hızlı çalışmasını sağlar. Ayrıca, aynı anda birden çok sınıfın sınıflandırılmasını destekler ve farklı ölçeklerdeki nesneleri algılayabilir.

SSD, farklı ölçeklerdeki nesneleri algılayabilmek için ölçekli özellik haritalarını kullanır. Bu özellik haritaları, farklı konvolüsyon katmanlarından gelen bilgileri kullanarak nesnelerin farklı boyutlardaki görsel özelliklerini temsil eder.

SSD, her bir ölçekte bir dizi öneri kutusu oluşturur. Bu öneri kutuları, belirli bir konumda farklı boyutlarda ve en-boy oranlarında bulunan nesneleri temsil eder. Her bir öneri kutusu, nesne sınıflandırması ve konum belirleme işlemleri için kullanılır.

SSD, her bir öneri kutusu için çeşitli boyut ve en-boy oranları kullanarak geniş bir nesne çeşitliliğini kapsamayı amaçlar. Bu sayede, farklı şekil ve boyutlardaki nesnelerin daha etkin bir şekilde algılanması sağlanır.

kıyasla daha iyi performans sergilediğini ve daha hızlı eğitildiğini ortaya koymuştur. Bu nedenle, ResNet, derin öğrenme alanında önemli bir dönüm noktası olarak kabul edilir.

ResNet'in temel prensibi, 'artıklı öğrenme' adı verilen bir yaklaşıma dayanmaktadır. Bu yaklaşım, ağır katmanlarının çıkışı hedef çıkışa değil, hedef çıkışla katmanın girişi arasındaki farka odaklanarak öğrenmeye çalışır.

Artıklı öğrenme, her katmanın, önceki katmanın çıkışına eklenen bir 'artık' haritasını öğrenmesini sağlar. Bu matematiksel olarak, bir katmanın çıkışı $H(x)$ ve girişi olan x arasındaki farkı $F(x)=H(x)-x$ şeklinde ifade eder. Bu fark, katmanın öğrenmesi gereken gerçek işlevi temsil eder.

ResNet, bu artık haritalarını odaklanarak daha derin ağların eğitimini kolaylaştırır. Artık haritalarının öğrenilmesi, geleneksel olarak zorlanan veya kaybolan gradyanları daha etkili bir şekilde yönetir. Bu, daha derin ve etkili modellerin eğitimini mümkün kılar.

ResNet'in mimarisi genellikle 'artıklı bloklar' adı verilen yapılarla oluşturulur. Her bir artıklı blok, bir veya daha fazla evrişim katmanını içerir ve ardından 'shortcut connection' veya 'skip connection' denilen doğrudan bir bağlantıya sahiptir. Bu bağlantı, artık haritaların eklenmesi gereken noktayı belirtir.

2.3.17. Xception Derin Öğrenme Modeli ve Çalışma Prensibi

Xception, Google tarafından 2016 yılında geliştirilen önemli bir derin öğrenme modelidir. "Extreme Inception" (aşırı başlatma) terimiyle de bilinir ve derin sinir ağları için özel bir mimari olan "Depthwise Separable Convolution" (derinlik bazlı ayrılabilir evrişim) yöntemini kullanır. Bu yapı, modelin parametre sayısını azaltarak hesaplama verimliliğini artırır (Abunasser, vd., 2022).

Xception'ın temel fikri, geleneksel evrişim katmanlarını "derinlik bazlı ayrılabilir evrişim" adı verilen iki aşamalı bir süreçle değiştirmektir. Bu süreçte, her bir kanal için ayrılabilir evrişim önce yapılır ve ardından her bir kanal için 1x1 boyutunda evrişim uygulanır (Şekil 2.22). Bu, daha az parametre ve hesaplama maliyetiyle daha derin modeller elde etmenin yolunu açar.


Xception, büyük veri setleri üzerinde yüksek doğruluk sağlamıştır, özellikle de ImageNet gibi önemli veri setlerinde. Genel olarak, diğer derin öğrenme modellerine

kıyasla daha az hesaplama gücü gerektirir. Ayrıca, transfer öğrenme uygulamalarında da etkili bir şekilde kullanılmıştır.

Xception, bilgisayarlı görü ve nesne tanıma gibi alanlarda önemli bir etkiye sahiptir ve derin öğrenme modellerinin daha hafif ve daha verimli hale getirilmesinde önemli bir adımı temsil eder.

Xception'ın temel ilkesi, "derinlik bazlı ayırık evrişim" olarak adlandırılan bir evrişim operatörüne dayanır. Bu özel operatör, giriş kanallarını ve filtreleri ayrı ayrı işleyerek geleneksel evrişim yöntemlerinden farklılık gösterir.

Şekil 2.22: Xception Mimarisi



Bu yaklaşım, modelin daha hafif ve hesaplama açısından daha verimli olmasını sağlar. Daha az parametre ve hesaplama maliyeti gerektirirken, bilgi akışını daha etkili bir şekilde yönetebilir ve daha iyi özellik haritaları oluşturabilir.

Xception'ın mimarisi, "Xception Blokları" adı verilen modüllerden oluşur. Her bir blok, derinlik bazlı ayırık evrişim operatörlerini içeren bir dizi evrişim katmanını barındırır. Bu bloklar, birbiriyle bağlantılıdır ve genellikle ağın derinliği boyunca tekrarlanır.

Xception, görsel tanıma görevlerinde yüksek performans sergilerken, aynı zamanda daha hafif ve verimli bir modeldir. Bu özelliklerinden dolayı, Xception genellikle kaynak sınırlı ortamlarda veya mobil cihazlarda tercih edilir.

2.3.18. MobileNet Derin Öğrenme Modeli ve Çalışma Prensibi

MobileNet, sınırlı donanım kaynaklarına sahip mobil ve gömülü cihazlarda derin öğrenme modellerinin etkin kullanımını sağlamak için geliştirilmiş bir sinir ağı

mimarisidir. Google tarafından oluşturulan bu mimari, çeşitli versiyonlarla birlikte sunulmuştur.

MobileNet'in ana özelliği, geleneksel konvolüsyonlar yerine derin ayrık konvolüsyonlar kullanmasıdır (Mahesh, vd., 2023). Bu yöntem, hesaplama maliyetini ve parametre sayısını önemli ölçüde düşürür. Derin ayrık konvolüsyonlar iki aşamada gerçekleştirilir: İlk olarak, her kanal için ayrı ayrı derin konvolüsyonlar (depthwise convolution) yapılır. Ardından, bu çıktılar birleştirilerek noktasal konvolüsyonlar (pointwise convolution) uygulanır.

MobileNet, düşük hesaplama gücüne sahip cihazlarda yüksek performans sunacak şekilde optimize edilmiştir, bu da enerji verimliliği ve hız açısından büyük bir avantaj sağlar. Kullanıcılar, hesaplama maliyeti ve doğruluk arasında denge kurabilmek için genişlik çarpanı (width multiplier) ve çözünürlük çarpanı (resolution multiplier) gibi faktörlerle modelin karmaşıklığını ve boyutunu ayarlayabilirler.

İlk sürüm olan MobileNet V1, mobil cihazlar için etkili bir model sunarak derin ayrık konvolüsyonları tanıtmıştır. MobileNet V2 ise geri çıkıntı (inverted residual) ve doğrusal daraltma bloğu (linear bottleneck) gibi yeniliklerle gelmiştir. Bu yapı, modelin doğruluğunu artırırken hesaplama maliyetini düşük tutmayı hedeflemektedir. MobileNet V3 ise Neural Architecture Search (NAS) kullanılarak otomatik optimize edilmiştir. Bu versiyon, doğruluk ve verimlilik açısından önceki versiyonlara göre iyileştirmeler sunar ve Squeeze-and-Excitation (SE) blokları gibi yeni bileşenler içerir.

MobileNet'in kullanım alanlarına bakacak olursak, geniş veri kümeleri üzerinde eğitilerek çeşitli nesneleri sınıflandırmada kullanılabilir. Daha karmaşık görevler için, örneğin nesne algılama (object detection) gibi uygulamalarda, SSD (Single Shot MultiBox Detector) ile birlikte kullanılarak etkili nesne algılama modelleri oluşturulabilir. Ayrıca, MobileNet görüntü segmentasyonu görevlerinde de kullanılabilir; bu tür uygulamalarda, bir görüntüdeki her pikselin hangi nesneye ait olduğunu belirlemek hedeflenir.



ÜÇÜNCÜ BÖLÜM
MATERYAL VE METOT

3.1. VERİ SETİ VE ÖNERİLEN MODEL


Tez kapsamında kullandığımız veri seti kaggle üzerinden elde edilmiştir. Bu veri kümesi, Irak-Onkoloji Öğretim Hastanesi / Ulusal Kanser Hastalıkları Merkezi (IQ-OTH/NCCD) tarafından organize edilen bir akciğer kanseri veri kümesini açıklamaktadır (<https://www.kaggle.com/datasets/adityamahimkar/iqothnccd-lung-cancer-dataset>). Veri kümesi, 2019 sonbaharında belirtilen uzman hastanelerde üç ay boyunca toplanmıştır. Bu özel veri seti, farklı evrelerde teşhis edilmiş akciğer kanseri olan hastaların ve sağlıklı bireylerin bilgisayarlı tomografi (BT) taramalarını içermektedir. IQ-OTH/NCCD slaytları, bu iki merkezdeki onkologlar ve radyologlar tarafından değerlendirilmiştir. Toplamda, 110 durumu temsil eden 1190 görüntü bulunmaktadır.

Bu çalışmada akciğer kanserinin tespit edilmesi ve sınıflandırılması amacıyla 1190 görüntü içeren bir veri seti kullanılmıştır. Bu veri setinden örnek görüntüler Şekil 3.1'de gösterilmiştir. Akciğer kanserinin erken teşhisi için kullanılan verisetinde Bengin (iyi huylu tümör), Normal ve Malignant (kötü huylu) olmak üzere üç sınıf vardır. Bu sınıflara ait örnek sayıları ve dağılımları Şekil 3.2'de gösterilmiştir.


Önerilen derin öğrenme modellerine ilişkin akış bloğu Şekil 3.3'te verilmiştir. Ayrıca eğitim, valid ve test görüntülerine ilişkin sayısal değerler ve sınıflar içerisinde dağılımları Şekil 3.2'de gösterilmiştir. Çalışmada kullanılan 1190 akciğer görüntüsü filtreleme, normalize etme, görüntüyü ortak boyuta getirme gibi ön işleme adımlarından geçirilerek tüm görüntülerin ön işleme aşamaları yapılmıştır. Görüntü veri kümesinin %70 eğitim, %15'i valid ve geri kalan %15'i ise test olarak kullanılmıştır. Sınıf dengesini sağlamak amacıyla her sınıftan eşit oranda örnek sayısı eğitim, valid ve test olarak ayrılmıştır. Önerilen farklı ve derin ağ yapısına sahip derin öğrenme modelleri (DNN, CNN, ResNet, Xception, Alex Net, VGG 16) farklı değerlendirme kriterleri ile analiz edilmiştir ve her iki model için de elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur.

Veri setindeki görsellerin boyutları DNN ve CNN için 150x150 olacak şekilde ayarlanmıştır. Alex Net için 227x227, VGG 16 için 224x224 olarak belirlenmiştir. Tüm modeller için tüm sınıflara ait eğitim, test ve doğrulama verileri Tablo 3.1 ve 3.2' de gösterilmiştir.

Şekil 3.1: Akciğer Kanseri İçin Kullanılan Verilerden Görüntüler



Şekil 3.2: Akciğer Görüntülerin Sınıflar İçerisinde Dağılımları




Tablo 3.1: DNN, CNN, AlexNet, VGG16 ve MobileNet için Tüm Sınıflara Ait Eğitim, Test ve Doğrulama Verileri

Class 1 (Bengin)	120 (% 10.9389243)
Class 2 (Malignant)	561 (% 51.1394713)
Class 3 (Normal)	416 (% 37.9216044)
Train Data	767 (% 69.9179581)
Class 1 (Bengin)	84 (% 10.9517601)
Class 2 (Malignant)	392 (% 51.1082138)
Class 3 (Normal)	291 (% 37.9400261)
Validation Data	165 (% 15.041021)
Class 1 (Bengin)	18 (% 10.9090909)
Class 2 (Malignant)	84 (% 50.9090909)
Class 3 (Normal)	63 (% 38.1818182)
Test Data	165 (% 15.041021)
Class 1 (Bengin)	18 (% 10.9090909)
Class 2 (Malignant)	85 (% 51.5151515)
Class 3 (Normal)	62 (% 37.5757576)

Tablo 3.2: ResNet, Xception Modeli için Tüm Sınıflara Ait Eğitim, Test ve Doğrulama Verileri

Class 1 (Bengin)	120 (% 10.9389243)
Class 2 (Malignant)	561 (% 51.1394713)
Class 3 (Normal)	416 (% 37.9216044)
Train Data	767 (% 69.9179581)
Class 1 (Bengin)	84 (% 10.9517601)
Class 2 (Malignant)	392 (% 51.1082138)
Class 3 (Normal)	291 (% 37.9400261)
Validation Data	165 (% 15.041021)
Class 1 (Bengin)	18 (% 10.9090909)
Class 2 (Malignant)	85 (% 51.5151515)
Class 3 (Normal)	62 (% 37.5757576)
Test Data	165 (% 15.041021)
Class 1 (Bengin)	18 (% 10.9090909)
Class 2 (Malignant)	84 (% 50.9090909)
Class 3 (Normal)	63 (% 38.1818182)

Şekil 3.3: Önerilen Modellerin İş Akış Bloğu




3.2. OLUŞTURULAN MODELLER

Bu bölümde önerilen modeller tanıtılmıştır.

3.2.1. DNN

Çalışmamızda önerilen DNN ağ modeli ve kullanılan hiperparametreler Şekil 3.4'te verilmiştir. Çalışmada farklı boyuttaki akciğer BT görüntülerin hepsi 150x150 boyutundaki görüntülere çevrilmiştir ve 100 epoch için her iterasyonda en uygun hiper parametreler belirlenmiştir. Bu çalışmada epoch değeri 100 seçilmiştir ve her 100 epoch için 10 iterasyon belirlenmiştir. Modelin uygun yerde durdurulması için batch size değeri olarak 50 verilmiştir. 100 epoch döngüsü için 50 batch size ve aktivasyon fonksiyonu olarak relu ve softmax kullanılmıştır. Ayrıca çalışmada kullanılan katmanlardan sonra elde edilen tüm parametreler Tablo 3.3'de gösterilmiştir.

Şekil 3.4: Önerilen DNN Modeli



Tablo 3.3: Önerilen DNN Modeli Parametleri


Layer	Output Shape	Param #
Flatten1 (Flatten)	(None, 67500)	0
Dense1 (Dense)	(None, 128)	8640128
Norm1 (BatchNormalization)	(None, 128)	512
Dropout1 (Dropout)	(None, 128)	0
Dense2 (Dense)	(None, 32)	4128
Norm2 (BatchNormalization)	(None, 32)	128
Dropout2 (Dropout)	(None, 32)	0
Dense3 (Dense)	(None, 3)	99
Total params: 8644995 (32.98 MB)		
Trainable params: 8644675 (32.98 MB)		
Non-trainabl params: 320 (1.25 KB)		

3.2.2. CNN

Çalışmamızda önerilen CNN ağ modeli ve kullanılan hiperparametreler Şekil 3.5'te verilmiştir. Çalışmada farklı boyuttaki akciğer BT görüntülerin hepsi 150x150 boyutundaki görüntülere çevrilmiştir ve 100 epoch için her iterasyonda en uygun hiper parametreler belirlenmiştir. Konvolüsyon ve havuzlama katmanında belirlenen katmanlara softmax ve relu katmanları eklenerek filtre sayısının artırılarak eğitim ve test görüntülerindeki sınıflandırma ve hastalık tespitinin doğru belirlenmesi sağlanmaya

çalışılmıştır. Ayrıca 3 x 3'lük konvolüsyon ve 2 x 2'lik havuzlama katmanı kullanılmıştır. Ayrıca çalışmada kullanılan katmanlardan sonra elde edilen tüm parametreler Tablo 3.4'te gösterilmiştir.

Şekil 3.5: Önerilen CNN Modeli




Tablo 3.4: Önerilen CNN Modeli Parametreleri

Layer	Output Shape	Param #
Conv1 (Conv2D)	(None, 150, 150, 16)	448
MaxPool1 (MaxPooling2D)	(None, 75, 75, 16)	0
Conv2 (Conv2D)	(None, 75, 75, 32)	4640
MaxPool2 (MaxPooling2D)	(None, 37, 37, 32)	0
Dropout1 (Dropout)	(None, 37, 37, 32)	0
Conv3 (Conv2D)	(None, 37, 37, 64)	18496
MaxPool3 (MaxPooling2D)	(None, 18, 18, 64)	0
Dropout2 (Dropout)	(None, 18, 18, 64)	0
Flatten1 (Flatten)	(None, 20736)	0
Dense1 (Dense)	(None, 128)	2654336
Dense2 (Dense)	(None, 32)	4128
Total params: 2682147 (10.23 MB)		
Trainable params: 2682147 (10.23 MB)		
Non-trainabl params: 0 (0.00 Byte)		

3.2.3. ResNET

Çalışmamızda önerilen ResNet ağ modeli ve kullanılan hiperparametreler Şekil 3.6'da verilmiştir. Çalışmada farklı boyuttaki akciğer BT görüntülerin hepsi 224x224 boyutundaki görüntülere çevrilmiştir ve 100 epoch için her iterasyonda en uygun hiper parametreler belirlenmiştir. Resnet 101 modeline iki dense katmanı eklenmiştir. İlk dense katmanı için aktivasyon fonksiyonu olarak relu katmanları eklenerek ve filtre sayısı artırılarak eğitim ve test görüntülerindeki sınıflandırma ve hastalık tespitinin doğru belirlenmesi sağlanmaya çalışılmıştır. İkinci dense katmanı için ise aktivasyon fonksiyonu olarak softmax eklenmiştir. Ayrıca çalışmada kullanılan katmanlardan sonra elde edilen tüm parametreler Tablo 3.5'te gösterilmiştir.

Şekil 3.6: Önerilen ResNet101 Modeli




Tablo 3.5: Önerilen Resnet Modeli Parametreleri

Layer	Output Shape	Param #	Connected to
Input_3 (InputLayer)	[(None, 224, 224, 3)]	0	[]
conv1_pad (ZerroPadding2D)	(None, 230, 230, 3)	0	['input_3[0][0]']
conv1_conv (Conv2D)	(None, 112, 112, 64)	9472	['conv1_pad[0][0]']
conv1_bn (BatchNormalization)	(None, 112, 112, 64)	256	['conv1_conv[0][0]']
conv1_relu (Activation)	(None, 112, 112, 64)	0	['conv1_bn[0][0]']
pool1_pad (ZeroPadding2D)	(None, 114, 114, 64)	0	['conv1_relu[0][0]']
pool1_pool (MaxPooling2D)	(None, 56, 56, 64)	0	['pool1_pad[0][0]']
conv2_block1_1_conv (Conv2D)	(None, 56, 56, 64)	4160	['pool1_pool[0][0]']
conv2_block1_1_bn (BatchNormalization)	(None, 56,56,64)	256	['conv2_block1_1_conv[0][0]']
Total params: 42658176 (162.73 MB)			
Trainable params: 0 (0.00 MB)			
Non-trainabl params: 42658176 (162.73 Byte)			

3.2.4. Xception

Çalışmamızda önerilen Xception ağ modeli ve kullanılan hiperparametreler Şekil 3.7’de verilmiştir. Çalışmada farklı boyuttaki akciğer BT görüntülerin hepsi 299x299 boyutundaki görüntülere çevrilmiştir ve 100 epoch için her iterasyonda en uygun hiper parametreler belirlenmiştir. Xception modeline ekstra olarak Dropout katmanı eklenmiştir ve rate oranı 0.3 olarak belirlenmiştir. Bu katmandan sonra dense katmanı 128 katman için aktivasyon fonksiyonu relu olarak belirlenmiştir. Ayrıca sırasıyla sonraki katmanlar için dropout ve dense katmanları eklenmiştir. Dropout katmanı için rate oranı 0.3 olarak belirlenmiştir. En son katman olarak eklenen Dense katmanı için ise aktivasyon fonksiyonu olarak softmax kullanılmıştır. Ayrıca çalışmada kullanılan katmanlardan sonra elde edilen tüm parametreler Tablo 3.6’da gösterilmiştir.

Şekil 3.7: Önerilen Xception Modeli




Tablo 3.6: Önerilen Xception Modeli Parametreleri

Layer	Output Shape	Param #
xception (Functional)	(None, 2048)	20861480
flatten (Flatten)	(None, 2048)	0
dropout (Dropout)	(None, 2048)	0
dense (Dense)	(None, 128)	262272
dropout_1 (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 3)	387
Total params: 21124139 (80.58 MB)		
Trainable params: 262659 (1.00 MB)		
Non-trainabl params: 20861480 (79.58 MB)		

3.2.5. AlexNET

Çalışmamızda önerilen AlexNet ağ modeli ve kullanılan hiperparametreler Şekil 3.8’de verilmiştir. Çalışmada farklı boyuttaki akciğer BT görüntülerin hepsi 227x227 boyutundaki görüntülere çevrilmiştir ve 100 epoch için her iterasyonda en uygun hiper parametreler belirlenmiştir. Konvolüsyon ve havuzlama katmanında belirlenen katmanlara softmax ve relu katmanları eklenerek ve filtre sayısı artırılarak eğitim ve test görüntülerindeki sınıflandırma ve hastalık tespitinin doğru belirlenmesi sağlanmaya çalışılmıştır. Ayrıca 5 x 5’lük ve 3x3’lük konvolüsyon ve 3 x 3’lük havuzlama katmanı kullanılmıştır. Alex Net modeli için çalışmada kullanılan katmanlar Tablo 3.7’de gösterilmiştir. Ayrıca çalışmada kullanılan katmanlardan sonra elde edilen tüm parametreler Tablo 3.8’de gösterilmiştir.

Şekil 3.8: Önerilen AlexNet Modeli



Tablo 3.7: Önerilen Alexnet Modeli Kullanılan Katmanlar

Input	-
Conv2D	filters=96, kernel_size=(11,11), strides=(4,4), activation=relu
BatchNormalization	
MaxPool2D	pool_size=(3,3), strider= (2,2)
Conv2D	filters=256, kernel_size=(5,5), strides=(1,1), activation=relu, padding=same
BatchNormalization	
MaxPool2D	pool_size=(3,3), strider= (2,2)
Conv2D	filters=384, kernel_size=(3,3), strides=(1,1), activation=relu, padding=same
BatchNormalization	
Conv2D	filters=384, kernel_size=(3,3), strides=(1,1), activation=relu, padding=same
BatchNormalization	
Conv2D	filters=256, kernel_size=(3,3), strides=(1,1), activation=relu, padding=same
BatchNormalization	
MaxPool2D	pool_size=(3,3), strider= (2,2)
Flatten	
Dense	4096, activation=relu
Dropout	0,5
Dense	nClass, activation=softmax

Tablo 3.8: Önerilen Alexnet Modeli Parametreleri


Layer	Output Shape	Param #
conv2d_10 (Conv2D)	(None, 55,55,96)	34944
batch_normalization_10 (Batchnormalization)	(None, 55,55,96)	384
max_pooling2d_6 (maxPooling2D)	(None, 27,27,96)	0
conv2d_11 (Conv2D)	(None, 27,27,256)	614656
batch_normalization_11 (Batchnormalization)	(None, 27,27,256)	1024
max_pooling2d_7 (maxPooling2D)	(None, 13,13,256)	0
conv2d_12 (Conv2D)	(None, 13,13,384)	885120
batch_normalization_12 (Batchnormalization)	(None, 13,13,384)	1536
Total params: 41517827 (158.38 MB)		
Trainable params: 41515075 (158.37 MB)		
Non-trainabl params: 2752 (10.75 KB)		

3.2.6. VGG16

Çalışmamızda önerilen VGG16 ağ modeli ve kullanılan hiper parametreler Şekil 3.9'da verilmiştir. Çalışmada farklı boyuttaki akciğer BT görüntülerin hepsi 224x224 boyutundaki görüntülere çevrilmiştir ve 100 epoch için her iterasyonda en uygun hiper parametreler belirlenmiştir. VGG16 modeline iki dense katmanı eklenmiştir. İlk dense

100 katman için aktivasyon fonksiyonu olarak relu katmanları eklenerek ve filtre sayısı artırılarak eğitim ve test görüntülerindeki sınıflandırma ve hastalık tespitinin doğru belirlenmesi sağlanmaya çalışılmıştır. İkinci dense katmanı için ise aktivasyon fonksiyonu olarak softmax eklenmiştir. Ayrıca çalışmada kullanılan katmanlardan sonra elde edilen tüm parametreler Tablo 3.9’da gösterilmiştir.

Şekil 3.9: Önerilen VGG 16 Modeli



Tablo 3.9: Önerilen VGG 16 Modeli Parametreleri


Layer	Output Shape	Param #
input_1 (Inputlayer)	(None, 224,224,3)	0
block1_conv1 (Conv2D)	(None, 224,224,64)	1792
block1_conv2 (Conv2D)	(None, 224,224,64)	36928
block1_pool (MaxPooling2D)	(None, 112,112,64)	0
block2_conv1 (Conv2D)	(None, 112,112,128)	73856
block2_conv2 (Conv2D)	(None, 112,112,128)	147584
block2_pool (MaxPooling2D)	(None, 56,56,128)	0
block3_conv1 (conv2D)	(None, 56,56,256)	295168
block3_conv2 (conv2D)	(None, 56,56,256)	590080
block3_conv3 (conv2D)	(None, 56,56,256)	590080
block3_pool (Maxpooling2D)	(None, 28,28,256)	0
Total params: 14766291 (56.33 MB)		
Trainable params: 51603 (201.57 KB)		
Non-trainabl params: 14714688 (56.13 MB)		

3.2.7. MobileNetV2

Çalışmamızda önerilen MobileNetV2 ağ modeli ve kullanılan hiper parametreler Şekil 3.10’da verilmiştir. Çalışmada farklı boyuttaki akciğer BT görüntülerin hepsi 224x224 boyutundaki görüntülere çevrilmiştir ve 100 epoch için her iterasyonda en uygun hiper parametreler belirlenmiştir. MobileNet modeline bir flatten katmanı ve iki dense katmanı eklenmiştir. İlk aşamada flatten katmanı eklenmiştir. İkinci aşamada ise 2 dense katmanı kullanılmıştır. İlk dense 128 katman için aktivasyon fonksiyonu olarak

relu katmanları eklenerek ve filtre sayısı artırılarak eğitim ve test görüntülerindeki sınıflandırma ve hastalık tespitinin doğru belirlenmesi sağlanmaya çalışılmıştır. İkinci dense katmanı için ise aktivasyon fonksiyonu olarak softmax eklenmiştir. Ayrıca çalışmada kullanılan katmanlardan sonra elde edilen tüm parametreler Tablo 3.10'da gösterilmiştir.

Şekil 3.10: Önerilen MobileNetV2 Modeli



Tablo 3.10: Önerilen Mobilenet Modeli Parametreleri

Layer	Output Shape	Param #	Connected to
İnput_2 (InputLayer)	[(None, 224, 224, 3)]	0	[]
conv1 (Conv2D)	(None, 112, 112, 32)	864 ['input_2[0][0]']	
bn_Conv1 (BatchNormalization)	(None, 112, 112, 32)	128 ['Conv1[0][0]']	
conv1_relu (ReLU)	(None, 112, 112, 32)	0 ['bn_Conv1[0][0]']	
expanded_conv_depthwise (DepthwiseConv2D)	(None, 112, 112, 32)	288 ['Conv1_relu[0][0]']	
expanded_conv_depthwise_BN (BatchNormalization)	(None, 112, 112, 32)	128 ['expanded_conv_depthwise [0][0]']	
expanded_conv_depthwise_relu (ReLU)	(None, 112, 112, 32)	0 ['expanded_conv_depthwise_BN[0][0]']	
expanded_conv_project (Conv2D)	(None, 112, 112, 16)	512 ['expanded_conv_depthwise_relu [0][0]']	
Total params: 42658176 (162.73 MB)			
Trainable params: 0 (0.00 MB)			
Non-trainabl params: 42658176 (162.73 Byte)			

3.3. DEĞERLENDİRME METRİKLERİ

Bu tez kapsamında gerçekleştirdiğimiz çalışmada, performans değerlendirmesi için doğruluk (accuracy), geri çağırma (recall), özgüllük (specificity), kesinlik (precision) ve F1 skoru gibi ölçüm metrikleri kullanılmıştır.

Makine öğreniminde yaygın olarak kullanılan karışıklık matrisi, sınıflandırma sisteminin elde ettiği gerçek ve tahmini sınıflar arasındaki ilişkiyi göstermektedir. Karışıklık matrisi, iki boyutlu bir yapıya sahiptir; satırlar gerçek sınıf örneklerini, sütunlar ise tahmin edilen sınıf durumlarını temsil eder. Bu matris, sınıflandırma sisteminin performansını anlamak ve analiz etmek için değerli bir bilgi kaynağıdır.

Doğru (Gerçek) Pozitifler (True Positives - TP): Pozitif sınıfı doğru olarak tanımlanan örneklerin miktarıdır. Sınıflandırıcının pozitif sınıfı isabetli bir şekilde belirlediği durumları ifade eder.

Doğru (Gerçek) Negatifler (True Negatives - TN): Negatif sınıfı doğru olarak tanımlanan örneklerin miktarıdır. Sınıflandırıcının negatif sınıfı doğru şekilde belirlediği durumları ifade eder.

Yanlış Pozitifler (False Positives - FP): Hatalı pozitif sınıflandırılan örneklerin sayısıdır. Sınıflandırıcının negatif sınıfı yanlış bir şekilde pozitif olarak tanımladığı durumları ifade eder.

Yanlış Negatifler (False Negatives - FN): Pozitif sınıfı yanlış bir şekilde negatif olarak sınıflandırılan örneklerin sayısını ifade eder.

Toplam Örnekler: Bütün örneklerin toplam sayısını belirtir. Bu, Doğru Pozitifler (TP), Doğru Negatifler (TN), Yanlış Pozitifler (FP) ve Yanlış Negatiflerin (FN) toplamıdır.

Accuracy (Doğruluk): Bu ölçüt, bir sınıflandırma modelinin tüm veri kümesi üzerinde doğru tahmin ettiği örneklerin oranını belirten bir performans göstergesidir. Modelin genel başarımını değerlendirir ve doğru sınıflandırılan örneklerin toplam örnekler içindeki yüzdesini belirtir. Doğruluk, aşağıda bulunan formül ile hesaplanır:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Precision (Kesinlik): Bu performans ölçütü, modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu belirler. Kesinlik, yanlış pozitifleri

azaltmayı amaçlar. Yüksek bir kesinlik değeri, modelin pozitif tahminlerinin doğruluğunu ve yanlış pozitif sayısının düşük olduğunu gösterir. Kesinlik, aşağıdaki formül kullanılarak hesaplanır:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

Recall (Hassasiyet): Bu ölçüm, sınıflandırma modelinin pozitif örnekleri ne kadar başarıyla tespit edebildiğini gösterir. Yüksek bir duyarlılık değeri, modelin pozitif örnekleri kaçırma oranının düşük olduğunu ve bu nedenle performansının yüksek olduğunu ifade eder. Duyarlılık, aşağıdaki formül kullanılarak hesaplanır:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3)$$

F1 Score: Bu ölçüt, bir sınıflandırma modelinin performansını değerlendiren bir metriktir. Kesinlik ve duyarlılığın harmonik ortalaması olarak hesaplanır. Dengeli bir performans göstergesi olup, modelin genel olarak ne kadar iyi çalıştığını değerlendirmek için kullanılır. F1 Skoru, aşağıdaki formül ile hesaplanır:

$$\text{F1 Score} = \frac{TP}{TP + \frac{1}{2}(FP+FN)} \quad (4)$$



DÖRDÜNCÜ BÖLÜM
BULGULAR VE DENEYSEL SONUÇLAR

4.1. DENEYSEL ÇALIŞMA

Bu bölümde akciğer BT görüntülerinde tümörlü verilerin tespitine ilişkin geliştirilen tüm derin öğrenme modellerinin analizleri ve sonuçları detaylı olarak verilmiştir.


4.1.1. DNN Sonuçları

Çalışmada kullanılan veri seti için epoch değerlerine göre kategorik çapraz entropi (categorical cross entropy) hata değerlerinin değişimi Şekil 4.1’de verilmiştir. Epoch değerlerine göre hata oranlarının belirli bir epoch değerinden sonra en düşük seviyelere ulaştığı gözlemlenmiştir. Öğrenme katsayısı 0.001, batch boyutu 50 ve "adam" optimizasyon algoritması olarak tercih edilmiştir. Değerlendirme kriteri olarak doğruluk metriği kullanılmıştır. Önerilen DNN derin öğrenme modelinin sınıflandırma başarısı Tablo 4.1’de gösterilmiştir.

Tablo 4.1: Önerilen DNN Derin Öğrenme Modelinin Sınıflandırma Başarısı (%)


Veri / Kullanılan Yöntem (%)	Eğitim	Doğrulama	Test
DNN	99.73	99.39	98.18

Şekil 4.1: Önerilen DNN İçin Cross Entropy Loss




Şekil 4.2’de verilen sınıflandırma doğruluğu grafiğinde ağırlıklar güncellenerek en iyi öğrenme gerçekleştirilmektedir. Eğitim ve valid için sınıflandırma doğruluğu analiz edildiğinde eğitim ve valid doğruluğunda en iyi öğrenmenin epoch değerleri verilmiştir.

Şekil 4.2: Önerilen DNN İçin Classification Accuracy




Şekil 4.3’de önerilen DNN modelinde tüm veri için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.3: Tüm Veri İçin Karmaşıklık Matrisi




Şekil 4.4’te önerilen DNN modelinde eğitim verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.4: Eğitim Verisi İçin Karmaşıklık Matrisi




Şekil 4.5'te önerilen DNN modelinde valid için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.5: Valid Verisi İçin Karmaşıklık Matrisi



Şekil 4.6'da önerilen DNN modelinde test verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.6: Test Verisi İçin Karmaşıklık Matrisi




Tablo 4.1 Tablo 4.2’de önerilen DNN modelinin tüm, eğitim ve valid verileri için akciğer kanserinin (benign, normal, malignant) tanı ve teşhisinin bazı değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir.

Tablo 4.2: Eğitim ve Valid İçin Sınıflandırma Raporu

For All Data	Precision	Recall	F1-Score	Support
Benign	1.0000	0.9667	0.9831	120
Malignant	1.0000	0.9964	0.9982	561
Normal	0.9858	1.0000	0.9928	416
Accuracy			0.9945	1097
Macro Avg	0.9983	0.9877	0.9914	1097
Weighted Avg	0.9946	0.9945	0.9945	1097
For Train Data	Precision	Recall	F1-Score	Support
Benign	1.0000	0.9762	0.9880	84
Malignant	1.0000	1.0000	1.0000	392
Normal	0.9932	1.0000	0.9966	291
Accuracy			0.9974	767
Macro Avg	0.9977	0.9921	0.9948	767
Weighted Avg	0.9974	0.9974	0.9974	767
For Valid Data	Precision	Recall	F1-Score	Support
Accuracy			0.9818	165
Macro Avg	0.9846	0.9736	0.9786	165
Weighted Avg	0.9827	0.9818	0.9819	165


Şekil 4.7’de önerilen DNN modelinin tüm veri için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.7: Tüm Veri İçin ROC Analizi




Şekil 4.8’de önerilen DNN modelinin eğitim verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.8: Eğitim Verisi İçin ROC Analizi




Şekil 4.9’da önerilen DNN modelinin valid için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.9: Valid İçin ROC Analizi



Şekil 4.10’da önerilen DNN modelinin test verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.10: Test Verisi İçin ROC Analizi



4.1.2. CNN Sonuçları


Çalışmada kullanılan veri seti için epoch değerlerine göre kategorik çapraz entropi (categorical cross entropy) hata değerlerinin değişimi Şekil 4.11’de verilmiştir. Epoch değerlerine göre hata oranlarının belirli bir epoch değerinden sonra en düşük seviyelere ulaştığı gözlemlenmiştir. Öğrenme katsayısı 0.001, batch boyutu 50 ve "adam" optimizasyon algoritması olarak tercih edilmiştir. Değerlendirme kriteri olarak doğruluk

metriği kullanılmıştır. Önerilen CNN derin öğrenme modelinin sınıflandırma başarısı Tablo 4.3'te gösterilmiştir.

Tablo 4.3: Önerilen CNN Derin Öğrenme Modelinin Sınıflandırma Başarısı (%)


Veri / Kullanılan Yöntem (%)	Eğitim	Doğrulama	Test
CNN	99.86	98.78	98.18

Şekil 4.11: Önerilen CNN için Cross Entropy Loss




Şekil 4.12'de önerilen CNN modeli için verilen sınıflandırma doğruluğu grafiğinde ağırlıklar güncellenerek en iyi öğrenme gerçekleştirilmiştir. Eğitim ve valid için sınıflandırma doğruluğu analiz edildiğinde eğitim ve valid doğruluğunda en iyi öğrenmenin epoch değerleri verilmiştir.

Şekil 4.12: Önerilen CNN İçin Classification Accuracy




Şekil 4.13'te önerilen CNN modelinde tüm veri için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.13: Tüm Veri İçin Karmaşıklık Matrisi




Şekil 4.14'te önerilen CNN modelinde eğitim verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.14: Eğitim Verisi İçin Karmaşıklık Matrisi




Şekil 4.15'te önerilen CNN modelinde valid için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.15: Valid İçin Karmaşıklık Matrisi



Şekil 4.16’da önerilen CNN modelinde test verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.16: Test Verisi İçin Karmaşıklık Matrisi




Tablo 4.4’te önerilen CNN modelinin tüm, eğitim ve valid verileri için akciğer kanserinin (bengin, normal, malignant) tanı ve teşhisinin bazı değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir.

Tablo 4.4: Eğitim ve Valid İçin Sınıflandırma Raporu


For All Data	Precision	Recall	F1-Score	Support
Bengin	0.9835	0.9917	0.9876	120
Malignant	0.9947	1.0000	0.9973	561
Normal	0.9976	0.9880	0.9928	416
Accuracy			0.9945	1097
Macro Avg	0.9919	0.9932	0.9925	1097
Weighted Avg	0.9946	0.9945	0.9945	1097
For Train Data	Precision	Recall	F1-Score	Support
Bengin	0.9882	1.0000	0.9941	84
Malignant	1.0000	1.0000	1.0000	392
Normal	1.0000	0.9966	0.9983	291
Accuracy			0.9987	767
Macro Avg	0.9961	0.9989	0.9975	767
Weighted Avg	0.9987	0.9987	0.9987	767
For Valid Data	Precision	Recall	F1-Score	Support
Accuracy			0.9818	165
Macro Avg	0.9748	0.9839	0.9789	165
Weighted Avg	0.9824	0.9818	0.9817	165

Şekil 4.17’de önerilen CNN modelinin tüm veri için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.17: Tüm Veri İçin ROC Analizi


Şekil 4.18’de önerilen CNN modelinin eğitim verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.18: Eğitim Verisi İçin ROC Analizi




Şekil 4.19’da önerilen CNN modelinin valid için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.19: Valid İçin ROC Analizi



Şekil 4.20’de önerilen CNN modelinin test verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.20: Test Verisi İçin ROC Analizi


4.1.3. ResNET101 Sonuçları

Çalışmada kullanılan veri seti için epoch değerlerine göre kategorik çapraz entropi (categorical cross entropy) hata değerlerinin değişimi Şekil 4.21’de verilmiştir. Epoch değerlerine göre hata oranlarının belirli bir epoch değerinden sonra en düşük seviyelere ulaştığı gözlemlenmiştir. Öğrenme katsayısı 0.001, batch boyutu 50 ve "adamax" optimizasyon algoritması olarak tercih edilmiştir. Değerlendirme kriteri olarak doğruluk metriği kullanılmıştır. Önerilen ResNET101 derin öğrenme modelinin sınıflandırma başarısı Tablo 4.5’te gösterilmiştir.

Tablo 4.5: Önerilen Resnet101 Derin Öğrenme Modelinin Sınıflandırma Başarısı (%)


Veri / Kullanılan Yöntem (%)	Eğitim	Doğrulama	Test
ResNET101	97.39	95.75	95.15

Şekil 4.21: Önerilen Resnet101 İçin Cross Entropy Loss




Şekil 4.22’de verilen sınıflandırma doğruluğu grafiğinde ağırlıklar güncellenerek en iyi öğrenme gerçekleştirilmektedir. Eğitim ve valid için sınıflandırma doğruluğu analiz edildiğinde eğitim ve valid doğruluğunda en iyi öğrenmenin epoch değerleri verilmiştir.

Şekil 4.22: Önerilen Resnet101 İçin Classification Accuracy




Şekil 4.23’te önerilen Resnet101 modelinde tüm veri için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.23: Tüm Veri İçin Karmaşıklık Matrisi




Şekil 4.24'te önerilen Resnet101 modelinde eğitim verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.24: Eğitim Verisi İçin Karmaşıklık Matrisi




Şekil 4.25'te önerilen Resnet101 modelinde valid için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.25: Valid Verisi İçin Karmaşıklık Matrisi



Şekil 4.26’da önerilen Resnet101 modelinde test verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.26: Test Verisi İçin Karmaşıklık Matrisi




Tablo 4.6’da önerilen Resnet101 modelinin tüm, eğitim ve valid verileri için akciğer kanserinin (benign, normal, malignant) tanı ve teşhisinin bazı değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir.

Tablo 4.6: Eğitim ve Valid İçin Sınıflandırma Raporu


For All Data	Precision	Recall	F1-Score	Support
Bengin	1.0000	0.9667	0.9831	120
Malignant	1.0000	0.9964	0.9982	561
Normal	0.9858	1.0000	0.9928	416
Accuracy			0.9945	1097
Macro Avg	0.9953	0.9977	0.9914	1097
Weighted Avg	0.9946	0.9945	0.9945	1097
For Train Data	Precision	Recall	F1-Score	Support
Bengin	1.0000	0.9762	0.9880	84
Malignant	1.0000	1.0000	1.0000	392
Normal	0.9932	1.0000	0.9966	291
Accuracy			0.9974	767
Macro Avg	0.9977	0.9921	0.9948	767
Weighted Avg	0.9974	0.9974	0.9974	767
For Valid Data	Precision	Recall	F1-Score	Support
Accuracy			0.9818	165
Macro Avg	0.9746	0.9736	0.9786	165
Weighted Avg	0.9827	0.9818	0.9819	165

Şekil 4.27’de önerilen Resnet101 modelinin tüm veri için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.27: Tüm Veri İçin ROC Analizi


Şekil 4.28’de önerilen Resnet101 modelinin eğitim verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.28: Eğitim Verisi İçin ROC Analizi




Şekil 4.29'da önerilen Resnet101 modelinin valid için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.29: Valid İçin ROC Analizi



Şekil 4.30'da önerilen Resnet101 modelinin test verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.30: Test Verisi İçin ROC Analizi


4.1.4. Xception Sonuçları

Çalışmada kullanılan veri seti için epoch değerlerine göre kategorik çapraz entropi (categorical cross entropy) hata değerlerinin değişimi Şekil 4.31’de verilmiştir. Epoch değerlerine göre hata oranlarının belirli bir epoch değerinden sonra en düşük seviyelere ulaştığı gözlemlenmiştir. Öğrenme katsayısı 0.001, batch boyutu 50 ve "adam" optimizasyon algoritması olarak tercih edilmiştir. Değerlendirme kriteri olarak doğruluk metriği kullanılmıştır. Önerilen Xception derin öğrenme modelinin sınıflandırma başarısı Tablo 4.7’de gösterilmiştir.

Tablo 4.7: Önerilen Xception Derin Öğrenme Modelinin Sınıflandırma Başarısı (%)


Veri / Kullanılan Yöntem (%)	Eğitim	Doğrulama	Test
Xception	95.04	97.57	89.09

Şekil 4.31: Önerilen Xception İçin Cross Entropy Loss




Şekil 4.32’de önerilen Xception modeli için verilen sınıflandırma doğruluğu grafiğinde ağırlıklar güncellenerek en iyi öğrenme gerçekleştirilmiştir. Eğitim ve valid için sınıflandırma doğruluğu analiz edildiğinde eğitim ve valid doğruluğunda en iyi öğrenmenin epoch değerleri verilmiştir.

Şekil 4.32: Önerilen Xception İçin Classification Accuracy




Şekil 4.33’te önerilen Xception modelinde tüm veri için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.33: Tüm Veri İçin Karmaşıklık Matrisi




Şekil 4.34’de önerilen Xception modelinde eğitim verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.34: Eğitim Verisi İçin Karmaşıklık Matrisi




Şekil 4.35’te önerilen Xception modelinde valid için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.35: Valid İçin Karmaşıklık Matrisi



Şekil 4.36’da önerilen Xception modelinde test verisi için en optimum hiper parametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.36: Test Verisi İçin Karmaşıklık Matrisi




Tablo 4.8’de önerilen Xception modelinin tüm, eğitim ve valid verileri için akciğer kanserinin (bengin, normal, malignant) tanı ve teşhisinin bazı değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir.

Tablo 4.8: Eğitim ve Valid İçin Sınıflandırma Raporu


For All Data	Precision	Recall	F1-Score	Support
Bengin	0.9848	0.5417	0.6989	120
Malignant	1.0000	0.9911	0.9955	561
Normal	0.8758	1.0000	0.9338	416
Accuracy			0.9453	1097
Macro Avg	0.9535	0.8443	0.8761	1097
Weighted Avg	0.9512	0.9453	0.9397	1097
For Train Data	Precision	Recall	F1-Score	Support
Bengin	1.0000	0.5714	0.7273	84
Malignant	1.0000	0.9949	0.9974	392
Normal	0.8845	1.0000	0.9387	291
Accuracy			0.9505	767
Macro Avg	0.9615	0.8554	0.8878	767
Weighted Avg	0.9562	0.9505	0.9456	767
For Valid Data	Precision	Recall	F1-Score	Support
Accuracy			0.8909	165
Macro Avg	0.8458	0.7103	0.7119	165
Weighted Avg	0.8916	0.8909	0.8660	165

Şekil 4.37: Tüm Veri İçin ROC Analizi Şekil 4.37’de önerilen Xception modelinin tüm veri için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.37: Tüm Veri İçin ROC Analizi


Şekil 4.38’de önerilen Xception modelinin eğitim verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.38: Eğitim Verisi İçin ROC Analizi




Şekil 4.39’da önerilen Xception modelinin valid için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.39: Valid İçin ROC Analizi



Şekil 4.40'ta önerilen Xception modelinin test verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.40: Test Verisi İçin ROC Analizi




4.1.5. AlexNET Sonuçları

Çalışmada kullanılan veri seti için epoch değerlerine göre kategorik çapraz entropi (categorical cross entropy) hata değerlerinin değişimi Şekil 4.41'de verilmiştir. Epoch değerlerine göre hata oranlarının belirli bir epoch değerinden sonra en düşük seviyelere ulaştığı gözlemlenmiştir. Öğrenme katsayısı 0.001, batch boyutu 50 ve "adam" optimizasyon algoritması olarak tercih edilmiştir. Değerlendirme kriteri olarak doğruluk metriği kullanılmıştır. Önerilen AlexNet derin öğrenme modelinin sınıflandırma başarısı Tablo 4.9'da gösterilmiştir.

Tablo 4.9: Önerilen Alexnet Derin Öğrenme Modelinin Sınıflandırma Başarısı (%)


Veri / Kullanılan Yöntem (%)	Eğitim	Doğrulama	Test
AlexNet	82.26	81.21	82.42

Şekil 4.41: Önerilen Alexnet İçin Cross Entropy Loss




Şekil 4.42’de önerilen AlexNet modeli için verilen sınıflandırma doğruluğu grafiğinde ağırlıklar güncellenerek en iyi öğrenme gerçekleştirilmiştir. Eğitim ve valid için sınıflandırma doğruluğu analiz edildiğinde eğitim ve valid doğruluğunda en iyi öğrenmenin epoch değerleri verilmiştir.

Şekil 4.42: Önerilen Alexnet İçin Classification Accuracy




Şekil 4.43’te önerilen AlexNet modelinde tüm veri için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.43: Tüm Veri İçin Karmaşıklık Matrisi




Şekil 4.44'te önerilen AlexNet modelinde eğitim verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.44: Eğitim Verisi İçin Karmaşıklık Matrisi




Şekil 4.45'te önerilen AlexNet modelinde valid için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.45: Valid İçin Karmaşıklık Matrisi



Şekil 4.46’da önerilen AlexNet modelinde test verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.46: Test Verisi İçin Karmaşıklık Matrisi




Tablo 4.10’da önerilen AlexNet modelinin tüm, eğitim ve valid verileri için akciğer kanserinin (benign, normal, malignant) tanı ve teşhisinin bazı değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir.

Tablo 4.10: Eğitim ve Valid İçin Sınıflandırma Raporu


For All Data	Precision	Recall	F1-Score	Support
Bengin	0.0000	0.0000	0.0000	120
Malignant	0.9283	0.9002	0.9140	561
Normal	0.7161	0.9519	0.8173	416
Accuracy			0.8213	1097
Macro Avg	0.5481	0.6174	0.5751	1097
Weighted Avg	0.7463	0.8213	0.7774	1097
For Train Data	Precision	Recall	F1-Score	Support
Bengin	0.0000	0.0000	0.0000	84
Malignant	0.9437	0.8980	0.9203	392
Normal	0.7081	0.9588	0.8146	291
Accuracy			0.8227	767
Macro Avg	0.5506	0.6189	0.5783	767
Weighted Avg	0.7510	0.8227	0.7794	767
For Valid Data	Precision	Recall	F1-Score	Support
Accuracy			0.8242	165
Macro Avg	0.5465	0.6177	0.5788	165
Weighted Avg	0.7396	0.8242	0.7781	165

Şekil 4.47’de önerilen AlexNet modelinin tüm veri için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.47: Tüm Veri İçin ROC Analizi


Şekil 4.48’de önerilen AlexNet modelinin eğitim verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.48: Eğitim Verisi İçin ROC Analizi




Şekil 4.49’da önerilen AlexNet modelinin valid için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.49: Valid İçin ROC Analizi



Şekil 4.50’de önerilen AlexNet modelinin test verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.50: Test Verisi İçin ROC Analizi




4.1.6. VGG16 Sonuçları

KÇalışmada kullanılan veri seti için epoch değerlerine göre kategorik çapraz entropi (categorical cross entropy) hata değerlerinin değişimi Şekil 4.51’de verilmiştir. Epoch değerlerine göre hata oranlarının belirli bir epoch değerinden sonra en düşük seviyelere ulaştığı gözlemlenmiştir. Öğrenme katsayısı 0.001, batch boyutu 50 ve "adam" optimizasyon algoritması olarak tercih edilmiştir. Değerlendirme kriteri olarak doğruluk metriği kullanılmıştır. Önerilen VGG16 derin öğrenme modelinin sınıflandırma başarısı Tablo 4.11’de gösterilmiştir.

Tablo 4.11: Önerilen VGG16 Derin Öğrenme Modelinin Sınıflandırma Başarısı (%)


Veri / Kullanılan Yöntem (%)	Eğitim	Doğrulama	Test
VGG16	96.34	95.15	92.12

Şekil 4.51: Önerilen VGG16 İçin Cross Entropy Loss




Şekil 4.52’de önerilen VGG16 modeli için verilen sınıflandırma doğruluğu grafiğinde ağırlıklar güncellenerek en iyi öğrenme gerçekleştirilmiştir. Eğitim ve valid için sınıflandırma doğruluğu analiz edildiğinde eğitim ve valid doğruluğunda en iyi öğrenmenin epoch değerleri verilmiştir.

Şekil 4.52: Önerilen VGG16 İçin Classification Accuracy




Şekil 4.53’te önerilen VGG16 modelinde tüm veri için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.53: Tüm Veri İçin Karmaşıklık Matrisi




Şekil 4.54'te önerilen VGG16 modelinde eğitim verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.54: Eğitim Verisi İçin Karmaşıklık Matrisi




Şekil 4.55'te önerilen VGG16 modelinde valid için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.55: Valid İçin Karmaşıklık Matrisi



Şekil 4.56'da önerilen VGG16 modelinde test verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.56: Test Verisi İçin Karmaşıklık Matrisi




Tablo 4.12'de önerilen VGG16 modelinin tüm, eğitim ve valid verileri için akciğer kanserinin (benign, normal, malignant) tanı ve teşhisinin bazı değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir.

Tablo 4.12: Eğitim ve Valid İçin Sınıflandırma Raporu


For All Data	Precision	Recall	F1-Score	Support
Bengin	0.9540	0.6917	0.8019	120
Malignant	0.9876	0.9964	0.9920	561
Normal	0.9144	0.9760	0.9442	416
Accuracy			0.9553	1097
Macro Avg	0.9520	0.8880	0.9127	1097
Weighted Avg	0.9562	0.9553	0.9531	1097
For Train Data	Precision	Recall	F1-Score	Support
Bengin	0.9688	0.7381	0.8378	84
Malignant	0.9899	0.9974	0.9936	392
Normal	0.9286	0.9828	0.9549	291
Accuracy			0.9635	767
Macro Avg	0.9624	0.9061	0.9288	767
Weighted Avg	0.9643	0.9635	0.9619	767
For Valid Data	Precision	Recall	F1-Score	Support
Accuracy			0.9212	165
Macro Avg	0.9134	0.8264	0.8552	165
Weighted Avg	0.9218	0.9212	0.9163	165

Şekil 4.57’de önerilen VGG16 modelinin tüm veri için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.57: Tüm Veri İçin ROC Analizi


Şekil 4.58’de önerilen VGG16 modelinin eğitim verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.58: Eğitim Verisi İçin ROC Analizi




Şekil 4.59’da önerilen VGG16 modelinin valid için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.59: Valid İçin ROC Analizi



Şekil 4.60’ta önerilen VGG16 modelinin test verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.60: Test Verisi İçin ROC Analizi


4.1.7. MobileNet Sonuçları

Çalışmada kullanılan veri seti için epoch değerlerine göre kategorik çapraz entropi (categorical cross entropy) hata değerlerinin değişimi Şekil 4.1’de verilmiştir. Epoch değerlerine göre hata oranlarının belirli bir epoch değerinden sonra en düşük seviyelere ulaştığı gözlemlenmiştir. Öğrenme katsayısı 0.001, batch boyutu 50 ve "adamax" optimizasyon algoritması olarak tercih edilmiştir. Değerlendirme kriteri olarak doğruluk metriği kullanılmıştır. Önerilen MobileNet derin öğrenme modelinin sınıflandırma başarısı Tablo 4.13’te gösterilmiştir.

Tablo 4.13: Önerilen Mobilenet Derin Öğrenme Modelinin Sınıflandırma Başarısı (%)


Veri / Kullanılan Yöntem (%)	Eğitim	Doğrulama	Test
MobileNet	99.86	93.93	96.36

Şekil 4.61: Önerilen Mobilenet İçin Cross Entropy Loss




Şekil 4.62’de verilen sınıflandırma doğruluğu grafiğinde ağırlıklar güncellenerek en iyi öğrenme gerçekleştirilmektedir. Eğitim ve valid için sınıflandırma doğruluğu analiz edildiğinde eğitim ve valid doğruluğunda en iyi öğrenmenin epoch değerleri verilmiştir.

Şekil 4.62: Önerilen Mobilenet İçin Classification Accuracy




Şekil 4.63’te önerilen MobileNet modelinde tüm veri için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.63: Tüm Veri İçin Karmaşıklık Matrisi




Şekil 4.64'te önerilen MobileNet modelinde eğitim verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.64: Eğitim Verisi İçin Karmaşıklık Matrisi




Şekil 4.65'te önerilen MobileNet modelinde valid için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.65: Valid Verisi İçin Karmaşıklık Matrisi



Şekil 4.66’da önerilen MobileNet modelinde test verisi için en optimum hiperparametre seçimine göre karmaşıklık matrisi verilmiştir.

Şekil 4.66: Test Verisi İçin Karmaşıklık Matrisi




Tablo 4.14’te önerilen MobileNet modelinin tüm, eğitim ve valid verileri için akciğer kanserinin (bengin, normal, malignant) tanı ve teşhisinin bazı değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir.

Tablo 4.14: Eğitim ve Valid İçin Sınıflandırma Raporu


For All Data	Precision	Recall	F1-Score	Support
Bengin	0.9646	0.9083	0.9356	120
Malignant	0.9997	1.0000	0.9973	561
Normal	0.9762	0.9856	0.9809	416
Accuracy			0.9845	1097
Macro Avg	0.9785	0.9646	0.9713	1097
Weighted Avg	0.9844	0.9845	0.9843	1097
For Train Data	Precision	Recall	F1-Score	Support
Bengin	0.9882	1.0000	0.9941	84
Malignant	1.0000	1.0000	1.0000	392
Normal	1.0000	0.9966	0.9983	291
Accuracy			0.9987	767
Macro Avg	0.9961	0.9989	0.9975	767
Weighted Avg	0.9987	0.9987	0.9987	767
For Valid Data	Precision	Recall	F1-Score	Support
Accuracy			0.9636	165
Macro Avg	0.9408	0.9283	0.9343	165
Weighted Avg	0.9630	0.9636	0.9632	165

Şekil 4.67’de önerilen MobileNet modelinin tüm veri için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.67: Tüm Veri İçin ROC Analizi


Şekil 4.68’de önerilen MobileNet modelinin eğitim verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.68: Eğitim Verisi İçin ROC Analizi




Şekil 4.69’da önerilen MobileNet modelinin valid için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.69: Valid İçin ROC Analizi



Şekil 4.70’te önerilen MobileNet modelinin test verisi için ROC grafiği gösterilmiştir. ROC eğrisi analiz edildiğinde akciğer kanserinin tespitinde oldukça başarılı olduğu gözlemlenmiştir.

Şekil 4.70: Test Verisi İçin ROC Analizi





BEŞİNCİ BÖLÜM
SONUÇ VE TARTIŞMA

5.1. SONUÇ VE TARTIŞMA

Kanser hücrelerin çeşitli sebeplerden dolayı vücutta kontrolsüz ve hızlı bir şekilde çoğalmasıyla oluşur. Vücutta farklı dokulara yayılarak hücrelerde birtakım farklılıklara ve bunun sonucunda diğer organlara yayılabilir. Kanser tüm dünyada olduğu gibi Türkiye’de de ölüm sebepleri arasında oldukça büyük bir çoğunluğu oluşturmaktadır. Bu sebeple hastalığın tedavisinde kanser taraması yaparak erken tanı ve teşhis büyük önem taşımaktadır.

Tiroid, yumurtalık, mide, kalın bağırsak, rahim ve akciğer gibi birçok farklı kanser çeşidi vardır. Bu çalışmada derin öğrenme modelleri kullanılarak en yüksek ölüm oranına sahip olan akciğer kanserinin teşhis edilmesi amaçlanmıştır. Ayrıca sağlıkçıların gerek iş yükleri gerekse manuel teşhis koyma zorluklarını aşmak amacıyla derin öğrenme tabanlı modeller önerilmiştir. Böylelikle tıbbi alanda doğru ve hızlı kararlar veren karar destek mekanizmaları oluşturularak sağlıkçıların tanı koyma noktasındaki iş yükleri hafifletilmiştir. İyi, normal ve kötü huylu tümörler çalışmamızda DNN ve CNN modeliyle tespit edilmiştir. Yapılan çalışmayla, kullanılan veri seti üzerinde uygulanan DNN yöntemi ile valid verisi üzerinde 99.39 oranında doğruluk, CNN yöntemi ise valid verisi üzerinde 98.78 oranında doğruluk saptanmıştır.


Tablo 5.1: Önerilen Tüm Derin Öğrenme Modellerinin Sınıflandırma Başarısı (%)

Veri / Kullanılan Yöntem (%)	Eğitim	Doğrulama	Test
DNN	99.73	99.39	98.18
CNN	99.86	98.78	98.18
ResNet	97.39	95.75	95.15
Xception	95.04	97.57	89.09
AlexNet	82.26	81.21	82.42
VGG16	96.34	95.15	92.12
MobileNet	99.86	93.93	96.36

Çalışmamızda DNN, CNN, ResNet, Exception, AlexNet, VGG16 ve MobileNetV2 modellerinin sonuçları eğitim ve test için ayrı ayrı alınmıştır ve karmaşıklık matrisleri ile ROC analizleri ayrıntılı analiz edilmiştir. En optimum sonucu veren hiper parametrelere göre hesaplanan DNN, CNN, ResNet, Exception, Alex Net, VGG16 ve MobileNetV2 modellerinin eğitim, valid ile test verileri için doğruluk oranları Tablo 5.1

ve Şekil 5.1’de gösterilmiştir. Sonuçlara bakıldığında önerilen tüm yöntemler akciğer kanserinin tanı ve teşhisinde başarılı sonuçlar verilmiştir.

Şekil 5.1: Önerilen Modellerin Başarısı (%)



Tablo 5.2’de aynı veriseti üzerinde (IQ-OTH/NCCD akciğer CT görüntüleri) önerdiğimiz modelle literatürde yapılan bazı çalışmaların sonuçları verilmiştir. Çalışmamız bu veriseti üzerinde oldukça başarılı sonuçlar verdiği gösterilmiştir. Başarı oranı olarak doğrulama (valid) değerleri alınmıştır.

Tablo 5.2: Önerilen Modeller İle Literatürde Yapılan Bazı Çalışmaların Sonuçları

Literatürde Yapılan Çalışma	Kullanılan Method	Başarı Oranı (%)
Al-Huseiny et.al [28]	Transfer learning with GoogLeNet	94.38
Sabzalian et.al [29]	Bidirectional Recurrent neural network	97.06
Solyman and Schwenker [30]	Ensemble learning techniques	92.80
Kareem et.al [31]	SVM	89.88
Raza et.al [32]	EfficientNet	99.10
Önerilen model	DNN	99.39
Önerilen model	CNN	98.78
Önerilen model	ResNET 101	95.75
Önerilen model	Xception	97.57
Önerilen model	AlexNet	81.21
Önerilen model	VGG16	95.15
Önerilen model	MobileNet	93.93

Yapılan çalışmada, kullanılan veri seti üzerinde uygulanan DNN, CNN, ResNET101, Xception, AlexNet, VGG16 ve MobileNet yöntemi sırasıyla %99.39, %98.78, %95.75 , %97.57, %81.21, %95.15 ve 93.93 oranında başarı saptanmıştır.

İleriki çalışmalarda daha büyük veri kümelerinde farklı hastalıklar üzerinde oluşturulan modeller test edilecektir.



KAYNAKÇA

- Abunasser, B. S., vd. (2022). Breast cancer detection and classification using deep learning Xception algorithm. *International Journal of Advanced Computer Science and Applications*, 13(7), 223-228.
- Agarwal, A. (2021, July). *Lung cancer detection and classification based on alexnet CNN* [Conference presentation]. In 2021 6th international conference on communication and electronics systems (ICCES), Coimbatre, India.
- Al Mamlook, R. E. (2020, July). *Investigation of the performance of machine learning classifiers for pneumonia detection in chest X-ray images* [Conference presentation]. In 2020 IEEE International Conference on Electro Information Technology (EIT), Chicago, IL, USA.
- Al-Huseiny, M. S., & Sajit, A. S. (2021). Transfer learning with GoogLeNet for detection of lung cancer. *Indonesian Journal of Electrical Engineering and Computer Science*, 22(2), 1078-1086.
- Alshmrani, G. M., vd. (2023). A deep learning architecture for multi-class lung diseases classification using chest X-ray (CXR) images. *Alexandria Engineering Journal*, 64, 923-935.
- Ayayna, F. (2023). Akciğer kanserinin derin öğrenme yaklaşımları kullanılarak tespit edilmesi (Yayımlanmış Yüksek Lisans Tezi). Batman Üniversitesi Lisansüstü Eğitim Enstitüsü, Batman.
- Bayram, M. (2019). Akciğer kanserinin mesleki ve çevresel nedenleri. *Güncel Göğüs Hastalıkları Serisi*, 7(2), 28-37.
- Bharati, S., vd. (2020). Hybrid deep learning for detecting lung diseases from X-ray images. *Informatics in Medicine Unlocked*, 20, 100391.
- Canayaz, M. (2021). MH-COVIDNet: Diagnosis of COVID-19 using deep neural networks and meta-heuristic-based feature selection on X-ray images. *Biomedical Signal Processing and Control*, 64, 102257.
- Chaudhary, A., & Singh, S. S. (2012, September). *Lung cancer detection on CT images by using image processing* [Conference presentation] . In 2012 International Conference on Computing Sciences, Phagwara, India.

- Das, A. K., Ghosh, vd. (2021). Automatic COVID-19 detection from X-ray images using ensemble learning with convolutional neural network. *Pattern Analysis and Applications*, 24, 1111-1124.
- De Margerie-Mellon, C., & Chassagnon, G. (2023). Artificial intelligence: A critical review of applications for lung nodule and lung cancer. *Diagnostic and Interventional Imaging*, 104(1), 11-17.
- Deepa, P., vd. (2023). An Effective Method for Lung Cancer Classification Using Convolutional Neural Network. *International Journal of Intelligent Systems and Applications in Engineering*, 11(9), 461-467.
- El Naqa, I., & Murphy, M. J. (Eds.). (2015). *What is machine learning? : Vol. 1*. Springer. https://doi.org/10.1007/978-3-319-18305-3_1.
- Ezzat, D., & Ella, H. A. (2020). GSA-DenseNet121-COVID-19: a hybrid deep learning architecture for the diagnosis of COVID-19 disease based on gravitational search optimization algorithm. arXiv preprint arXiv:2004.05084.
- Gökalp, Ö. M. (2022). *Makine öğrenmesi* (Yayımlanmış Yüksek Lisans Tezi). Gazi Üniversitesi, Gazi Bilişim Enstitüsü, Adli Bilişim Bölümü.
- Gopinath, A., vd. (2023). Computer aided model for lung cancer classification using cat optimized convolutional neural networks. *Measurement: Sensors*, 30(1), 100932-100932.
- Hasanah, S. A., vd. (2023). A deep learning review of resnet architecture for lung disease Identification in CXR Image. *Applied Sciences*, 13(24), 13111.
- He, K., vd. (2021). Synergistic learning of lung lobe segmentation and hierarchical multi-instance classification for automated severity assessment of COVID-19 in CT images. *Pattern Recognition*, 113, 107828.
- Hişam, D., & Hişam, E. (2021, October). *Deep learning models for classifying cancer and COVID-19 lung diseases* [Conference presentation]. In 2021 Innovations in Intelligent Systems and Applications Conference (ASYU), Elazig, Turkey.
- IQ-OTH/NCCD - Lung Cancer Dataset (2021, 10 Şubat). Erişim adresi: <https://www.kaggle.com/datasets/adityamahimkar/iqothnccd-lung-cancer-dataset>

- Hussain, E., vd. (2021). CoroDet: A deep learning based classification for COVID-19 detection using chest X-ray images. *Chaos, Solitons & Fractals*, 142, 110495.
- Ibrahim, D. M., vd. (2021). Deep-chest: Multi-classification deep learning model for diagnosing COVID-19, pneumonia, and lung cancer chest diseases. *Computers in biology and medicine*, 132, 104348.
- Jaiswal, A. K., vd. (2019). Identifying pneumonia in chest X-rays: A deep learning approach. *Measurement*, 145, 511-518.
- Jiang, P., vd. (2022). A Review of Yolo algorithm developments. *Procedia Computer Science*, 199, 1066-1073.
- Kandhro, I. A. (2024). Performance Evaluation of E-VGG19 Model: Enhancing Real-Time Skin Cancer Detection and Classification. *Heliyon*, 10(10), 1-10.
- Kansal, K., & Sharma, S. (2023, December). *Predictive Deep Learning: An Analysis of Inception V3, VGG16, and VGG19 Models for Breast Cancer Detection* [Conference presentation]. In International Advanced Computing Conference, Springer Nature Switzerland.
- Kareem, H. F., vd. (2021). Evaluation of SVM performance in the detection of lung cancer in marked CT scan dataset. *Indonesian Journal of Electrical Engineering and Computer Science*, 21(3), 1731-1731.
- LeCun, Y., vd. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Li, X., VD. (2020). A modified YOLOv3 detection method for vision-based water surface garbage capture robot. *International Journal of Advanced Robotic Systems*, 17(3), 1-10.
- Li, Y., vd. (2018). Research on a surface defect detection algorithm based on MobileNet-SSD. *Applied Sciences*, 8(9), 1678-1678.
- Mahesh, T. R., vd. (2023). Early predictive model for detection of plant leaf diseases using MobileNetV2 architecture. *International Journal of Intelligent Systems and Applications in Engineering*, 11(2), 46-54.
- Masood, A., vd. (2018). Computer-Assisted Decision Support System in Pulmonary Cancer detection and stage classification on CT images. *Journal of Biomedical Informatics*, 79, 117–128.

- Mothkur, R., & Veerappa, B. N. (2023). Classification Of Lung Cancer Using Lightweight Deep Neural Networks. *Procedia Computer Science*, 218, 1869-1877.
- Naseri, H., & Mehrdad, V. (2023). Novel CNN with investigation on accuracy by modifying stride, padding, kernel size and filter numbers. *Multimedia Tools and Applications*, 82(15), 23673-23691.
- Prasad, U., & Mahto, G. (2023). Lung cancer detection and classification using deep neural network based on hybrid metaheuristic algorithm. *Soft Computing*, 7 (7), 1-24.
- Provath, vd. (2023). Classification of Lung and Colon Cancer Histopathological Images Using Global Context Attention Based Convolutional Neural Network. *IEEE Access*, 11, 110164-110183.
- Raza, R., vd. (2023). Lung-EffNet: Lung cancer classification using EfficientNet from CT-scan images. *Engineering Applications of Artificial Intelligence*, 126, 106902.
- Sabzalian, M. H., vd. (2023). New bidirectional recurrent neural network optimized by improved Ebola search optimization algorithm for lung cancer diagnosis. *Biomedical Signal Processing and Control*, 84, 104965.
- Sirazitdinov, I., vd. (2019). Deep neural network ensemble for pneumonia localization from a large-scale chest x-ray database. *Computers & electrical engineering*, 78, 388-399.
- Solyman, S., & Schwenker, F. (2022, October). Lung Tumor Detection and Recognition Using Deep Convolutional Neural Networks (Eds.), *In Pan African Conference on Artificial Intelligence, Vol. 1. Springer Nature Switzerland* (pp. 79-81).
- Swain, A. K., vd. (2024). Classification of non-small cell lung cancer types using sparse deep neural network features. *Biomedical Signal Processing and Control*, 87, 105485.
- Thakur, S. K., & Choudhary, J. (2020). Lung cancer identification: a review on detection and classification. *Cancer and Metastasis Reviews*, 39, 989-998.

- Turkoglu, M. (2021). COVID-19 detection system using chest CT images and multiple kernels-extreme learning machine based on deep neural network. *Irbm*, 42(4), 207-214.
- Xu, X., vd. (2022). Crack detection and comparison study based on faster R-CNN and mask R-CNN. *Sensors*, 22(3), 1215.
- Yu, X., & Zhang, Y. D. (2021). CGNet: A graph-knowledge embedded convolutional neural network for detection of pneumonia. *Information Processing & Management*, 58(1), 102411.
- Zhou, T., vd. (2021). The ensemble deep learning model for novel COVID-19 on CT images. *Applied soft computing*, 98, 106885.

DİZİN

A

Accuracy, 75, 79, 81, 84, 87, 90, 93, 96,
99, 102, 105, 108, 111, 114, 117, 127

C

CNN, 3, 4, 5, 7, 8, 9, 10, 11, 12, 26, 27,
29, 32, 34, 35, 38, 40, 41, 42, 43, 53,
54, 55, 62, 64, 66, 67, 83, 84, 85, 86,
87, 88, 121, 122, 123, 124, 127, 128

D

DNN, 3, 4, 5, 9, 34, 35, 62, 64, 65, 66,
78, 79, 80, 81, 82, 83, 121, 122, 123

E

Eğitim, 5, 10, 11, 23, 25, 41, 42, 46, 47,
48, 50, 51, 52, 53, 55, 57, 58, 62, 64,
66, 68, 70, 73, 74, 78, 79, 80, 81, 82,
84, 85, 86, 87, 88, 89, 90, 91, 92, 93,
94, 95, 96, 97, 98, 99, 100, 101, 102,
103, 104, 105, 106, 107, 108, 109,
110, 111, 112, 113, 114, 115, 116,
117, 118, 121, 124

F

F1-Score, 75, 76, 81, 87, 92, 93, 99,
105, 111, 117

M

Matris, 5, 27, 28, 75, 79, 80, 81, 84, 85,
86, 90, 91, 92, 96, 97, 98, 102, 103,
104, 108, 109, 110, 114, 115, 116,
121

P

Precision, 75, 76, 81, 87, 92, 93, 99,
105, 111, 117

R

Recall, 75, 76, 81, 87, 92, 93, 99, 105,
111, 117

ROC, 5, 81, 82, 83, 87, 88, 89, 93, 94,
95, 99, 100, 101, 105, 106, 107, 111,
112, 113, 117, 118, 119, 121, 124, 126,
127, 128

S

Support, 81, 87, 92, 93, 99, 105, 111,
117, 126

T

Test, 5, 8, 10, 11, 18, 19, 50, 51, 62, 64,
66, 68, 70, 73, 74, 78, 80, 81, 83, 84,
86, 88, 89, 92, 94, 95, 98, 101, 104,
107, 110, 112, 113, 116, 118, 119,
121, 123

Train, 64, 66, 67, 68, 69, 72, 73, 74, 81,
87, 93, 99, 105, 111, 117

V

Valid, 5, 62, 64, 78, 80, 81, 82, 83, 84,
85, 86, 87, 88, 90, 91, 92, 93, 94, 96, 97,
98, 99, 100, 102, 103, 104, 105, 106,
108, 109, 110, 111, 112, 114, 115, 116,
117, 118, 121, 122