



**BÖBREK HASTALIKLARININ TESPİTİ İÇİN
POLY-CNN MODELİ ÖNERİSİ VE
PERFORMANSININ KARŞILAŞTIRMASI**

(Yüksek Lisans Tezi)

Kenan GÜLLE

Kütahya – 2024

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

Yüksek Lisans Tezi

**BÖBREK HASTALIKLARININ TESPİTİ İÇİN POLY-CNN
MODELİ ÖNERİSİ VE PERFORMANSININ KARŞILAŞTIRMASI**

Danışman:
Doç. Dr. Durmuş ÖZDEMİR

Hazırlayan:
Kenan GÜLLE

Kütahya – 2024

Kabul ve Onay

KÜTAHYA DUMLUPINAR ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalında, 202085151060 öğrenci numaralı, Kenan GÜLLE'nin hazırlamış olduğu "Böbrek Hastalıklarının Tespiti için Poly-CNN Modeli Önerisi ve Performansının Karşılaştırması" başlıklı yüksek lisans tez çalışması ile ilgili tez savunma sınavı jüri tarafından yapılmış ve adayın tezinin OY BİRLİĞİ ile kabul edilmesine karar verilmiştir.

24/01/2024

Tez Jürisi	İmza	
	Kabul	Ret
Doç. Dr. Durmuş ÖZDEMİR (Danışman)		
Doç. Dr. Hasan TEMURTAŞ		
Dr. Öğr. Üyesi Zafer DURAKLI		

Onay

Doç. Dr. Eray ACAR

Enstitü Müdürü

Bilimsel Etik Bildirimi

Yüksek Lisans tezi olarak hazırladığım “*Böbrek Hastalıklarının Tespiti için Poly-CNN Modeli Önerisi ve Performansının Karşılaştırması*” 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.

24/01/2024

Kenan GÜLLE

Özgeçmiş

İlk ve orta öğrenimimi İzmir'de tamamladı. Ön lisans eğitimini Celal Bayar Üniversitesi Bilgisayar Teknolojisi ve Programlama bölümünde bitirdi. Lisans eğitimini ise Kütahya Dumlupınar Üniversitesi Bilgisayar Mühendisliği bölümünde başarıyla tamamladı. Kütahya Sağlık Bilimleri Üniversitesi'nde network ve sistem yöneticisi olarak görev yapmaktadır.



ÖZET

BÖBREK HASTALIKLARININ TESPİTİ İÇİN POLY-CNN MODELİ ÖNERİSİ VE PERFORMANSININ KARŞILAŞTIRMASI

GÜLLE, Kenan

Yüksek Lisans Tezi, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Durmuş ÖZDEMİR

Ocak, 2024, 98 sayfa

Son yıllarda, özellikle gelişmiş ülkelerde hızla artan böbrek hastalıkları, insan sağlığını olumsuz etkileyen önemli sorunlardan biri haline geldi. Böbrek fonksiyonlarını değerlendirmek için kan ve idrar testlerinin yanı sıra PACS (Picture Archiving and Communication System) görüntüleme de yaygındır. Gelişen yapay zekâ teknolojileri ile tıbbi görüntü analizlerinde büyük başarı elde edilmektedir. Yapay zekâ destekli teşhisler, hekimlere ve patoloğlara potansiyel hatalardan kaçınma imkânı sunarak, yorgunluk, dikkatsizlik ve tecrübesizlik kaynaklı riskleri en aza indirmektedir. Hastalık teşhislerinde başarı oranını artıran bu yöntemler, toplum sağlığına ve erken tedaviye önemli katkılar sağlamaktadır.

Böbrek hastalıklarının teşhisinde sınıflandırma süreci büyük bir öneme sahiptir. Bu çalışma, Kaggle platformundan elde edilen veri setini kullanarak böbrek hastalıklarının sınıflandırılması üzerine odaklanmıştır. Toplamda 12.446 benzersiz veri içeren bu veri seti, 2.283'ü tümör (Tumor), 5.077'si normal, 1.377'si taş (Stone), ve 3.709'u kist (Cyst) olarak sınıflandırılmıştır. Çalışmada, veri setimizin %70'i eğitim (train), %15'i doğrulama (Validation) ve %15'i de test işlemi için ayrılmıştır. ANN (Artificial Neural Network), AlexNet, VGG16, VGG19, Klasik CNN (Convolutional Neural Networks) ve bu çalışmada önerilen Poly-CNN gibi derin öğrenme metotlarının performansları karşılaştırılarak analiz edilmiştir. Daha istikrarlı öğrenme sağlamak için klasik CNN yapısına ekstra havuzlama katmanı ve bağlantı katmanı eklenmiştir. Eklenen bu katmanlar aşırı öğrenmeye sebebiyet vermemesi için, eğitim sırasında rastgele nöronlar devre dışı bırakılmıştır. Derin öğrenme modellerinde kullanılan parametre değerleri, katman yapıları ve doğrulama verileri üzerinden elde edilen karmaşıklık matrisleri ile doğruluk ve kayıp grafikleri detaylı bir şekilde analiz edilmiştir. Mimarilerin istatistiksel analiz sonuçları değerlendirildiğinde test verileri en iyi doğruluk oranı, başarı sırasına göre şu şekildedir: Poly-CNN (%99,94), VGG19 (%99,78), ANN (%99,78), Klasik CNN (%99,57), VGG16 (%96,57) ve AlexNet (%89,44) sonuçları elde edilmiştir.

Çalışma sonuçlarının alan uzmanlarına ve hekimlere karar verme süreçlerinde değerli öneriler sunabileceği düşünülmektedir. Özellikle hastalığın teşhis süresinin kısaltılması ve ayrıca insan kaynaklı hataların en aza indirilmesi gibi avantajlar sunmaktadır.

Anahtar Kelimeler: Böbrek hastalığı, Derin öğrenme, Evrimsel sinir ağı, Yapay sinir ağları, Yapay zekâ



ABSTRACT**POLY-CNN MODEL RECOMMENDATION AND PERFORMANCE
COMPARISON FOR KIDNEY DISEASES DETECTION****GÜLLE, Kenan****Master's Thesis, Department of Computer Engineering****Supervisor: Assoc. Prof. Durmuş ÖZDEMİR****January, 2023, 99 pages**

In recent years, rapidly increasing kidney diseases, especially in developed countries, have become one of the important problems that negatively affect human health. PACS (Picture Archiving and Communication System) imaging, as well as blood and urine tests, are also common to evaluate kidney function. Great success is achieved in medical image analysis with developing artificial intelligence technologies. Artificial intelligence-supported diagnoses allow physicians and pathologists to avoid potential errors, minimizing the risks caused by fatigue, carelessness and inexperience. These methods, which increase the success rate in disease diagnosis, make significant contributions to public health and early treatment.

The classification process is of great importance in the diagnosis of kidney diseases. This study focused on the classification of kidney diseases using the data set obtained from the Kaggle platform. This dataset contains a total of 12,446 unique data, 2,283 of which are classified as tumor, 5,077 as normal, 1,377 as stone, and 3,709 as cyst. In the study, 70% of our data set is reserved for training, 15% for validation and 15% for testing. The performances of deep learning methods such as ANN (Artificial Neural Network), AlexNet, VGG16, VGG19, Classic CNN (Convolutional Neural Networks) and Poly-CNN proposed in this study were compared and analyzed. Extra pooling layer and connection layer have been added to the classical CNN structure to provide more stable learning. To prevent these added layers from causing excessive learning, random neurons were disabled during training. The complexity matrices and accuracy and loss graphs obtained from the parameter values, layer structures and validation data used in deep learning models were analyzed in detail. When the statistical analysis results of the architectures are evaluated, the best accuracy rate of the test data is as follows, in order of success: Poly-CNN (99.94%), VGG19 (99.78%), ANN (99.78%), Classic CNN (99%). 57), VGG16 (96.57%) and AlexNet (89.44%) results were obtained. It is thought that the study results can provide valuable suggestions to field experts and physicians in their

decision-making processes. It offers advantages such as shortening the diagnosis time of the disease and minimizing human errors.

Keywords: Artificial intelligence, Artificial neural networks, Convolutional neural network, Deep learning, Kidney disease,



ÖNSÖZ

Akademik yolculuğum boyunca bana rehberlik eden, motivasyon sağlayan ve yardımlarını esirgemeyen kıymetli danışman hocam Doç. Dr. Durmuş ÖZDEMİR'e ve çalışmamda beni bilgi birikimi ile destekleyen Doç. Dr. Hasan TEMURTAŞ hocama en içten teşekkürlerimi sunmak isterim. Bu değerli hocalarımla çalışmak benim için büyük bir onurdu ve kendilerine olan teşekkür borcumu ifade etmek isterim.

Ayrıca, tez çalışma sürecimde beni sabırla destekleyen, her zaman yanımda olan ve motivasyonumu canlı tutan eşim Seval GÜLLE'ye ve sevgili çocuklarım Yusuf ve Zeynep'e en içten sevgilerimi sunarım.

24/01/2024

Kenan GÜLLE

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET.....	v
ABSTRACT	vii
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ.....	xiv
KISALTMALAR.....	xvi
GİRİŞ	2

BİRİNCİ BÖLÜM

LİTERATÜR TARAMASI

1.1. LİTERATÜR TARAMASI.....	4
------------------------------	---

İKİNCİ BÖLÜM

GENEL BİLGİLER

2.1. BİLGİSAYARLI GÖRÜ	9
2.2. BÖBREK HASTALIKLARI.....	10
2.2.1. Böbrek Taşı	11
2.2.2. Böbrek Tümörü	12
2.2.3. Böbrek Kisti	14
2.3. BÖBREK HASTALIKLARI TANI VE TEDAVİ YÖNTEMLERİ	15
2.3.1. Tam İdrar Tahlili.....	15
2.3.2. Böbrek Fonksiyon Testleri	16
2.3.3. Manyetik Rezonans (MR), Ultrason ve Bilgisayarlı Tomografi.....	17
2.3.4. Böbrek Biyopsisi.....	17
2.4. YAPAY ZEKÂ ÖĞRENME YÖNTEMLERİ.....	18
2.4.1. Makine Öğrenme.....	18
2.4.1.1. Denetimli Öğrenme.....	19
2.4.1.2. Denetimsiz Öğrenme.....	19
2.4.2. Derin Öğrenme	20
2.4.3. Derin Öğrenme Yapıları.....	22
2.4.3.1. Evrişimsel Sinir Ağları.....	22
2.4.3.2. Sınırlı Boltzmann Makineleri.....	23
2.4.3.3. Tekrarlayan Sinir Ağları	23
2.4.3.4. Derin İnanç Ağları	24
2.4.3.5. Derin Oto Kodlayıcılar.....	24
2.4.3.6. Destek Vektör Makineleri.....	24

ÜÇÜNCÜ BÖLÜM

MATERYAL VE METOT

3.1. VERİ SETİ.....	26
3.2. GELİŞTİRME ORTAMI VE KULLANILAN PLATFORM	28
3.3. KULLANILAN MODELLERDE YAPILAN İŞLEMLER VE YÖNTEMLER	29
3.3.1. Yapay Sinir Ağları (Artificial Neural Network- ANN).....	34
3.3.2. Evrişimsel Sinir Ağları (Convolutional Neural Network – Classic CNN) ...	36
3.3.3. Derin Evrişimli Sinir Ağları (ALEXNET).....	37
3.3.4. VGG16	39
3.3.5. VGG19	41
3.4. ÖNERİLEN POLY-CNN MODELİ	43

DÖRDÜNCÜ BÖLÜM

BULGULAR VE DENEYSEL SONUÇLAR

4.1. BÖBREK HASTALIĞI VERİLERİNİN DEĞERLENDİRİLMESİ.....	47
4.1.1. Değerlendirme Metrikleri	47
4.1.2. ANN	49
4.1.3. Classic CNN.....	52
4.1.4. ALEXNET	55
4.1.5. VGG16	59
4.1.6. VGG19	62
4.1.7. Önerilen Poly-CNN Modeli	66

BEŞİNCİ BÖLÜM

SONUÇ VE TARTIŞMA

5.1. SONUÇ VE TARTIŞMA	72
KAYNAKÇA.....	73
DİZİN	80

TABLOLAR LİSTESİ

Sayfa

Tablo 1.1: Böbrek Tümörü Sınıflandırması İle İlgili Çalışmalar	7
Tablo 2.1: Denetimli ve Denetimsiz Öğrenme	18
Tablo 2.2: Bilgisayarlı Görü için Derin Öğrenme Çağına Giden Önemli Katkıları	21
Tablo 3.1: Tüm Sınıflara Ait Eğitim, Test ve Doğrulama Verileri	27
Tablo 3.2: En Popüler Python Kütüphaneleri	29
Tablo 3.3: ANN Modelinde Kullanılan Katmanlar ve Parametre Bilgileri	36
Tablo 3.4: Classic CNN Modelinde Kullanılan Katmanlar ve Parametreler	37
Tablo 3.5: AlexNet Modelinde Kullanılan Katmanlar ve Parametreler	39
Tablo 3.6: VGG16 Modelinde Kullanılan Katmanlar ve Parametreler	41
Tablo 3.7: VGG19 da Kullanılan Katmanlar ve Parametreler	43
Tablo 3.8: Önerilen Poly-CNN Modelinde Kullanılan Katmanlar ve Parametreler	45
Tablo 4.1: ANN Modeli Eğitim Verisi Başarı Oranı	49
Tablo 4.2: ANN Modeli Doğrulama (Validation) Verisi Başarı Oranı	49
Tablo 4.3: ANN Modeli Test Verisi Başarı Oranı	49
Tablo 4.4: ANN Modeli Eğitim Aşaması Değerlendirme Metrikleri	51
Tablo 4.5: ANN modeli için test aşaması değerlendirme sonuçları	52
Tablo 4.6: Classic CNN Modeli Eğitim Verisi Başarı Oranı	52
Tablo 4.7: Classic CNN Modeli Doğrulama (Validation) Verisi Başarı Oranı	52
Tablo 4.8: Classic CNN Modeli Test Verisi Başarı Oranı	52
Tablo 4.9: Classic CNN Modeli Eğitim Aşaması Değerlendirme Metrikleri	54
Tablo 4.10: Classic CNN Modeli için Test Aşaması Değerlendirme Metrikleri	55
Tablo 4.11: ALEXNET Modeli Eğitim Verisi Başarı Oranı	55
Tablo 4.12: ALEXNET Modeli Doğrulama (Validation) Verisi Başarı Oranı	56
Tablo 4.13: ALEXNET Modeli Test Verisi Başarı Oranı	56
Tablo 4.14: AlexNet Modeli Eğitim Aşaması Değerlendirme Metrikleri	58
Tablo 4.15: AlexNet Modeli için Test Aşaması Değerlendirme Metrikleri	59
Tablo 4.16: ALEXNET Modeli Eğitim Verisi Başarı Oranı	59
Tablo 4.17: ALEXNET Modeli Doğrulama (Validation) Verisi Başarı Oranı	59
Tablo 4.18: ALEXNET Modeli Test Verisi Başarı Oranı	60
Tablo 4.19: VGG16 Modeli Eğitim Aşaması Değerlendirme Metrikleri	61
Tablo 4.20: VGG16 Modeli için Test Aşaması Değerlendirme Metrikleri	62

Tablo 4.21: VGG19 Modeli Eğitim Verisi Başarı Oranı	63
Tablo 4.22: VGG19 Modeli Doğrulama (Validation) Verisi Başarı Oranı	63
Tablo 4.23: VGG19 Modeli Test Verisi Başarı Oranı	63
Tablo 4.24: VGG16 Modeli Eğitim Aşaması Değerlendirme Metrikleri	65
Tablo 4.25: VGG16 Modeli için Test Aşaması Değerlendirme Metrikleri	65
Tablo 4.26: Poly-CNN Modeli Eğitim Verisi Başarı Oranı.....	66
Tablo 4.27: Poly-CNN Modeli Doğrulama (Validation) Verisi Başarı Oranı	66
Tablo 4.28: Poly-CNN Modeli Test Verisi Başarı Oranı	67
Tablo 4.29: Poly-CNN Modeli Eğitim Aşaması Değerlendirme Metrikleri	69
Tablo 4.30: VGG16 Modeli için Test Aşaması Değerlendirme Metrikleri	70
Tablo 5.1: Tüm Modellerin Başarı (Accuracy) Oranları	72



ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1: Böbrek ve Üreterlerin Yerleşimi.....	11
Şekil 2.2: İdrar İçindeki Kristallerin Birleşmesi ile Oluşan Böbrek Taşları.....	12
Şekil 2.3: Böbrek Tümörü	13
Şekil 2.4: Böbrek Kistleri	14
Şekil 2.5: Evrişimli Sinir Ağının Mimarisi (CNN).....	22
Şekil 2.6: Evrişimli Sinir Ağları (CNN) Katmanları	23
Şekil 3.1: Böbrek Hastalığı için Kullanılan Verilerden Görüntüler.....	26
Şekil 3.2: Kullanılan Verilerin Sınıflara Göre Dağılımları	27
Şekil 3.3: Çalışmaya Ait Akış Diyagramı.....	30
Şekil 3.4: Havuzlama (Polling) İşlemi Gösterimi	32
Şekil 3.5: Düzleştirme (Flatting) İşlemi Gösterimi	33
Şekil 3.6: Tam Bağlı (Dense) ve Çıkış (Output) Katmanı Gösterimi.....	33
Şekil 3.7: Yapay Sinir Ağları (Artificial Neural Network- ANN) Modelinin Yapısı.....	35
Şekil 3.8: Evrişimsel Sinir Ağları (Convolutional Neural Network – Classic CNN) Modelinin Yapısı	37
Şekil 3.9: Derin Evrişimli Sinir Ağları (ALEXNET) Modelinin Yapısı.....	39
Şekil 3.10: Derin Evrişimli Sinir Ağları (ALEXNET) modelinin yapısı	Hata! Yer işareti tanımlanmamış.
Şekil 3.11: VGG16 Modelinin Yapısı	40
Şekil 3.12: VGG16 Modelinin Yapısı.....	42
Şekil 3.13: Önerilen Poly-CNN Modelinin Yapısı	44
Şekil 4.1: İkili Sınıflandırma için Karışıklık Matrisi.....	48
Şekil 4.2: ANN Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu Grafikleri	50
Şekil 4.3: Yapay Sinir Ağları (Artificial Neural Network- ANN) Modeli Eğitim, Doğrulama ve Test Verisi için Karışıklık Matrisi	50
Şekil 4.4: Classic CNN Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu Grafiği	53
Şekil 4.5: Classic CNN Modeli Eğitim, Doğrulama ve Test Verisi için Karışıklık Matrisi.....	54

Şekil 4.6: AlexNet Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu	
Grafiği.....	56
Şekil 4.7: Alexnet Modeli Eğitim, Doğrulama ve Test Verisi için Karşılıklı Matrisi	57
Şekil 4.8: VGG16 Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu	
Grafiği.....	60
Şekil 4.9: VGG16 Modeli Eğitim, Doğrulama ve Test Verisi için Karşılıklı Matrisi	61
Şekil 4.10: VGG19 Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu	
Grafiği	64
Şekil 4.11: VGG19 Modeli Eğitim, Doğrulama ve Test Verisi için Karşılıklı Matrisi ...	64
Şekil 4.12: Poly-CNN Modeli için Çapraz Entropi Hatası ve Sınıflandırma	
Doğruluğu Grafiği	68
Şekil 4.13: Poly-CNN Modeli Eğitim, Doğrulama ve Test Verisi için Karşılıklı	
Matrisi	68

KISALTMALAR

AI	Artificial Intelligence
ANN	Artificial Neural Network
CNN	Convolutional Neural Network
CPU	Central Processing Unit
DBN	Deep Belief Network
DNN	Deep Neural Network
GPU	Graphics Processing Unit
KBH	Kronik Böbrek Hastalığı
ML	Machine Learning
MR	Magnetic Resonance
RNN	Recurrent Neural Network
SVM	Support Vector Machine
UACR	Urine Albumin-to-Creatinine Ratio



TEZ METNİ

GİRİŞ

Son yıllarda derin öğrenme metotları, baş döndürücü bir hızla gelişerek farklı alanlarda başarılı uygulama örnekleri sunmaktadır. Derin öğrenme yöntemleri özellikle biyomedikal alanında önemli bir çığır açmış, özellikle anomali tespiti ve hastalık teşhisi gibi karmaşık sorunlarda etkileyici başarılar elde etmiştir. Bu başarılar, bilgisayar destekli teşhis sistemlerinin geliştirilmesine yönelik büyük bir ilgi ve ihtiyaç doğurmuştur. Bu bağlamda, böbrek hastalıklarının teşhisi, özellikle karmaşık ve çok yönlü bir süreç olup, doğru ve hızlı bir şekilde gerçekleştirilmesi, hastaların tedavi süreçlerini olumlu yönde etkileyebilecek kritik bir unsurdur.

Modellerin etkili bir şekilde eğitilebilmesi için geniş, temsil edici ve nitelikli veri setlerine olan ihtiyaç kaçınılmazdır. Bu çalışma, Kaggle platformundan elde edilen açık bir veri seti üzerinde gerçekleştirilmiş ve böbrek hastalıklarının tespiti ve sınıflandırılması için derin öğrenme yöntemlerinin etkinliğini belirlemeyi ve performanslarının kıyaslanarak değerlendirilmesini amaçlamıştır.

Çalışma kapsamında değerlendirilen derin öğrenme modelleri arasında Klasik CNN, Yapay Sinir Ağı (ANN), ALEXNET, VGG16 ve VGG19 gibi öncü modeller bulunmaktadır. Bunlarla birlikte, çalışma içinde öne çıkan ve önerilen Poly-CNN modeli, geleneksel yapıyı aşan, ekstra max pooling ve dense katmanları ekleyerek güçlendirilmiş bir derin öğrenme modeli olarak tasarlanmıştır. Bu özel model, daha geniş bir özellik çeşitliliği ve karmaşıklığı yönetebilme yeteneği ile daha etkili öğrenme performansı sunmayı hedefler. Eklenen katmanlar, aşırı öğrenmeye karşı direnç sağlamak ve modelin sınıflandırma yeteneğini artırmak amacıyla eğitim sırasında rastgele devre dışı bırakılan nöronları içermektedir. Bu sayede, Poly-CNN, bilgi çıkarma ve sınıflandırma görevlerinde daha yüksek başarı sağlamayı amaçlar.

Elde edilen sonuçlar, Poly-CNN'in %99,94'lük yüksek bir doğruluk oranıyla öne çıktığını göstermiştir. Bu sonuçlar, Poly-CNN'in, bilinen diğer CNN modellerine göre daha üstün bir performans sergileyerek önerilen araştırma çerçevesinde etkinliğini belirgin bir şekilde ortaya koymaktadır. Ayrıca, Poly-CNN'in, diğer çalışmalara kıyasla gözle görülür bir doğruluk artışı sağladığı gözlemlenmiştir.

Çalışmanın ayrıntılı analizi, kullanılan parametre değerlerinden, katman yapılarına, karmaşıklık matrislerinden doğruluk ve kayıp grafiklerine kadar bir dizi önemli bilgi sunmaktadır.



BİRİNCİ BÖLÜM
LİTERATÜR TARAMASI

1.1. LİTERATÜR TARAMASI

Krizhevsky vd., (2012), çalışmalarında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nın 2010 versiyonunda yer alan 1.2 milyon görüntüyü, 1.000 farklı sınıfı tespit etmek amacıyla büyük ve derin bir evrişimli sinir ağı (CNN) modeli geliştirmişlerdir. ILSVRC-2010 sonuçlarına göre, model top-1 ve top-5 test hata oranlarını %17 ve %37,5'a ulaşmıştır. Bu, ILSVRC-2010 yarışmasında elde edilen en iyi sonuç olmuştur; yarışmada en iyi sonuçlar %47,1 ve %28,2'dir. Bu veri setinde, top-1 ve top-5 hata oranları sırasıyla %67,4 ve %40,9 olarak bulunmuştur.

Sabarinathan vd., (2020), bilgisayarlı tomografi (BT) görüntülerinde böbrek tümörü segmentasyonunun zorluklarına odaklanarak Hyper Vision Net adını verdikleri bir çalışma gerçekleştirmişlerdir. Bu çalışmada, mevcut U-Net modellerinin değiştirilmiş bir versiyonu olan Hyper Vision Net modeliyle yeni bir böbrek tümörü segmentasyon yöntemi sunulmuştur. Görüntü ön işleme aşamasında, tüm BT görüntüleri 256x256 boyutuna yeniden boyutlandırılmıştır. Modelin kodlayıcı kısmında, V-Net mimarisi kullanılmış ve koordinat evrişimli katmanlar eklenerek ağın genelleme kapasitesi artırılmıştır. Kod çözücü kısmında ise, maksimum havuzlama katmanları dışında aynı bloklar kullanılarak özellik haritaları elde edilmiştir. Toplu normalleştirme ve bırakma katmanları ağı dahil edilmiş ve üstel doğrusal etkinleştirme işlevi ile eğitilmiştir. Önerilen model, arteriyel abdominal BT görüntülerinden oluşan 300 hastanın veri setiyle eğitilmiş ve KiTS19 veri setinden yararlanılarak doğrulanmıştır. Sonuçlar, önerilen yöntemin tümör bölgesi ve böbrek bölgesinde sırasıyla yüzde 95,52 ve yüzde 96,33 oranlarında başarı elde ettiğini göstermiştir. Bu sonuçlar, Hyper Vision Net modelinin başarısını göstermektedir.

Nithya vd., (2020), böbrek ultrason görüntülerinden yararlanarak böbrek hastalığı taraması ve teşhisi için yapay sinir ağı tabanlı bir mimari geliştirmiştir. Çalışmanın temel amacı, kümeleme ve sınıflandırma yaklaşımlarını birleştirerek böbrek hastalığının tespitini ve segmentasyonunu sağlamaktır. Böbrek taşı tespiti ve segmentasyonu, ultrason görüntüleri için önemli bir çalışmadır ve genellikle manuel olarak yapılır. Bu süreç zaman alıcı ve operatöre bağlı olduğu için zorlayıcı olabilir. Nithya ve ekibi, yapay sinir ağı ile böbrek taşı tespiti ve çok çekirdekli kümeleme algoritması ile segmentasyon önermiştir. Sistem, parazitleri giderme, özellik çıkarma, sınıflandırma ve segmentasyon olmak üzere dört ana bölümden oluşur. Giriş

görüntüsündeki gürültüyü ortadan kaldırmak için medyan filtresi kullanılır, ardından önemli ağ özellikleri çıkarılır. Sinir ağı sınıflandırıcısı ile normal ve anormal görüntüler ayrıştırılır ve anormal görüntüler, taş ve tümör bölgelerini ayırmak için bölümlene aşamasına tabi tutulur. Yapılan testler, önerilen sistemin diğer metotlarla kıyaslandığında %99,61'lik bir başarı oranına ulaştığını göstermektedir.

Alakwaa vd., (2017), akciğer BT görüntülerini Kaggle Data Science Bowl veri setindeki işaretlenmemiş nodüllü BT taramaları için bir Bilgisayar Destekli Teşhis (CAD) sistemi önermektedir. İlk aşamada, eşikleme yöntemi kullanılarak akciğer dokusu BT taraması ile diğer dokulardan ayrılarak akciğer segmentasyonu yapılmıştır. Bölümlere ayrılmış akciğer bölgeleri, BT taramasını akciğer kanseri için pozitif veya negatif olarak sınıflandırmak için 3B Evrişimli Sinir Ağları (CNN'ler) ile işlenmiştir. 3D CNN'ler, test seti doğruluğu açısından %86,6 oranında başarı elde etmiştir.

Bhaskar ve Manikandan (2019), böbrek hastalığını otomatik olarak tespit etmek için yeni bir algılama yöntemi önermektedir. Bu yöntem, hastalığı teşhis etmek için tükürükteki üre konsantrasyonunu izlemektedir. Tükürük örneğindeki üre seviyelerini derin öğrenme evrişimli sinir ağı (CNN) algoritması uygulanmış ve bunun yanı sıra bir destek vektör makinesi (SVM) sınıflandırıcısı ile birleştirilmiştir. CNN-SVM birleşik ağı, modelin sınıflandırma doğruluğunu artırmıştır. Önerilen model, örnekleri %98.04'lük bir doğrulukla başarıyla sınıflandırmıştır.

Tüzün ve Özdemir (2023), manyetik rezonans (MR) görüntülerini kullanarak beyin tümör hastalığının erken teşhisini gerçekleştirmeyi amaçlamaktadır. Bu bağlamda, GoogleNet, Mobilenetv2, InceptionV3 ve Efficientnet-b0 gibi derin öğrenme modelleri, Matlab platformunda kodlanarak beyin tümörlerini tespit ve sınıflandırmak için kullanılmıştır. Sınıflandırma işlemi, Glioma, Meningioma ve Pituitary gibi yaygın beyin tümörleri üzerinde gerçekleştirilmiştir. Kaggle platformunda elde edilen 7022 beyin MR görüntüsünden oluşan veri seti, dört farklı sınıfta bulunan tümörleri içermektedir. Karşılaştırılan derin öğrenme modellerinin değerlendirilmesi sonucunda, başarı sırasıyla GoogleNet (%98.25), Efficientnet-b0 (%99.54), Mobilenetv2 (%98.93) ve InceptionV3 (%99.47) olarak belirlenmiştir. Araştırma sonuçları, Efficientnet-b0 modelinin diğer modellere kıyasla daha üstün bir başarı oranına sahip olduğunu göstermektedir.

Mamani vd. (2019), böbrek tümörü taraması için U-Net tabanlı bir 3B ağ modeli geliştirmiştir. KITS19 veri seti üzerinde yapılan çalışmada, Önerilen modelin yetkinliğini

artırmak için ek bir giriş formatı tanımlanmış ve böbrekler ile böbrek tümörleri sınıfları tek bir sınıf olarak birleştirilmiştir. Görüntü ön işleme aşamasında BT taramaları ve notları belirli çözünürlüklere yeniden örneklendirilmiştir. Daha sonra, her iki giriş farklı çözünürlüklerin segmentasyonlarını eşleştirmek için aynı ağırlık merkezini paylaşmıştır. Önerilen ağ, 3B U-Net tabanlı bir yapıya dayanmaktadır. Düşük çözünürlüklü alt ağ, 16 filtreli bir giriş ile bölümlenme gerçekleştirmek için kullanılmıştır. Yüksek çözünürlüklü bölümlenme alt ağı ise orijinal U-Net modelini kullanmaktadır. Ayrıca, ağ yapısına ekstra bir sınıflandırma görevi eklenmiş ve çalışmanın sonucunda başarı yüzde 90'a kadar ulaştığı görülmüştür.

Uçar (2022), araştırmasında, kas ultrason görüntülerinden hastalıkları teşhis eden bir bilgisayar destekli teşhis sistemi oluşturmayı hedeflemiştir. Çalışmada 3214 kas ultrason görüntüsü kullanılmıştır. Modelini VGG16 ve VGG19 mimarilerini birleştirerek ikili ve çoklu sınıflandırma problemlerinde test etmiştir. Önerilen sistem, S1 için %93, S2 için %96,01, S3 için %91,74 ve çoklu sınıflandırma (S4) için %95,12 doğruluk elde etmiştir. Test verisi sonuçları gösteriyor ki, önerilen derin öğrenme yönteminin kas hastalıklarının sınıflandırmasında başarılı olduğunu göstermektedir.

Alzu'bi vd., (2022), çalışmalarında, bilgisayarlı tomografi (BT) görüntülerinden böbrek tümörlerini tespit etmek için çeşitli modeller karşılaştırılmaktadır. Bu modeller arasında 2D konvolüsyonel sinir ağı (CNN-6), 50 katmanlı bir ResNet50 ve 16 katmanlı bir VGG16 bulunmaktadır. Araştırmada, Kral Abdullah Üniversitesi Hastanesi'nde (KAUH) kaydedilen 120 yetişkin hastanın tıbbi görüntüleri kullanılmıştır. Toplamda, 8.400 bilgisayarlı tomografi (BT) görüntüsünden oluşmaktadır. Veri seti, modelin eğitilmesi ve test edilmesi için %80 ve %20 oranında bölünmüştür. Yapılan çalışmanın sonuçları ise, 2D CNN-4 modeli %92, 2D CNN-6 modeli %97 ve ResNet50 modeli %96 doğruluk oranına ulaşmıştır.

Sasikaladevi ve Revathi (2024), çalışmalarında böbrek yetmezliğinin otomatik tespiti için derin öğrenme tekniklerine dayalı bir çalışmayı tanımlıyor. Çalışma, kronik böbrek hastalığının son aşaması olan böbrek yetmezliğini, bilgisayarlı tomografi (CT) görüntülerinden çeşitli böbrek hastalıklarını teşhis etmeye odaklanıyor. Bu hastalıklar arasında böbrek taşı, kist ve tümör bulunmaktadır. Çalışma, CT tarama karın ve ürogram görüntülerini kullanarak bir dijital ikiz oluşturuyor. Bu işlem, görüntülerin karmaşık yapılarını anlamak ve önemli özellikleri çıkarmak için kullanılıyor. Çıkarılan derin özellikler daha sonra hiper kenarlar olarak adlandırılır ve böbrek görüntülerini temsil

eden bir hipergrafa kullanılmak üzere dönüştürülmüştür. Bu yaklaşım, tıbbi görüntülerin incelenmesi ve analizinde yaygın olarak kullanılan bir yöntemdir. Derin öğrenme metrikleri arasında hassasiyet, geri çağırma, doğruluk ve F1 skoru kullanılarak önerilen modelin başarısı değerlendiriliyor. Önerdiği modelin, diğer önde gelen modeller ile karşılaştırıldığında yüksek bir doğrulamaya sahip olduğu görülmektedir. (%99,71).

Yapılan literatür taraması, böbrek hastalığının erken teşhisinin sınıflandırılması için derin öğrenme yöntemlerinin başarıyla kullanıldığını göstermektedir. Çeşitli araştırmalarda kullanılan modeller, farklı medikal görüntüleme veri setleri üzerinde yüksek doğruluk oranları elde etmiştir. Bu çalışmalar, derin öğrenme yöntemlerinin medikal görüntüleme alanında etkili bir şekilde kullanılabileceğini ve bu tekniklerin erken teşhis ve doğru sınıflandırma konularında önemli bir potansiyele sahip olduğunu vurgulamaktadır. Elde edilen yüksek doğruluk oranları, bu modellerin klinik uygulamalarda kullanılabilirliğini desteklemekte ve medikal görüntüleme alanındaki teknolojik ilerlemelerin hastalıkların tespiti ve sınıflandırılmasında önemli bir rol oynayabileceğini göstermektedir.

Böbrek tümörü sınıflandırmasıyla ilgili geçmiş yıllarda gerçekleştirilen çalışmalar, çeşitli yöntemlerin ve veri kümelerinin kullanıldığı çeşitli yaklaşımları ortaya koymaktadır. Tablo 1.1'de, 2020'den 2024'e kadar olan dönemde bu alanda yapılan önemli çalışmaların özetini görebiliriz. Bu çalışmalar, farklı veri setleri, derin öğrenme mimarileri ve sınıflandırma yöntemleri üzerine odaklanmıştır. Bu tabloda, yıllara göre sıralanmış çeşitli çalışmaların öne çıkan sonuçlarını ve kullanılan metodolojileri görebiliriz. Özellikle, 2022 ve 2023 yıllarındaki çalışmaların, yüksek doğruluk oranlarına ulaşan derin öğrenme modellerini içermesi dikkat çekicidir.

Tablo 1.1: Böbrek Tümörü Sınıflandırması ile İlgili Çalışmalar

Yıl	Dataset	Method	Sonuç	Kaynak
2020	CHC Hospital	DNN	%96,54	(Sudharson ve Kokil 2020)
2020	KiTS19	Hybrid V-Net	%97,70	(Türk, vd., 2020)
2021	KiTS19	InceptionV3, ROC	%97,40	(Heller, vd., 2021)
2022	KiTS19	DeepLabv3+ 2.5D	%99,71	(Cruz, vd., 2022)
2022	8400	2D-CNN	%97,00	(Alzu'bi, vd., 2022)
2022	CT Kidney Dataset	Swin Transformer	%99,30	(Islam, vd., 2022)
2023	CT Kidney Dataset	Hybrid CNN Model	%99,37	(Bingol, vd., 2023)
2024	CT Kidney Dataset	Proposed Model	%99,71	(Sasikaladevi ve Revathi, 2024)



İKİNCİ BÖLÜM
GENEL BİLGİLER

2.1. BİLGİSAYARLI GÖRÜ

Yapay zekanın en dikkat çekici özelliklerinden biri, çeşitli biçimlerde deneyimlediğimiz bilgisayar görüşüdür. Bu alan, bilgisayar sistemlerinin görsel verileri anlama, yorumlama ve işleme kabiliyetini içerir, bu da görüntü tanıma, nesne algılama ve diğer görsel görevlerde üstün yetenekler sağlar. Yapay zekâ, günümüz bilgi teknolojilerinde önemli bir paradigmayı temsil etmektedir. Bu bağlamda, bilgisayar görüşü, görsel verileri anlama ve işleme yeteneği ile bilgisayarın bilişsel yeteneklerini geliştirmeye yönelik kritik bir araştırma alanını oluşturmaktadır. Görüntü ve videolardaki nesneleri insan algısı ile benzer şekilde tanıma kapasitesi, bilgisayarlı görü alanının temelini teşkil etmektedir. Zaman içerisinde, bilgisayarlı görü, sınırlı yeteneklere sahip olmasına rağmen, son yıllarda yapay zekâ, derin öğrenme ve sinir ağı teknolojilerindeki gelişmelerle büyük bir evrim geçirmiştir. Yeni donanım ve algoritmaların entegrasyonu, bilgisayarlı görme alanındaki nesne tanıma doğruluk oranlarında önemli artışlara yol açmıştır. Makine öğrenimi tekniklerini aşan bilgisayarlı görü, video, fotoğraf, film gibi görsel verilerden yüz tanıma, aktivite tanıma gibi uygulamalarda üst düzey performans sergilemektedir. Bu teknolojik ilerlemeler, bilgisayarla görme disiplininin genel potansiyelini daha iyi anlamamıza ve gelecekteki araştırma yönelimlerini belirlememize katkı sağlamaktadır.

Görüntü işleme süreci, ilk olarak bir veya birden fazla sensör tarafından bir veya birden fazla görüntünün edinilmesi ile başlar. Bu sensörler kameralar, termal kameralar, LIDAR (Işın Algılama ve Mesafe Ölçme), radarlar veya diğer ölçüm cihazları olabilir. Elde edilen görüntüler genellikle piksellerden oluşur. Görüntü edindikten sonra, bu görüntüler genellikle ön işleme adı verilen bir dizi adımdan geçirilir. Bu adımlar arasında gürültü azaltma, kontrast düzenleme, renk dengesi sağlama gibi işlemler bulunabilir (Zhao, vd., 2019). Ayrıca, görüntülerin boyutunu düzenleme ve gerektiğinde renk uzayını değiştirme gibi işlemler de yapılabilir (Dalal ve Triggs, 2005). Görüntüdeki önemli bilgileri belirlemek için özellik çıkarma adı verilen bir süreç kullanılır. Bu süreçte, görüntünün belirli bölgelerinde bulunan özellikler çıkarılır. Bu özellikler, nesnelerin kenarları, renk dağılımı, desenler veya diğer tanımlayıcı özellikler olabilir (Santosh, vd., 2022). Özellik çıkarma adımından sonra, elde edilen özellikler genellikle öznitelik uzayında temsil edilir. Öznitelik uzayı, özelliklerin birer vektör olarak temsil edildiği bir matematiksel uzaydır. Bu uzayda, benzer özelliklere sahip nesneler birbirine daha yakın bir konumda bulunur. Bu aşamada, elde edilen özellikler temel alınarak nesneler tanınır

ve sınıflandırılır. Sınıflandırma, bir görüntüde bulunan nesnenin belirli bir kategoriye ait olup olmadığını belirleme işlemidir. Bu genellikle öğrenme algoritmaları ve modelleri kullanılarak gerçekleştirilir. Derin öğrenme, bu aşamada özellikle etkili olmaktadır. Tanıma ve sınıflandırma adımından elde edilen sonuçlar genellikle bir sonuç analizi sürecinden geçer (Zhao, vd., 2019). Bu temel yapı taşları, bilgisayarlı görü sistemlerinin çeşitli uygulamalarda kullanılmasını sağlar. Her bir adım, özel uygulamalara ve gereksinimlere göre özelleştirilebilir. Derin öğrenme, özellikle öznitelik çıkarma ve tanıma/sınıflandırma aşamalarında önemli bir rol oynayarak bilgisayarlı görü sistemlerinin performansını artırabilir (Santosh, vd., 2022).

2.2. BÖBREK HASTALIKLARI

Böbrekler, vücuttaki atıkları, asitleri ve fazla sıvıları süzerek temizleyip, sonrasında idrar şeklinde dışarı atan önemli organlardır, bu sayede vücut sağlığının sürdürülmesinde kritik bir rol oynarlar. Kronik böbrek hastalığı (KBH) dünya nüfusunun yaklaşık %10'unu etkilemektedir. Kronik böbrek hastalığında görülen az semptomlar hastalığın erken evrelerinde olduğu anlaşılmaktadır. Bu semptomlar artmadıkça kronik böbrek hastalığının olduğu anlaşılmamaktadır. Kronik böbrek hastalığı, yapay filtreleme (diyaliz) uygulanmazsa veya böbrek nakli gerçekleştirilmezse, ölümcül sonuçları olan son evre böbrek yetmezliğine ilerleyebilir (Arık ve Dilek, 2023).

İnsanlarda böbrek, sırtımızın ortasına yakın bir yerde büyüklüğü yumruğumuz kadar ve iki adet olduğu bilinmektedir. Böbreğin içinde yaklaşık bir milyon küçük yapıya sahip nefron vardır. Nefron, kanı filtreleyerek idrar haline gelen atıkları vücuttan uzaklaştırmaktadır. Böbrek hastalıkları nefronlara zamanla zarar vermektedir. Bu zarar böbreklerin atıkları uzaklaştıramamasına neden olabilmektedir.


Böbrek hastalıklarında oluşan sorunlar şunlardır:

- Böbrek Taşı
- Böbrek Tümörü
- Böbrek Kisti

Doktorlar böbrek hastalığının olup olmadığını kontrol etmek için kan ve idrar testleri yapmaktadır. Bu testler doğrultusunda böbrekler iflas ederse hastanın tedavi edilebilmesi için diyalize ya da böbrek nakline ihtiyaç bulunmaktadır. İnsan vücudunun karın arka kısmında omurganın her iki yanında bulunan böbrekler, yaklaşık 10 cm (4 inç)

uzunluğunda, fasulye şeklinde 2 organdır (National Health Service, 2023). Böbrek ve üreterlerin abdomende yerleşimi Şekil 2.1’de verilmiştir (Netter, 1987).

Şekil 2.1: Böbrek ve Üreterlerin Yerleşimi




Kaynak: Netter, 1987

2.2.1. Böbrek Taşı

Böbrek taşı, idrardaki çeşitli minerallerin birleşmesiyle oluşan sert yapıdır. Böbrek taşı semptomları idrarda yanma, idrarda kan, şiddetli sırt ağrısı, kusma ve ateş gibi görülmektedir. İdrarın içinde çeşitli atıklar çözünmüş halde bulunur. Sıvı miktarı düşük olduğunda, atıkların konsantrasyonu artar ve bu durum kristal oluşumuna neden olur. Bu kristaller, diğer elementleri çeker ve vücuttan atılmadığı sürece bir araya gelerek daha büyük bir katı oluştururlar. Çoğu insanda yeterli miktarda sıvı bulunması taşların temizlenmesini sağlar veya idrardaki diğer kimyasallar taş oluşumunu durdurmaktadır. İdrar içindeki kristallerin birleşmesi ile oluşan böbrek taşları Şekil 2’de verilmiştir. Araştırmacılar, yaklaşık on kişiden birinin yaşamı boyunca böbrek taşı olacağı sonucuna varmıştır. Çocuklarda böbrek taşları yetişkinlere göre çok daha az görülmektedir ancak aynı nedenlerle ortaya çıkmaktadır (Böbrek Taş Hastalığı, 2023).

Şekil 2.2: İdrar İçindeki Kristallerin Birleşmesi ile Oluşan Böbrek Taşları




Kaynak: Böbrek Taş Hastalığı, 2023

2.2.2. Böbrek Tümörü

Böbrek tümörleri, kanserli veya kanserli olmayan dokuların anormal büyümeleridir. Bazı böbrek kitleleri (tümörü) iyi huyludur (kanserli değildir), bazıları ise kötü huyludur (kanserli). Küçük böbrek kitleleri iyi huylu olma olasılığı daha yüksek fakat büyük kitlelerin kanserli olma olasılığı daha yüksektir. Bazı tümörler hızlı ya da yavaş büyüyebilir ya da daha agresif olabilmektedir. Agresif tümörler daha hızlı bir şekilde büyümekte ve yayılmaktadır. Böbrek tümörünün diyagramı Şekil 2.3'te verilmiştir (Urology Care, 2023).

Şekil 2.3: Böbrek Tümörü



Kaynak: Urology Care, 2023

2020 itibariyle dünya genelinde renal hücreli kanser hastalarının sayısı yaklaşık 431.000 civarındadır. Bu rakamın 2040 yılında 666.000'i aşması beklenmektedir (Pfizer, 2023). Türkiye'de ise 2020 yılında renal hücreli kanser vakalarının sayısı 5.130 iken, 2040 yılında 8.090'a çıkması öngörülmektedir (Pfizer, 2023).

Erken evrede oluşan böbrek kitlelerinin belirtileri şu şekilde ortaya çıkabilir:

- İdrarda kan görülmesi
- Bel ağrıları
- Diyetle alakalı olmayan kilo kaybı
- İştah kaybı
- Geçmeyen ateş (İnfeksiyon kaynaklı olmayan)
- Anemi belirtileri (Kırmızı kan hücrelerinin düşük seviyesi)


Böbrek kitlelerinin tedavisinde temel amaç, kanseri tedavi etmek ve mümkün olduğunca böbrek fonksiyonlarını korumaktır. Böbreği tek ya da başka bir böbrek hastalığı olan hastalarda böbrek fonksiyonunun korunması oldukça önemlidir. Bazı hastalar için

ameliyat en iyi seçim olurken bazı hastalarda ameliyata gerek bile kalmamaktadır. Daha fazla bilgi edinmek için tümörden biyopsi alınması önerilebilmektedir.

2.2.3. Böbrek Kisti

Böbrek kistleri, böbreklerde sıvı dolu keseciklerin oluştuğu durumları ifade eder. Basit böbrek kistleri, genellikle sıvı dolu, ince duvarlı keseciklerdir ve genellikle böbrek fonksiyonları üzerinde belirgin bir etkileri olmaz (Kidney Cyst, 2023). Ancak, bazı durumlarda kistler büyüyebilir veya sayıca artabilir, bu durumda böbrek fonksiyonları üzerinde etkiler gösterebilirler. Böbrek kistleri genellikle belirti göstermez ve çoğunlukla tesadüfen tespit edilir. (Urology Care, 2023). Ancak belirli bir boyuta veya komplikasyona ulaştıklarında, tedavi gerekebilir.

Şekil 2.4: Böbrek Kistleri



Kaynak: Kidney Cyst, 2023

Sıklıkla yapılan görüntüleme testi sırasında basit böbrek kistleri bulunmaktadır. Semptomlara neden olmadığı sürece basit kistler tedaviye gerek görülmemektedir. Basit bir böbrek kisti yeterince büyürse belirtileri şöyle olacaktır:

- Sırtta donuk ağrı
- Ateş
- Üst mide ağrısı

2.3. BÖBREK HASTALIKLARI TANI VE TEDAVİ YÖNTEMLERİ

Nefrolog olarak adlandırılan uzmanlar böbrek hastalığını teşhis ve tedavi etmektedir. Böbrekler kandaki atıkları filtreleme yeteneğini yavaş yavaş kaybettiklerinde tedavi edilmezse, böbreklerden birinin ya da her ikisinin çalışmadığı ya da böbrek yetmezliğinin meydana geldiği görülmektedir. Akut böbrek yetmezliği yaşayan bazı insanların organları kısa sürede iflas ettiği görülmektedir (Urology Care, 2023).

Fasulye şeklinde küçük organlar olan böbrekler, her biri yumruk büyüklüğünde vücudun arka tarafında göğüs kafesinin altındadır. İlaçların, kimyasal maddelerin, sindirilmiş gıdaların vb. atık ürünlerin kandan uzaklaştırmasında birçok önemli işlevleri vardır. Bunlar daha sonra idrarla atılmaktadır. Böbrekler ayrıca vücudun fosfor, potasyum ve sodyum gibi sıvı ve elektrolit seviyelerini de dengelemektedir. Kalbin, kasların ve diğer yapıların çalışması için bunlar gereklidir. Ayrıca böbrekler, kan basıncını düzenlemeye ve kemikleri güçlendirmeye yardımcı olan hormonlar üretmektedir. Bazı kişilerde kronik böbrek hastalığı olmasına rağmen hiçbir belirti göstermemektedir. Bu nedenle kan ve idrar testleri yapıldıktan sonra hastalık teşhis edilmektedir. Sağlık uzmanlarının böbrek sağlığını kontrol etmek için isteyebileceği farklı testler şu şekildedir:

- Tam idrar tahlili
- Böbrek Fonksiyon Testleri
- Ultrasonografi ve bilgisayarlı tomografi
- Böbrek biyopsisi

2.3.1. Tam İdrar Tahlili

Böbrek hastalığının tanısında idrar tahlili hem ayaktan hem de hastane ortamlarında klinisyenin kolayca erişebileceği, bilgilendirici ve invaziv olmayan bir tanı aracıdır. Fizik muayene ve laboratuvar testleri ile birlikte idrar tahlili, akut ve kronik böbrek hastalığının değerlendirilmesinde merkezi bir rol oynamaktadır (Urology Care, 2023). Ek olarak, asemptomatik bir hastada bile rutin idrar tahlilindeki anormal bulgular, altta yatan böbrek hastalığının ilk kanıtı olabilmektedir. İdrar tahlili bazı hastalarda yerleşik böbrek hastalığının seyrini izlemek için de kullanılabilir.

Proteinin idrardan sızması böbrek hastalığının en erken belirtilerinden biridir. Sağlık uzmanı idrardaki proteini kontrol etmek için hastadan idrar testi istemektedir. İki

tür idrar testi ile hastanın protein seviyesi kontrol edilebilmektedir. Bu testler şu şekildedir:

- **Yağ çubuğu idrar testi.** İdrarda karaciğer tarafından üretilen proteini (albümin) aramak için yapılır ve bu test genel idrar tahlilinin bir parçasıdır. Verilen idrar tahlili örneğine bir seviye çubuğu (kimyasal olarak işlenmiş bir kâğıt) yerleştirilmektedir. Bu seviye çubuğunda çıkan seviyeler normalin üzerindeyse çubuğun rengi değişmektedir (Urinalysis Dipstick, 2023).
- **İdrar albümini/kreatinin oranı (UACR).** UACR testi, Nefrolog uzmanınız 24 saatlik bir süre içinde idrarınıza ne kadar albüminin geçtiğini bilmesini sağlamaktadır. Bu albümin miktarının idrardaki kreatinin miktarıyla karşılaştırılmaktadır (Green, vd., 2023).

Böbrek hastalığının tanısında yapılan idrar tahlilleri açısından aşağıdakileri bilmek önemlidir:

- Test birden fazla tekrarlanıp sonuçlar doğrulanmalıdır.
- Yapılan idrar testinde, idrardaki albümin miktarı ile böbrek hastalığı varsa sağlık uzmanı tarafından en iyi tedavinin hangisi olduğu bilinmesine yardımcı olmaktadır.
- İdrar albümin düzeyinin takibi ile tedavi sürdürülmektedir. Bu albümin düzeyi aynı kalır ya da azalırsa tedavi işe yaradığı anlamına gelmektedir (Sumida, vd., 2020).

2.3.2. Böbrek Fonksiyon Testleri

Böbreklerin ne kadar çalıştığını ölçmek için böbrek fonksiyon testleri yapılmaktadır. Böbreklerin sistemdeki atıkları iyi temizlendiğini kontrol etmek için bu testlerin çoğu yapılmaktadır. Kan testi ve idrar örneği böbrek testi olarak her ikisini birden içermektedir. Test sonuçları genellikle aynı gün veya birkaç gün içinde alınmaktadır. İdrar ve kan testleri, böbrek fonksiyonlarını değerlendirmekte kullanılır. Bu testler, glomerüler filtrasyon hızını (GFR) ölçerek, böbreklerin vücuttaki atıkları ne kadar etkili bir şekilde süzdüğünü değerlendirir (Caniklioğlu, vd., 2022). Bu süreç, böbreklerin sistemdeki zararlı maddeleri ne kadar verimli bir şekilde temizlediğini belirlemede yardımcı olur.

Böbrek fonksiyonlarını etkileyebilen durumlar arasında diyabet veya hipertansiyon bulunmaktadır. Hasta bu durumlardan birini yaşıyorsa, doktor böbrek fonksiyon testlerini önererek böbreklerin çalışmasını değerlendirebilir. Bu testler, potansiyel böbrek sorunlarına işaret eden belirtiler varsa gereklidir. Bu belirtiler şu şekilde sıralanabilir:

- İdrarda kan olması
- Acı veren idrar yapma durumu
- Sık sık idrar yapma isteği

Sağlık uzmanının bir veya birkaç farklı türde böbrek fonksiyon testi isteyebilmektedir. Böbrek fonksiyonu için istenilen kan ve idrar testleri:

- **Kan üre nitrojen**, kandaki azotu ölçmektedir.
- **Tahmini GFR**, Filtreleme oranlarını, protein seviyeleri, yaş ve cinsiyete bağlı olarak hesaplayan Tahmini GFR yöntemi kullanılmaktadır.
- **Serum kreatinin**, kreatinin oluşumunu aramaktadır.
- **Mikroalbuminüri**, spesifik bir protein aramaktadır.
- **İdrar tahlili**, idrarda kan, protein ve fonksiyon açısından değerlendirilmektedir (Üstündağ, vd., 2013).

2.3.3. Manyetik Rezonans (MR), Ultrason ve Bilgisayarlı Tomografi

Manyetik Rezonans (MR) testi, böbreklerin veya vücudun diğer bölümlerinin çok sayıda ayrıntılı resmini elde etmek için güçlü mıknatıslar ve radyo dalgaları kullanılmaktadır. Ayrıca ultrason gibi yapısal anormallikleri araştırmak için kullanılmaktadır. Ultrason testinde ses dalgalarını kullanılarak böbreklerin veya organların genel bir resmini elde etmektedir. Böbreklerdeki taş, tümör veya pozisyon anormalliklerini araştırmak için ultrason testi kullanılabilir. Bilgisayarlı tomografi testinde röntgen ışınlarını kullanılarak böbreklerin veya vücudun birçok ayrıntılı resmini elde etmektedir (Black, vd., 2020).

2.3.4. Böbrek Biyopsisi

Böbrek biyopsisi, sağlık uzmanlarının hastanın böbrek sağlığı hakkında daha derinlemesine bilgi edinmek amacıyla uyguladığı bir testtir. Bu testte, bir veya daha fazla küçük parça hastanın böbreğinden alınarak mikroskop altında incelenir. Sağlık

uzmanları, özellikle belirli semptomlar, laboratuvar test sonuçları veya görüntüleme yöntemleri ile ilgili belirsizlik durumlarında, hastalarının sağlık durumu hakkında daha fazla bilgi elde etmek amacıyla böbrek biyopsisi isteyebilirler (Kidney Biopsy, 2023).

2.4. YAPAY ZEKÂ ÖĞRENME YÖNTEMLERİ

2.4.1. Makine Öğrenme

Yapay zekanın (AI) bir alt türü olan makine öğrenimi (ML), bilgisayar sistemlerine veri analizi aracılığıyla öğrenme kabiliyeti kazandıran bir yapay zekâ dalıdır. Büyük veri kümelerinde desenleri tanıma, tahminler yapma ve kararlar alma gibi yeteneklere sahiptir. Sınıflandırma, regresyon, kümeleme gibi çeşitli teknikleri içerir ve sağlık, finans, görüntü tanıma gibi çeşitli alanlarda uygulanabilir (Brown, 2023).

Makine öğrenimi birçok sektörde yaygın olarak uygulanabilmektedir. Sağlık hizmetlerinde tedavi planlarını teşhis etmek ve önermek için makine öğrenimi kullanılmaktadır. Makine öğrenimi kullanımında diğer yaygın örnekler, dolandırıcılık tespiti, kötü amaçlı yazılım tehdidi tespiti ve spam filtreleme yer almaktadır (Columbia Engineering Boot Camps, 2023). Derin uzmanlık ve önemli kaynaklar gerektiren karmaşık ve zorlu bir teknoloji olan makine öğrenimi aynı zamanda sorunları çözmek, iyileştirmek ve görevleri otomatikleştirmek için güçlü bir araçtır. Büyük miktarda kaliteli veri içeren makine öğrenimi algoritmalarının eğitimi doğru sonuçlar üretmektedir. İnsan beynini örnek alan derin öğrenme sinir ağları gibi karmaşık algoritmalar tarafından üretilen sonuçları anlamak zor olabilmektedir. ML modellerinin çalıştırılması ve ayarlanması maliyetli olabilmektedir. Makine öğreniminin temel türleri; denetimli ve denetimsiz öğrenmedir. Denetimli öğrenme ve denetimsiz öğrenme karşılaştırma tablosu Tablo 2.1’de verilmiştir.

Tablo 2.1: Denetimli ve Denetimsiz Öğrenme

	Denetimli Öğrenme	Denetimsiz Öğrenme
Veri Tipi	Etiketli veriler	Etiketsiz veriler
Karmaşıklık	Az karmaşık	Daha fazla karmaşık
Analiz	Çevrimdışı analiz	Gerçek zamanlı analiz
Güvenirlilik	Doğru sonuçlar vermektedir	Orta derecede güvenilir olmasıdır.
Uygulama	Regresyon ve sınıflandırma problemleri	Kümeleme ve ilişkilendirme problemleri

2.4.1.1. Denetimli Öğrenme

Denetimli öğrenme, makine öğrenimi için temel bir yöntemdir. Model, eğitim verileri üzerinden öğrenir ve bu öğrenmeyi kullanarak belirli görevleri yerine getirebilir. Sınıflandırma ve regresyon gibi görevleri içeren denetimli öğrenme, etiketlenmiş veri setleri ile çalışır. Bu yöntem, nesne tanıma, spam filtreleme gibi birçok uygulamada kullanılır, çünkü etiketlenmiş veri setleri algoritmanın doğru çıktıyı öğrenmesine yardımcı olur, bu da yeni verilere uygulandığında doğru sonuçlar elde edilmesini sağlar (Brown, 2023).

Denetimli öğrenme algoritmaları, çeşitli görevler için kullanılır:

- Verileri iki kategoriye ayıran **ikili sınıflandırma**.
- İkiden fazla yanıt türü arasında seçim yapman **çok sınıflı sınıflandırma**.
- Daha doğru bir tahmin üretmek için birden fazla makine öğrenimi modelinin tahminlerini birleştiren **topluluk**.
- Veri içindeki ilişkilere dayalı olarak sürekli değerleri tahmin eden **regresyon modellemesidir**.

2.4.1.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, bir makine öğrenimi türüdür ve genellikle etiketlenmemiş veri setlerinde desenleri ve yapıları keşfetmeyi amaçlar. Bu yaklaşım, verilerde önceden belirlenmiş hedef etiketler olmaksızın, veri setindeki gizli yapıları ve ilişkileri anlamaya çalışır. Denetimsiz öğrenme algoritmaları, verilerdeki desenleri belirleme ve bu desenlere dayalı olarak veri setini anlama yeteneği geliştirmeye odaklanır. Kümeleme (clustering) ve boyut azaltma (dimensionality reduction) gibi teknikleri içeren denetimsiz öğrenme, veri setinde benzer özelliklere sahip örnekleri grupta, veri setini daha az boyutta temsil etme gibi görevleri gerçekleştirebilir. Bu tür yöntemler, genellikle veri madenciliği, desen tanıma gibi uygulamalarda kullanılır (Brown, 2023).

Denetimsiz öğrenme algoritmaların görevleri şu şekildedir:

- **Kümeleme:** Veri kümesinin benzerliğine dayalı gruplara ayrılmasıdır.
- **Anomali tespiti:** Kümedeki olağandışı veri noktalarının belirlenmesidir.

- **Birliktelik kuralı:** Birliktelik kuralı madenciliği kullanılarak bir veri kümesinde sıklıkla bir arada bulunan öge kümelerinin keşfedilmesidir.
- **Boyutsal küçülme:** Veri setindeki değişken sayısını azaltmaktır.

2.4.2. Derin Öğrenme

Derin öğrenme, yapay zekâ (AI) alanında önemli bir rol oynayan ve insan beyninden esinlenerek geliştirilen bir öğrenme yöntemidir. Bu yöntem, bilgisayar sistemlerine büyük miktarda veri üzerinden öğrenme yeteneği kazandırmak amacıyla tasarlanmıştır. Derin öğrenme, özellikle yapay sinir ağları kullanılarak gerçekleştirilen bir tür makine öğrenimi (ML) metodudur. Yapay sinir ağları, insan beyninin nöron ağlarına benzer bir yapıya sahip olan algoritmaları içerir. Bu ağlar, katmanlar halinde düzenlenmiş nöronlardan oluşur ve her katman, belirli bir türde işlemleri gerçekleştirmek için tasarlanmıştır. Derin öğrenme, metinler, sesler, resimler ve diğer karmaşık veri türlerini işlemek ve anlamak için kullanılır. Bu teknik, özellikle büyük veri setleri üzerinde çalışarak karmaşık modelleri öğrenebilir ve bu modelleri kullanarak öngörü ve tahminlerde bulunabilir. Derin öğrenme modelleri, daha önceki geleneksel tekniklerden daha iyi performans gösterme eğilimindedir, çünkü bu modeller, genellikle otomatik özellik öğrenimi yetenekleri sayesinde karmaşık ilişkileri tanımlayabilir. Son zamanlarda, derin öğrenme yöntemlerine olan ilgi, çeşitli görevlerde daha iyi performans sergilemeleri ve farklı veri kaynaklarından elde edilen başarı hikayeleri nedeniyle büyük ölçüde artmıştır. Bu, tıbbi teşhislerden otomotiv sektöründeki sürüş asistanlığına kadar birçok alanda uygulama potansiyeline işaret eder (LeCun, vd., 2015).

Sinir ağlarının ilk gelişimini, insan beynine benzeyen bir sistem oluşturma tutkusu sağlamıştır. Beynin nasıl karmaşık modeller üretebildiğini anlamaya McCulloch ve Pitts, 1943'te nöron adını verdikleri temel hücrelerle birbirine bağlı bir model geliştirerek, yapay sinir ağlarının temelini atmışlardır. Bu model, McCulloch-Pitts (MCP) nöron modeli olarak adlandırılmıştır ve yapay sinir ağlarının geliştirilmesine büyük katkı sağlamıştır. LeCun tarafından geliştirilen LeNet (1990) ve Hochreiter (1997) tarafından geliştirilen Uzun Kısa Süreli Bellek gibi önemli modeller, derin öğrenme alanında çığır açan çalışmalar arasında yer almaktadır. Bu modeller, derin öğrenme çağını başlatan ve çeşitli görevlerde önemli başarılar elde edilen önemli gelişmelerdir., Günümüzün "derin öğrenme çağına" öncülük eden, alandaki bir dizi önemli katkı Tablo 2.2'de sunulmaktadır (Voulodimos, vd., 2018).

Tablo 2.2: Bilgisayarlı Görü için Derin Öğrenme Çağına Giden Önemli Katkıları

Katkı	Katılımcı, yıl
Yapay Sinir Ağlarının atası sayılan MCP modeli	(McCulloch ve Pitts , 1943)
Hebbian öğrenme kuralı	(Hebb, 1949)
İlk algılayıcı	(Rosenblatt, 1958)
Geri yayılım	(Werbos, 1974)
Evrişimli Sinir Ağının atası olarak kabul edilen Neocognitron	(Fukushima, 1980)
Boltzman Makinesi	(Ackley, vd., 1985)
Kısıtlanmış Boltzmann Makinesi (başlangıçta Harmonium olarak biliniyordu)	(Smolensky, 1986)
Otomatik kodlayıcılar	(Rumelhart, vd., 1986)
LeNet, Evrişimli Sinir Ağları çağını başlatıyor	(LeCun, vd., 1990)
LSTM	(Hochreiter ve Schmidhuber, 1997)
Derin İnanç Ağı, “derin öğrenme çağını” başlatıyor	(Hinton ve Salakhutdinov, 2006)
Derin Boltzmann Makinesi	(Salakhutdinov ve Hinton, 2009)
AlexNet, ImageNet sınıflandırması CNN çağını başlatıyor	(Krizhevsky, vd., 2012)

Kaynak: Voulodimos, 2018

Derin öğrenmedeki devasa artışa katkıda bulunan önemli faktörlerden biri, büyük, yüksek kaliteli ve halka açık etiketli veri kümelerinin ortaya çıkışıdır. Derin öğrenme algoritmaları, genellikle büyük veri setleri üzerinde eğitildiğinde daha iyi performans gösterir ve karmaşık modelleri öğrenme kapasitelerini artırabilir. Ayrıca, CPU (Merkezi İşlem Birimi) tabanlı sistemlerden GPU (Grafik İşlem Birimi) tabanlı sistemlere geçiş, derin öğrenme alanında önemli bir dönüm noktasıdır. GPU'lar, paralel hesaplama yetenekleri sayesinde büyük ölçekli matris çarpımları ve diğer derin öğrenme operasyonları için oldukça hızlıdır. Bu, özellikle derin sinir ağları gibi büyük ve karmaşık modelleri eğitmek için gereken hesaplama gücünü artırmıştır. GPU'lar, derin öğrenme model eğitim sürelerini önemli ölçüde azaltarak araştırmacılara ve uygulayıcılara daha hızlı sonuçlar elde etme olanağı tanımıştır. Bu faktörlerin bir araya gelmesi, derin öğrenme modellerinin daha geniş bir uygulama yelpazesinde kullanılmasına ve çeşitli endüstrilerdeki problemlerin çözümüne katkıda bulunmasına olanak sağlamıştır. Daha hızlı prototip oluşturmaya olanak tanıyan TensorFlow (TensorFlow, 2023) ve Theano (Bastien, vd., 2012) gibi güçlü çerçeveler ortaya çıkmıştır.

Derin öğrenme; nesne algılama (Ouyang, vd., 2017), hareket izleme (Doulamis ve Voulodimos, 2016), eylem tanıma (Cao ve Nevatia, 2016), insan poz tahmini (Toshev ve Szegedy, 2014) ve anlamsal bölümlendirme (Long, vd., 2015) gibi çeşitli bilgisayarlı görme problemlerinde büyük ilerlemelere yol açmıştır.


2.4.3. Derin Öğrenme Yapıları

Makine öğrenimi modeli olan derin öğrenme, genel anlamda beynimize dayanmaktadır. Yapay sinir ağları 1950'lerden bu yana var ancak grafik işlem birimleri (GPU) gibi donanımlar, cuDNN, TensorFlow, Torch, Caffe, Theano, Deeplearning4j vb. yazılımlar ve yeni eğitim yöntemlerindeki son gelişmeler yapay sinir ağlarının eğitimini hızlandırdı (Chavan, vd., 2017).

2.4.3.1. Evrişimsel Sinir Ağları

Derin öğrenmenin bir alt dalı olan Evrişimli Sinir Ağları (CNN), görsel bilginin analiz edilmesinde ve önerilen modellerden ilham alarak kullanılmaktadır. Genellikle resim, video tanıma, resim sınıflandırma ve tıbbi görüntü analizi gibi kullanım alanları yaygındır. Matematik işlemi kullanan evrişimsel sinir ağı, sinir ağının konvolüsyon (evrişim) adı verilen lineer (doğrusal) işlem türüdür. Yann Le Cun ve arkadaşları, çeşitli örüntü tanıma görevlerinde iyi sonuçlar elde ederek evrişimli sinir ağlarını tasarlamışlardır (LeCun, vd., 1998; LeCun, vd., 1989; Tygert, vd., 2016). Evrişimli sinir ağları (CNN) mimarisi Şekil 5'te gösterilmiştir (LeCun, vd., 1998).

Şekil 2.5: Evrişimli Sinir Ağının Mimarisi (CNN)




Kaynak: LeCun, vd., 1998

Evrişim katmanlarında, bir CNN, çeşitli çekirdekler ve özellik haritaları kullanarak tüm görüntüyü evriştirmek suretiyle çeşitli özellik haritaları üretir. Bu evrişim

işlemleri, hızlı öğrenme sürelerine ulaşmak amacıyla birçok çalışma tarafından önerilmiştir (Oquab, vd., 2015). Bu katman, kenar ve köşe tespiti, nesne bulma gibi görevlerde giriş görüntüsünden öznitelik çıkarımı yapar. Görüntüler, matrislerle ifade edilir ve işlemler bu matrisler üzerinde gerçekleştirilir. Matris içindeki değerler, görüntüye ait piksel değerleridir. Bu katman, çeşitli filtreler kullanarak orijinal görüntü üzerinden özellikler belirleme görevini üstlenir ve bu sayede görüntü özelliklerini belirlemekten sorumludur. CNN’de öğrenme işlemi gerçekleştirilebilmesi için görüntüler katmanlardan geçirilmektedir. CNN, her katmanı farklı bir rol oynar ve bu katmanlar Şekil 2.6’da gösterilmiştir.

Şekil 2.6: Evrişimli Sinir Ağları (CNN) Katmanları



2.4.3.2. Sınırlı Boltzmann Makineleri

Sınırlı Boltzmann Makineleri (Restricted Boltzmann Machines - RBM), ilk olarak 1986’da Harmonium tarafından önerilmiş ancak hızlı bir öğrenme algoritmasıyla Geoffrey Hinton ve ekibi tarafından daha sonra öne çıkarılmıştır (Hinton ve Salakhutdinov, 2006). RBM, yapay sinir ağı olarak girdi seti üzerinde olasılık dağılımını öğrenebilme yeteneğine sahiptir. Bu makineler, görünür ve gizli olarak iki bileşenli grafiklerden oluşan bir tür bozaltman makinasıdır. RBM’ler, boyut indirgeme, sınıflandırma ve özellik öğrenimi gibi farklı alanlarda kullanışlı algoritmalar olarak bilinir (Hinton ve Salakhutdinov, 2006; Larochelle, 2008; Coates, vd., 2011).

2.4.3.3. Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN), 1997 yılında Hochreiter ve Schmidhuber tarafından uzun kısa vadeli bellek gibi çığır açan gelişmelerle

tanıtıldı. (Hochreiter ve Schmidhuber, 1997). RNN, yapay sinir ağı olarak sıralı bilgileri kullanma yeteneği ile karakterizedir. Graves ve Jaitly'nin çalışması, RNN temelli bir konuşma tanıma sistemi geliştirerek ses verilerini doğrudan metne dönüştürmeyi başarmıştır (Graves ve Jaitly, 2014).

2.4.3.4. Derin İnanç Ağları

Derin İnanç Ağları (DBN), Geoffrey Hinton tarafından geliştirilmiştir derin öğrenme modellerinden biridir ve genellikle öznitelik öğrenme ve sınıflandırma görevlerinde kullanılır. Katmanlı bir yapıya sahip olan bu ağlar, hiyerarşik özellikleri öğrenme yeteneğine odaklanır. Eğitim sürecinde ağırlıklar belirli bir görevdeki performansı artırmak için ayarlanır. Bu ağlar, unsupervised learning aşamasıyla başlar ve ardından supervised learning aşamasına geçer. Derin İnanç Ağları, özellikle büyük veri setlerinde, örneğin görüntü tanıma ve doğal dil işleme alanlarında, yaygın olarak kullanılır (Hinton, vd., 2006). DBN'ler, gözlemlenebilir veriler ve etiketler üzerinde ortak bir olasılık dağılımı sağlayan olasılıksal üretken modellerdir. Hinton ve Salakhutdinov tarafından önerilen şekilde, RBM'lerin istiflenmesiyle eğitilirler.

2.4.3.5. Derin Oto Kodlayıcılar

Oto-kodlayıcılar (Autoencoders - AE), İleri beslemeli sinir ağı olan Otomatik Kodlayıcı (AE), esasen girdi verisinin öne çıkan özelliklerini sıkıştırarak öğrenmeye odaklanır. AE, veriyi daha düşük boyutlu bir temsil ile ifade ederek önemli özellikleri çıkarmayı amaçlar. Bu şekilde, gürültü azaltma, boyut indirgeme ve öznitelik öğrenme gibi uygulamalarda kullanılabilir. AE, genellikle veri setlerindeki karmaşıklığı azaltmak ve anlamlı özellikleri belirginleştirmek için tercih edilir (Bengio, 2009; Lioui, vd., 2014).

2.4.3.6. Destek Vektör Makineleri

Destek Vektör Makineleri (SVM), veri noktalarını belirgin bir şekilde sınıflandırmak için kullanılan bir modeldir. Temel amacı, sınıflar arasında maksimum bir kenar boşluğunu içeren bir düzlemi bulmaktır. 1990-2000 yılları arasında destek vektör makineleri, problemle özdeşleşmiş ve elle hazırlanmış özellikleri kullanan daha basit modeller olarak oldukça tercih edilmiştir.




ÜÇÜNCÜ BÖLÜM
MATERYAL VE METOT

3.1. VERİ SETİ

Tezin bu bölümünde böbrek hastalığının tespit edilmesi ve sınıflandırılması amacıyla kullanılan veri seti, Cyst (Kist), Normal, Stone (Taş) ve Tumor (Tümör) olmak üzere dört farklı sınıfa ayrılmıştır. Toplamda 12,446 Bilgisayarlı Tomografi (BT) görüntüsü içeren bu veri seti, çeşitli böbrek sağlığı durumlarını temsil eden bu dört sınıfı kapsamaktadır. Kaggle platformundan elde edilmiş ve CT Kidney Dataset adını taşımaktadır (CT Kidney Dataset, 2023). Bu veri setinden alınan örnek görüntüler, Şekil 3.1'de ayrıntılı olarak gösterilmiştir.


Şekil 3.1: Böbrek Hastalığı için Kullanılan Verilerden Görüntüler



Kaynak: <https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone>, 2023

Böbrek hastalığı için kullanılan veri setinde Cyst (kist), Normal, Stone (taş) ve Tumor (tümör) toplam dört sınıftan oluşmaktadır. Bu sınıflara ait örnek sayıları Şekil 3.2’de gösterilmiştir. Bu grafikte 3709’u kist, 5077’si normal, 1377’si taş ve 2283’ü tümör olmak üzere toplam 12446 görüntü ele alınmıştır.

Şekil 3.2: Kullanılan Verilerin Sınıflara Göre Dağılımları



Çalışmada verilerin %70’i eğitim, %15’i test ve %15’i doğrulama olarak ayrılmıştır. Tüm sınıflara ait eğitim, test ve doğrulama verileri Tablo 3.1’de gösterilmiştir.

Tablo 3.1: Tüm Sınıflara Ait Eğitim, Test ve Doğrulama Verileri

Total Data	12446
Class 0 (Cyst)	3709 (% 29.8007392)
Class 1 (Normal)	5077 (% 40.7922224)
Class 2 (Stone)	1377 (% 11.0637956)
Class 3 (Tumor)	2283 (% 18.3432428)
Train Data	8712 (% 69.9983931)
Class 0 (Cyst)	2596 (% 29.7979798)
Class 1 (Normal)	3554 (% 40.7943067)
Class 2 (Stone)	964 (% 11.0651974)
Class 3 (Tumor)	1598 (% 18.3425161)
Validation Data	1867 (% 15.0008035)
Class 0 (Cyst)	557 (% 29.8339582)
Class 1 (Normal)	761 (% 40.7605785)
Class 2 (Stone)	206 (% 11.033744)
Class 3 (Tumor)	343 (% 18.3717193)

Tablo 3.1: (devam) Tüm Sınıflara Ait Eğitim, Test ve Doğrulama Verileri

Test Data	1867 (% 15.0008035)
Class 0 (Cyst)	556 (% 29.7803964)
Class 1 (Normal)	762 (% 40.8141403)
Class 2 (Stone)	207 (% 11.0873058)
Class 3 (Tumor)	342(% 18.3181575)

Cyst (kist), Normal, Stone (taş) ve Tumor (tümör)

3.2. GELİŞTİRME ORTAMI VE KULLANILAN PLATFORM

Yapay zekanın bir alt dalı olan derin öğrenmenin hızla gelişmesi, sürücüsüz arabalardan kanser tespitine kadar birçok alanda kullanılan bu teknoloji olmuş, günlük hayatımızı önemli ölçüde etkilemiştir. Bu bağlamda, derin öğrenme uygulamalarının geliştirilmesinde tercih edilen programlama dili Python ve bu dilin kullanılmasını sağlayan Jupyter Notebook üzerinde geliştirilmiştir. Python'un nesne tabanlı sözdizimi, yazılım geliştirme süreçlerini kolaylaştırarak, veri analizi ve yapay zekâ projelerini içeren geniş bir alanın üst düzey programlama dili olarak öne çıkmaktadır. Sürücüsüz arabalar ve görüntü işleme gibi yapay zekâ projelerinde etkili bir şekilde kullanılabilen Python, bu alanda çeşitli kütüphanelerle birlikte işlevsel çözümler sunmaktadır. Çalışmada kullanılan Numpy, Matplotlib, Tensorflow ve Keras gibi kütüphaneler, derin öğrenme modellerinin geliştirilmesi ve analiz edilmesinde kritik bir rol oynamaktadır. Bu araçlar, geliştiricilere güçlü bir altyapı sağlayarak projelerini daha etkili bir şekilde yönetmelerine olanak tanımaktadır. Açık kaynak kodlu Jupyter Notebook'un ise farklı yazılım dillerini bir arada çalıştırabilme yeteneği, geliştiricilere esnek bir çalışma ortamı sunmaktadır. Python kodlarının anlık olarak çalıştırılması ve çıktıların görüntülenmesi, projelerin hızlı bir şekilde geliştirilmesini desteklemektedir. Derin öğrenme alanındaki bu gelişmeler, günlük yaşantımıza daha akıllı ve yenilikçi çözümlerle entegre olma yönünde önemli bir adımı temsil etmektedir (Rogel-Salazar, 2023).

Derin öğrenme metotlarında geliştirilen birçok kütüphane vardır. Python dilinde oluşan kütüphanelerin bazıları Tablo 3.2.'de verilmiştir.


Tablo 3.2. En Popüler Python Kütüphaneleri

Kütüphane	Yazıldığı Dil	Geliştiriciler	Özellikleri
Numpy (Numpy, 2023)	Python	Jim Hugunin	Python'da bilimsel hesaplama ve veri işleme için temel bir kütüphanedir. Çok boyutlu diziler ve matrisler üzerinde yüksek performanslı işlemler yapma imkânı sunar.
Matplotlib (Matplotlib, 2023)	Python	John D. Hunter	Verileri farklı grafiklerde göstererek görselleştirir.
TensorFlow (TensorFlow, 2023)	Python	Google Brain DistBelief	Açık kaynaklı bir yazılımdır. CPU ile paralel çalışması, hızlı derleme yapması, model oluşturup eğitme imkânı bulunmasıdır.
Keras (Keras, 2023)	Python	François Chollet	Açık kaynaklı bir yazılımdır. Derin sinir ağı kitaplığıdır. Veri işleme, görselleştirme ve daha birçok konuda destek sağlamaktadır.
Pandas (Pandas, 2023)	Python	Wes McKinney	Verileri okumak, yazmak, birleştirmek, filtrelemek ve gruplandırmak için kullanılmaktadır. Veri analizi, veri bilimi ve ML görevleri için kullanılmaktadır.

3.3. KULLANILAN MODELLERDE YAPILAN İŞLEMLER VE YÖNTEMLER

Kullanılan böbrek hastalığı veri seti, işlem öncesinde kategorik hale getirilmiş ve veriler normalize edilmiştir. Model oluşturulurken, belirlenen ağ yapısı dikkate alınarak başlangıç değerleri atandı ve katmanlar ile parametreler titizlikle seçildi. Ardından, farklı epok değerleri kullanılarak eğitilmiş olan modeller, çeşitli iterasyonlarla eğitildi ve test edildi. Bu süreç sonucunda elde edilen sınıflandırma sonuçları detaylı bir şekilde analiz edildi ve modelin performansı karşılaştırıldı. Çalışmaya ait akış diyagramı Şekil 3.3'te verilmiştir. Bu çalışmada ANN, Classic CNN, VGG16, VGG19, ALEXNET ve önerilen Poly-CNN ağları kullanılmıştır.

Şekil 3.3: Çalışmaya Ait Akış Diyagramı



Çalışma kapsamındaki modellerde kullanılan katmanların işlevleri şu şekildedir:

Input Layer (Giriş Katmanı): Bu katman, isminden de anlaşılacağı gibi, ESA'nın ilk tabakasını oluşturur. Burada, veri ham haliyle ağı iletilir. Bu katmandaki veri boyutunun büyük önemi vardır çünkü modelin başarısını etkiler. Yüksek giriş görüntü boyutu seçimi, yüksek bellek talebi, uzun eğitim süresi ve görüntü başına düşen test süresi gibi zorlukları beraberinde getirebilir. Ancak bu durum aynı zamanda ağın başarısını artırabilir. Diğer yandan, düşük giriş görüntü boyutu seçimi bellek ihtiyacını azaltır ve eğitim süresini kısaltır, fakat ağın derinliğini azaltarak performansı olumsuz yönde etkileyebilir. Görüntü analizi için uygun bir giriş boyutunu seçmek, ağ derinliği, donanım maliyeti ve performans arasında denge kurmayı gerektirir (Amidi, 2023).

Rescaling Layer (Katmanın Yeniden Ölçeklendirilmesi): Giriş verilerini belirli bir aralığa yeniden ölçeklendiren bir ön işleme katmanını ifade eder. Bu katman, özellikle giriş verilerinin belirli bir aralıkta (örneğin, $[0, 1]$ veya $[-1, 1]$) olmasını sağlamak veya normalize etmek amacıyla kullanılabilir. Yeniden ölçeklendirme işlemi,

modelin eğitimi sırasında daha iyi performans elde etmek veya giriş verilerini daha iyi işlemek için tercih edilebilir (Amidi, 2023).

Convolution Layer (Evrişim Katmanı): Evrişimli Sinir Ağları'nın (ESA) temel bileşenlerinden biridir ve özellik çıkarımı için kritik bir rol oynar. Bu katman, özellikle görüntü işleme ve tanıma görevlerinde kullanılan filtreleme işlemlerini gerçekleştirir. Bu katmandaki filtreler, adım değerine göre giriş görüntüleri üzerinde kaydırılır. Özellikle x ve y eksenleri üzerinde simetri uygulanarak veya uygulanmadan (çapraz korelasyon) gerçekleştirilebilirler. Her bir aşamada, giriş görüntüsündeki piksel değerleri ile filtre matrisi arasında noktasal çarpım gerçekleştirilir, bu değerler toplanır ve çıkış matrisine yazılır. Sonrasında, her bir adımda bir eğilim (bias) değeri eklenir. Bu eğilim değeri, filtrelerin ve giriş değerlerinin çarpımlarından elde edilen toplamlara eklenir. Bu noktada, aktivasyon fonksiyonuna geçilmeden önce çıkış matrisi oluşturulmuş olur (Kızrak ve Bolat, 2018). Ancak, konvolüsyon işlemi esnasında giriş matrisi ile çıkış matrisi arasında boyut farklılıkları ortaya çıkabilir. Örneğin, giriş matrisinin boyutu $(m \times n) = (32 \times 32)$, filtre boyutu $(p \times q) = (3 \times 3)$ ve adım kaydırma değeri (stride = s) kullanılıyorsa, çıkış matrisinin boyutu aşağıdaki formüle göre hesaplanır.:

$$\left(\frac{n-f}{s} + 1\right) \times \left(\frac{n-f}{s} + 1\right)$$

Çıktı matrisinin boyutunu küçültmek istenmediği durumlarda, giriş matrisine "dolgu" adı verilen bir piksel ekleme yöntemi kullanılabilir. Bu strateji, çıktı matrisinin boyutunu koruyarak, özellikle kenar piksellerin işlenmesi sırasında bilgi kaybını önlemeye yardımcı olur. Dolgu eklemek için Denklem 2'de görülen hesaplamalar kullanılarak çıktı boyutu belirlenir. Bu, özellikle konvolüsyon işlemlerinde matris boyutlarını korumak ve modelin performansını artırmak için önemlidir. Bu dolgu işlemi, konvolüsyon işlemlerindeki kenar etkilerini dengeleyerek çıktı matrisinin boyutunu korumak amacıyla uygulanır. Dolgu eklenmesi, özellikle sınır piksellerinin işlenmesi sırasında bilgi kaybını önler ve modelin daha tutarlı ve etkili özellik çıkarımı yapmasına katkıda bulunur (Amidi, 2023).

$$\left(\frac{n+2p-f}{s+1}\right) \times \left(\frac{n+2p-f}{s+1}\right)$$

MaxPooling Layer (Maksimum Havuzlama Katmanı): Havuzlama Katmanı (Pooling Layer), özellikle görüntü sınıflandırma veya bilgisayarlı görme görevlerinde kullanılan bir sinir ağı katmanıdır, özellikle evrişimli sinir ağları (CNN'ler)

gibi modellerde. Bu katman, genellikle evrişim katmanını takiben gelir ve özellik haritasının uzamsal boyutlarını azaltmak amacıyla kullanılır. Ana hedefi, önemli bilgileri korurken uzamsal boyutları küçültmektir. Çünkü büyük boyutlar, modelin hesaplama karmaşıklığını artırabilir ve işlem sürelerini uzatabilir. Havuzlama katmanı, bu tür sorunları çözmek ve işlem hızını artırmak için önemli bir rol oynar. Tipik olarak, özellik haritasındaki belirli bir bölgeyi seçer ve bu bölgedeki değerler arasından bir ölçüm alır. Maksimum havuzlama ve ortalama havuzlama gibi farklı türleri bulunur. Maksimum havuzlama, seçilen bölgedeki en büyük değeri alırken, ortalama havuzlama bu bölgedeki değerlerin ortalamasını alır. Havuzlama katmanı, özellik haritasının boyutunu küçülterek hesaplama verimliliğini artırır. Maksimum veya ortalama değerleri kullanarak önemli özellikleri korur. Bu sayede, özellik haritasının boyutu azalırken önemli bilgilerin korunması ve hesaplama verimliliğinin artırılması sağlanır. Ayrıca, havuzlama katmanı genellikle modelin öğrenme yeteneğini artırır ve ağın genel performansını yükseltir. Havuzlama katmanının bu işlevleri, derin öğrenme modellerinin daha etkin ve verimli olmasına katkıda bulunur. (Amidi, 2023).


Şekil 3.4: Havuzlama (Polling) İşlemi Gösterimi



Flatten Layer (Düzleştirici Katmanı): Düzleştirici katman, genellikle evrişimli sinir ağları (CNN'ler) gibi modellerde kullanılan bir katmandır. Bu katman, çok boyutlu girdiyi (örneğin, evrişim katmanının çıkardığı özellik haritasını) tek boyutlu hale getirmek için kullanılır. Yani, girdi verisini düzleştirerek, tam bağlı katmanlara geçiş için uygun bir formata getirir. Evrişim katmanları genellikle özellik haritasını üretir, ancak tam bağlı katmanlar tek boyutlu vektörlerle çalışır. Bu nedenle, evrişim katmanından gelen çıkış verisi, düzleştirici katman tarafından işlenerek tek boyutlu bir vektöre dönüştürülür. Bu dönüşüm, evrişim katmanlarından çıkan özellikleri daha sonra gelen tam bağlı katmanlara iletmek için gereklidir. Örneğin, bir evrişim katmanı 3x3 boyutunda bir özellik haritası üretebilir. Flatten Layer, bu 3x3 matrisi 9 elemanlı bir tek boyutlu vektöre dönüştürerek, bu özellikleri içeren bir girişi tam bağlı bir katmana iletebilir.


Flatten Layer'ın temel görevi, evrişimli sinir ağlarının evrişim katmanlarından elde ettiği özellikleri, sıralı bir şekilde gelen tam bağlı katmanlara aktarmaktır. Bu sayede, model daha karmaşık özellikleri anlamak ve genel olarak daha yüksek düzeyde öğrenmeler yapmak için yetenekli hale gelir. Örnek işlem Şekil 3.5'te verilmiştir (Amidi, 2023).

Şekil 3.5: Düzleştirme (Flatting) İşlemi Gösterimi



Dense Layer (Yoğunluk Katmanı): Dense (tam bağlı) katmanları, Convolutional Neural Network (CNN) yapılarının kritik bir bileşenidir ve genellikle ağın sonunda yer alır. Şekil 3.6'da bu katmanlar, evrişim ve havuzlama katmanlarından gelen özellik haritalarını alarak bunları sıralı bir vektör formuna dönüştürerek ağın nihai çıkışını oluşturur. Her bir nöron, ağırlıklarla çarpılarak bias terimi eklenir ve bu parametreler eğitim süreci boyunca veri setine uyum sağlamak üzere öğrenilir. Dense katmanları, sınıflandırma veya regresyon gibi görevlerde yaygın olarak kullanılır ve genellikle softmax aktivasyon fonksiyonu ile sonlanarak çıkışı olasılık dağılımına dönüştürerek sınıflandırma problemleri için uygun bir formda sunarlar. Ayrıca, içerdikleri ağırlıklar evrişim ve havuzlama katmanlarından gelen özelliklerin öğrenilmiş temsillerini içerir, bu da ağın genel veri setine özgü görevleri daha etkili bir şekilde öğrenmesini sağlar. Bu katmanda relu, sigmoid ve tanh gibi çeşitli aktivasyon fonksiyonları kullanılmaktadır (Amidi, 2023).

Şekil 3.6: Tam Bağlı (Dense) ve Çıkış (Output) Katmanı Gösterimi



Output Layer (Çıkış Katmanı): Output katmanı, Convolutional Neural Network (CNN) yapısındaki final adımdır ve ağıın öğrenme sürecinde elde ettiği sonuçları sunar. Sınıflandırma görevinde kullanıldığında, bu katman girdi verisini farklı sınıflar arasındaki olasılıklara dönüştürmek için softmax aktivasyon fonksiyonunu kullanır. Böylece, her bir sınıf için tahmini olasılık değerleri elde edilir ve en yüksek olasılığa sahip sınıf, modelin tahmini olarak seçilir, bu da görüntünün ağ tarafından tanımlandığı sınıfı belirler. Output katmanı, ağıın genel başarısını belirleyen önemli bir bileşen olup, belirli görevlere uygun olarak tasarlanır. Şekil 3.6'da çıkış katmanı gösterilmiştir (Amidi, 2023).


Loss Functions (Kayıp Fonksiyonları): Convolutional Neural Networks (CNNs) veya derin öğrenme modelleri, genellikle sınıflandırma görevlerinde kullanıldıkları için çeşitli kayıp (loss) fonksiyonları ile eğitilirler. Bu kayıp fonksiyonları, modelin gerçek ve tahmin edilen çıkışları arasındaki farkı ölçerek ve bu farkı minimize ederek modelin doğru öğrenmesini sağlar. İki kategorili sınıflandırma görevlerinde sıkça kullanılan bir hata fonksiyonu olan "Binary Crossentropy" yaygın olarak tercih edilir. Bu fonksiyon, sigmoid aktivasyon fonksiyonu ile birlikte kullanılarak, iki sınıf arasındaki farkı ölçer. Çoklu sınıflı sınıflandırma görevlerinde ise "Categorical Crossentropy" sıkça tercih edilir. Bu fonksiyon, softmax aktivasyon fonksiyonu ile birlikte kullanılarak, birden fazla sınıf arasındaki olasılık dağılımını ölçer. Ayrıca, çoklu sınıflı sınıflandırma görevlerinde kullanılabilen bir diğer kayıp fonksiyonu "Sparse Categorical Crossentropy"dır, bu fonksiyon softmax aktivasyon fonksiyonu ile birlikte çalışırken etiketlerin tamsayı olarak temsil edildiği durumlar için uygundur. Regresyon problemlerinde yaygın olarak kullanılan bir hata fonksiyonu "Mean Squared Error (MSE)"dir. Bu fonksiyon, gerçek ve tahmin edilen değerler arasındaki ortalama karesel farkı minimize etmeye yöneliktir. Bu kayıp fonksiyonları, modelin belirli bir görevi doğru bir şekilde öğrenmesine ve sınıflandırma yeteneğini artırmasına yardımcı olur. Bu tez kapsamında kayıp fonksiyonu olarak ise "Categorical Crossentropy" kullanılmıştır (Amidi, 2023).

3.3.1. Yapay Sinir Ağları (Artificial Neural Network- ANN)

Tezin bu aşamasında böbrek hastalığı için kullanılan ANN modelindeki parametreler ve katmanlar Şekil 3.7'de gösterilmiştir. Bu modelde, öncelikle giriş verilerini (xTrain) 0 ile 1 arasında ölçekleyen bir ön işleme katmanı ile başlar. Bu, verilerin ölçeklendirilmesi sayesinde daha iyi eğitim performansı elde etmeyi amaçlar.

Daha sonra, düzleştirme katmanı gelir, bu katman çok boyutlu girişi tek boyutlu bir vektöre dönüştürür. Modelin ardından üç tam bağlantılı katman (Dense) gelir. İlk katman 16 nöron içerir ve ReLU aktivasyon fonksiyonu kullanır. Ardından bir normalleştirme katmanı (BatchNormalization) gelir, bu katman girişleri normalize ederek modelin daha hızlı ve kararlı öğrenmesine yardımcı olur. Daha sonra bir dropout katmanı gelir, bu katman eğitim sırasında rastgele belirtilen oranda nöronları devre dışı bırakarak aşırı uyumu azaltır. Benzer şekilde, ikinci bir tam bağlantılı katman (Dense2) gelir, ardından bir normalleştirme katmanı (Norm2) ve bir dropout katmanı (Dropout2) yer alır. Son olarak, çıkış katmanı (Dense3) gelir ve softmax aktivasyon fonksiyonu kullanılarak çok sınıflı sınıflandırma problemleri için çıkışları üretir. Model, 'adam' optimizasyon algoritması ve 'categorical_crossentropy' kayıp fonksiyonu ile derlenir. Optimizasyon algoritması, modelin ağırlıklarını güncellemek için kullanılırken, kayıp fonksiyonu eğitim sırasında modelin performansını değerlendirir. Eğitim süreci 15 epok boyunca gerçekleştirilir ve her biri 200 örnek içeren mini-batch'lerle yapılır. Ayrıca, eğitim sırasında modelin performansı doğrulama verileri üzerinde izlenir. Toplamda, model 1,080,484 parametreye sahiptir; bu parametrelerin 1,080,420'si eğitilebilirken, 64'ü eğitilemeyen parametrelerdir. Çalışmaya ait Yapay Sinir Ağı (Artificial Neural Network-ANN) modelinin yapısı Şekil 3.7'de verilmiştir.

Şekil 3.7: Yapay Sinir Ağları (Artificial Neural Network- ANN) Modelinin Yapısı



Böbrek hastalığı veri seti için ANN de kullandığımız katmanlar ve kullanılan parametreler Tablo 3.3'te verilmiştir.

Tablo 3.3: ANN Modelinde Kullanılan Katmanlar ve Parametre Bilgileri


Layer (type)	Output shape	Param #
Rescale 1 (Rescaling)	(none, 150, 150, 3)	0
Flatten 1 (Flatten)	(none, 67500)	0
Dense 1 (dense)	(none, 16)	1080016
Norm 1 (batch normalization)	(none, 16)	64
Dropout 1 (dropout)	(none, 16)	0
Dense 2 (dense)	(none, 16)	272
Norm 2 (batch normalization)	(none, 16)	64
Dropout 2 (dropout)	(none, 16)	0
Dense 3 (dense)	(none, 4)	68
Total params : 1,080,484		
Trainable params: 1,080,420		
Non-trainable params: 64		

3.3.2. Evrişimsel Sinir Ağları (Convolutional Neural Network – Classic CNN)

Bu modelde, öncelikle giriş verilerini 0 ile 1 arasında ölçekleyen bir ön işleme katmanıyla başlar. Bu, verilerin ölçeklendirilmesi sayesinde daha iyi eğitim performansı elde etmeyi amaçlar. Ardından, üç evrişim katmanı gelir. İlk evrişim katmanı 32 filtre kullanırken, diğer iki katman sırasıyla 64 filtre içerir. Her evrişim katmanının ardından bir maksimum havuzlama katmanı gelir. Maksimum havuzlama, özellik haritasının boyutunu azaltarak bilgi kaybını minimize eder ve önemli özellikleri vurgular. Daha sonra, özellik haritası tek boyutlu bir vektöre dönüştürülen bir düzleştirme katmanı gelir. Bu, evrişimli katmanlardan elde edilen özellikleri, tam bağlantılı katmanlara iletmek için gerekli olan düzleştirilmiş bir formata getirir. İki tam bağlantılı katman, modelin öğrenme yeteneğini artırmak için kullanılır. İlk tam bağlantılı katman 64 nöron içerir ve Rectified Linear Unit (ReLU) aktivasyon fonksiyonu kullanırken, ikinci katman sınıf sayısı kadar nöron içerir ve çıkış katmanı olarak softmax aktivasyon fonksiyonu kullanır. Softmax, çok sınıflı sınıflandırma problemlerinde çıkışları olasılık dağılımına dönüştürür. Model, 'adam' optimizasyon algoritması ve 'categorical_crossentropy' kayıp fonksiyonu ile derlenir. Bu optimizasyon algoritması, adaptif moment tahmini (Adam) kullanarak modelin parametrelerini günceller ve genellikle derin öğrenme modellerinde etkili bir şekilde çalışır. Categorical crossentropy kayıp fonksiyonu ise çok sınıflı sınıflandırma problemleri için uygundur, çünkü modelin tahminlerini gerçek etiketlerle karşılaştırarak bir hata ölçüsü sağlar. Eğitim süreci sırasında, 15 epok boyunca gerçekleştirilir. Her biri

200 örnek içeren mini-batch'ler kullanılarak gerçekleştirilen eğitim, modelin ağırlıklarını ve parametrelerini iyileştirir. Ayrıca, eğitim sırasında doğrulama verileri kullanılarak modelin performansı izlenir. Bu, modelin sınıflandırma yeteneğini değerlendirmek ve aşırı öğrenme (overfitting) durumlarını izlemek için önemlidir. Çalışmaya ait Yapay Sinir Ağı (Classic CNN) modelinin yapısı Şekil 3.8’de verilmiştir.

Şekil 3.8: Evrişimsel Sinir Ağları (Convolutional Neural Network – Classic CNN) Modelinin Yapısı



Çalışmaya ait Classic CNN modelinde kullanılan katmanlar ve parametre tablosu Tablo 3.4’te verilmiştir.

Tablo 3.4: Classic CNN Modelinde Kullanılan Katmanlar ve Parametreler


Layer (type)	Output Shape	Param #
Rescale 1 (Rescaling)	(none, 32, 32, 1)	0
conv2d (Conv2D)	(none, 30, 30, 32)	320
max_pooling2d (Max_Pooling2D)	(none, 15, 15, 32)	0
conv2d_1 (Conv2D)	(none, 13, 13, 64)	18496
max_pooling2d_1 (Max_Pooling2D)	(none, 6, 6, 64)	0
conv2d_2 (Conv2D)	(none, 4, 4, 64)	36928
flatten (Flatten)	(none, 1024)	0
Dense 1 (Dense)	(none, 64)	65600
dense (Dense)	(none, 4)	260
Total params : 121,604		
Trainable params: 121,604		
Non-trainable params: 0		

3.3.3. Derin Evrişimli Sinir Ağları (ALEXNET)

Evrişimli Sinir Ağları (CNN) mimarilerinden biri olan AlexNet temel alınarak oluşturulan model, karmaşıklığı ve derin öğrenme yeteneği ile dikkat çekmektedir. İlk katman olan Rescaling, giriş görüntülerindeki piksel değerlerini 0 ile 255 arasından, 0 ile 1 arasına ölçeklendirerek normalleştirme sağlar. Bu sayede, modelin daha hızlı ve etkili

bir şekilde öğrenmesi amaçlanır. Evrişimli Katman 1 (Conv2D), 96 adet 11x11 filtre kullanarak görüntülerdeki düşük seviyeli özellikleri vurgular. Bu katman, geniş bir alanı kapsayarak özelliklerin daha geniş bir bakış açısıyla öğrenilmesini sağlar. Ayrıca, ReLU aktivasyon fonksiyonu, pozitif özellikleri vurgular ve modelin öğrenme kapasitesini artırır. Batch Normalization 1, ağırlıkların daha hızlı öğrenilmesine yardımcı olur ve eğitim sürecini daha kararlı hale getirir. Bu sayede, ağırlıkların güncellenmesi daha tutarlı bir şekilde gerçekleşir. Max Pooling 1, 3x3 boyutunda bir havuzlama işlemi uygulayarak özellik haritasının boyutunu küçültür. Bu, modelin sınıflandırma yeteneğini artırabilir ve hesaplama maliyetini azaltabilir. Evrişimli Katman 2 (Conv2D_1), daha küçük bir filtre boyutu olan 5x5 ve 256 adet filtre ile görüntülerdeki daha karmaşık özellikleri öğrenmeye çalışır. Bu katmanın ardından gelen Batch Normalization 2, ağırlıkların normalize edilmesini sağlar. Max Pooling 2, özellik haritasını daha da küçültürerek öğrenme sürecini hızlandırır. Bu aşamada, model daha yüksek seviyeli özellikleri çıkarmaya başlar. Modelin orta kısmında, daha küçük filtre boyutları ve artan filtre sayılarına sahip üç evrişimli katman daha yer alır. Bu katmanlar, modelin görsel karmaşıklığını artırarak daha yüksek seviyeli özellikleri öğrenmesine olanak tanır. Tam bağlı katmanlar (Dense), evrişimli katmanların çıkışlarını düzleştirir ve sınıflandırma için kullanılır. İlk tam bağlı katman 4096 nörona sahiptir, bu da modelin öğrenme kapasitesini artırır. Dropout katmanı, aşırı öğrenmeyi kontrol etmek amacıyla kullanılır. Eğitim sırasında rastgele nöronları devre dışı bırakarak, modelin farklı özellikleri öğrenmesini teşvik eder ve genelleme yeteneğini artırır. Son çıkış katmanı, sınıf sayısına karşılık gelen bir softmax aktivasyon fonksiyonu ile 4 nöron içerir. Toplamda, model 41,521,924 parametreye sahiptir. Bu büyük parametre sayısı, modelin karmaşıklığını ve öğrenme kapasitesini yansıtarak, büyük veri setleri ve yüksek hesaplama kapasitesi gerektirir. Çalışmaya ait Yapay Sinir Ağı (AlexNet) modelinin yapısı Şekil 3.9’da verilmiştir.

Şekil 3.9: Derin Evrişimli Sinir Ağları (ALEXNET) Modelinin Yapısı



Çalışmaya ait AlexNet modelinde kullanılan katmanlar ve parametre tablosu Tablo 3.5’te verilmiştir.

Tablo 3.5: AlexNet Modelinde Kullanılan Katmanlar ve Parametreler


Layer (type)	Output Shape	Param #
rescaling (Rescaling)	(none, 227, 227, 3)	Ø
conv2d (Conv2D)	(none, 55, 55, 96)	34944
batch_normalization (Batchnormalization)	(none, 55, 55, 96)	384
max_pooling2d (Max Pooling2D)	(none, 27, 27, 96)	Ø
conv2d_1 (Conv2D)	(none, 27, 27, 96)	614656
batch_normalization_1 (Batchnormalization)	(none, 27, 27, 256)	1024
max_pooling2d_1 (Max Pooling2D)	(none, 13, 13, 256)	Ø
conv2d_2 (Conv2D)	(none, 13, 13, 384)	885120
batch_normalization_2 (Batchnormalization)	(none, 13, 13, 384)	1536
conv2d_3 (Conv2D)	(none, 13, 13, 384)	1237488
batch_normalization_3 (Batchnormalization)	(none, 13, 13, 384)	1536
conv2d_4 (Conv2D)	(none, 13, 13, 256)	884992
batch_normalization_4 (Batchnormalization)	(none, 13, 13, 256)	1024
max_pooling2d_2 (Max Pooling2D)	(none, 6, 6, 256)	Ø
flatten (Flatten)	(none, 9216)	Ø
dense (Dense)	(none, 4096)	37752832
dropout (Dropout)	(none, 4096)	Ø
Dense_1 (Dense)	(none, 4)	16388
Total params : 41,521,924		
Trainable params: 41,519,172		
Non-trainable params: 2,752		

3.3.4. VGG16

Tezin bu aşamasında VGG16 modeli, görüntü sınıflandırma görevleri için özel olarak tasarlanmış güçlü bir evrişimli sinir ağı (CNN) mimarisini benimser. Model, karmaşık özellikleri öğrenme yeteneğiyle dikkat çeken 13 evrişimli katman,

MaxPooling2D katmanları ve tam bağlı (dense) katmanlardan oluşan bir yapıya sahiptir. İlk katman, Rescaling katmanı olarak bilinen giriş katmanını içerir, bu katman giriş görüntülerinin piksel değerlerini normalleştirerek işlemleri başlatır. Evrişimli katmanlar, farklı sayıda filtre ve evrişim boyutlarıyla görüntülerden özellik haritaları çıkararak hiyerarşik öğrenme gerçekleştirir. Bu evrişimli katmanlardan sonra gelen MaxPooling2D katmanları, özellik haritalarını küçültmek ve önemli bilgileri korumak için kullanılır. Bu sayede, model öğrenirken önemli özellikleri vurgulayabilir ve genel olarak daha karmaşık ve genelleyici özelliklere ulaşabilir. Tam bağlı (dense) katmanlar, evrişimli katmanlardan elde edilen özellikleri kullanarak sınıflandırma yapar. İlk iki dense katman 4096 nörona sahiptir ve ReLU aktivasyon fonksiyonları içerir. Son dense katman, softmax aktivasyon fonksiyonu içerir ve genellikle modelin çıkışını oluşturan (Cyst, Normal, Tumor, Stone) sınıf sayısı kadar nörona sahiptir. Toplam parametre sayısı 134,276,932'dir, bu da modelin oldukça yüksek bir öğrenme kapasitesine sahip olduğunu gösterir. Bu sayede, model genellikle büyük veri kümeleri üzerinde eğitilir ve ardından transfer öğrenme ile özel görevlere uyarlanabilir. VGG16 modeli, evrişimli sinir ağları alanında etkili bir özellik çıkarma yeteneği ile tanınan ve geniş bir uygulama yelpazesi için kullanılan önemli bir derin öğrenme modelidir. Çalışmaya ait VGG16 modelinin yapısı Şekil 3.10'da verilmiştir.

Şekil 3.10: VGG16 Modelinin Yapısı



Böbrek hastalığı veri seti için VGG16 da kullandığımız katmanlar ve kullanılan parametre sayıları Tablo 3.6'da verilmiştir.

Tablo 3.6: VGG16 Modelinde Kullanılan Katmanlar ve Parametreler


Layer (type)	Output Shape	Param #
rescaling (Rescaling)	(none, 224, 224, 3)	Ø
conv2d (Conv2D)	(none, 224, 224, 64)	1792
conv2d_1 (Conv2D)	(none, 224, 224, 64)	36928
max_pooling2d (Max_Pooling2D)	(none, 112, 112, 64)	Ø
conv2d_2 (Conv2D)	(none, 112, 112, 128)	73928
conv2d_3 (Conv2D)	(none, 112, 112, 128)	147584
max_pooling2d_1 (Max_Pooling2D)	(none, 56, 56, 128)	Ø
conv2d_4 (Conv2D)	(none, 56, 56, 256)	295168
conv2d_5 (Conv2D)	(none, 56, 56, 256)	590080
conv2d_6 (Conv2D)	(none, 56, 56, 256)	Ø
max_pooling2d_2 (Max_Pooling2D)	(none, 28, 28, 256)	1180160
conv2d_7 (Conv2D)	(none, 28, 28, 512)	2359808
conv2d_8 (Conv2D)	(none, 28, 28, 512)	2359808
conv2d_9 (Conv2D)	(none, 28, 28, 512)	Ø
max_pooling2d_3 (Max_Pooling2D)	(none, 14, 14, 512)	Ø
conv2d_10 (Conv2D)	(none, 14, 14, 512)	Ø
conv2d_11 (Conv2D)	(none, 14, 14, 512)	2359808
conv2d_12 (Conv2D)	(none, 7, 7, 512)	2359808
max_pooling2d_4 (Max_Pooling2D)	(none, 25088)	Ø
flatten (Flatten)	(none, 4096)	Ø
dense (Dense)	(none, 4096)	102764544
dense_1 (Dense)	(none, 4096)	16781312
dense_2 (Dense)	(none, 4)	16388
Total params : 134,276,932		
Trainable params: 134,276,932		
Non-trainable params: Ø		

3.3.5. VGG19

VGG19 modeli, 2014 yılında Oxford Üniversitesi'ndeki Visual Geometry Group (VGG) tarafından geliştirilen bir evrişimli sinir ağı (CNN - Convolutional Neural Network) modelidir. VGG19 modeli, VGG16'nın bir genişletmesidir ve daha fazla evrişim katmanı içerir. Giriş katmanı olan InputLayer ile 224x224 piksel boyutunda ve 3 kanallı (RGB) görüntülerin alınmasıyla başlar. Ardından gelen bloklar, özellik çıkarma işlevini yerine getiren evrişimli (Conv2D) ve maksimum havuzlama (MaxPooling2D) katmanlarından oluşur. Blokların sayısı arttıkça, öğrenilen özelliklerin karmaşıklığı artar ve daha yüksek seviye özellik haritaları çıkarılır. Flatten katmanı, önceki bloklardan elde edilen özellik haritalarını düzleştirerek, bu özellikleri bir araya getirir. Daha sonra gelen tam bağlı (Dense) katmanlar, derin öğrenme modelinin nihai çıktısını üretmek üzere tasarlanmıştır. Tam bağlı katmanların sayısı arttıkça, model daha karmaşık ilişkileri öğrenmeye yetenekli hale gelir. Bu katmanlar, öğrenilen özellikleri temsil eden ağırlıkları içerir ve genellikle sınıflandırma görevlerinde kullanılır. Modelin toplam parametre sayısı 139,586,628'dir. Bu parametrelerin içinde eğitilebilir olanlar, modelin görevine uygun

ağırlıkları öğrenen 129,001,476 adet parametreyi içerir. Geriye kalan 10,585,152 adet parametre ise önceden eğitilmiş ağırlıkları temsil eder. VGG16 modeli, genellikle büyük veri setlerindeki görsel sınıflandırma görevlerinde transfer öğrenme amacıyla kullanılır. Çeşitli endüstri uygulamalarında ve araştırma alanlarında bu tip derin öğrenme modellerinin başarılı bir şekilde kullanılması, modelin geneldeki etkileyici yeteneklerini gösterir. Çalışmaya ait VGG19 modelinin yapısı Şekil 3.11’de verilmiştir.

Şekil 3.11: VGG19 Modelinin Yapısı



Böbrek hastalığı için önerilen VGG19 modelinde kullanılan parametreler ve katmanlar Tablo 3.7 ‘de gösterilmiştir.

Tablo 3.7: VGG19 da Kullanılan Katmanlar ve Parametreler


Layer (type)	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_pool1 (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147584
block2_pool1 (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_conv4 (Conv2D)	(None, 56, 56, 256)	590080
block3_pool1 (MaxPooling2D)	(None, 28, 28, 512)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1180160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv4 (Conv2D)	(None, 14, 14, 512)	2359808
block4_pool1 (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv4 (Conv2D)	(None, 14, 14, 512)	2359808
Block5_pool1 (MaxPooling2D)	(None, 7, 7, 512)	0
flatten (Flatten)	(None, 25088)	0
fc1 (Dense)	(None, 4096)	102764544
fc2 (Dense)	(None, 4096)	16781312
prediction (Dense)	(None, 4)	16388
Total params : 139,586,628		
Trainable params: 129,001,476		
Non-trainable params: 10,585,152		

3.4. ÖNERİLEN POLY-CNN MODELİ

Bu önerilen model, önceki yöntemlerin sınırlamalarını aşmak ve karmaşık görüntü yapısını daha etkili bir şekilde çözebilmek amacıyla tasarlanmıştır. Convolutional Neural Network (CNN) tabanlı yenilikçi bir yaklaşım geliştirmeyi amaçlamaktadır. Poly-CNN mimarisinin temelinde yatan yapısal özellikleri ve hiper parametreleri yeniden değerlendirerek, görüntü segmentasyonunda daha iyi performans sağlamayı hedeflemektedir. Elde edilen sonuçlar, geliştirilen modelin genel görüntü analizi uygulamalarında kullanılabilirliğini ve etkinliğini göstermeye yönelik önemli bir katkı sunmayı amaçlamaktadır. Geliştirdiğimiz Poly-CNN modeli, özellikle görüntü sınıflandırma görevleri için optimize edilmiş bir mimariye sahiptir. Modelin ilk katmanı Rescaling katmanıdır, bu katman veri setindeki piksel değerlerini normalize etmek için kullanılır. Giriş olarak xTrain veri kümesinin şeklini kullanır. Ardından, üç adet Conv2D

katmanı gelir (Conv1, Conv2, Conv3), her biri 3x3 boyutunda filtrelerle işlenmiş özellik haritalarını çıkartır. Her Conv2D katmanının ardından bir MaxPooling2D katmanı gelir (Pool1, Pool2, Pool3), bu katmanlar özellik haritalarındaki önemli bilgileri vurgular ve boyutlarını küçültür. Flatten katmanı, düzleştirme işlemi yaparak önceki katmanlardan elde edilen özellikleri tek boyutlu bir vektöre dönüştürür. Ardından iki adet Dense katmanı gelir (Dense1, Dense2), bu katmanlar sinir ağının öğrenmesini sağlar. Her Dense katmanının ardından bir BatchNormalization katmanı (Norm1, Norm2) gelir, bu katmanlar ağı normalleştirerek eğitimi daha stabil hale getirir. Dropout katmanları (Dropout1, Dropout2) aşırı öğrenmeyi önlemek için kullanılır, eğitim sırasında belirli bir oranda rastgele nöronları devre dışı bırakır. Son katman Dense3, çıkış sınıf sayısına (Tumor, Taş, Kist, Normal) sahip bir softmax aktivasyon fonksiyonu içerir. Bu katman, modelin verilen girişlere dayanarak sınıflar arasında olasılıkları tahmin etmesini sağlar. Modelin toplam parametre sayısı 88,516'dır ve bu parametrelerin 88,452'si eğitilebilirdir. Model, "adam" optimizasyon algoritması ve "categorical_crossentropy" kayıp fonksiyonu ile derlenmiş ve 15 epok süresince eğitilmiştir. Eğitim süreci boyunca modelin performansı, 200'lük mini-batch'ler kullanılarak gerçekleştirilmiştir. Bu Poly-CNN modeli, genel görüntü analizi uygulamalarında etkili bir çözüm sunmayı amaçlamaktadır. Yüksek performans ve optimize edilmiş mimari, modelin uygulamada başarılı sonuçlar elde etmesine olanak tanımaktadır. Çalışmaya ait Poly-CNN modelinin yapısı Şekil 3.12'de verilmiştir.

Şekil 3.12: Önerilen Poly-CNN Modelinin Yapısı



Böbrek hastalığı tiplerini sınıflandırmak için tez kapsamında önerdiğimiz Poly-CNN modelinde kullanılan parametreler ve katmanlar Tablo 3.8 'de gösterilmiştir.

Tablo 3.8: Önerilen Poly-CNN Modelinde Kullanılan Katmanlar ve Parametreler

Layer (type)	Output Shape	Param #
Rescale1 (Rescaling)	(None, 150, 150, 3)	0
Conv1 (Conv2D)	(None, 150, 150, 16)	448
Pool1 (MaxPooling2D)	(None, 75, 75, 16)	0
Conv2 (Conv2D)	(None, 75, 75, 16)	2320
Pool2 (MaxPooling2D)	(None, 37, 37, 16)	0
Conv3 (Conv2D)	(None, 37, 37, 16)	2320
Pool3 (MaxPooling2D)	(None, 18, 18, 16)	0
Flatten1 (Flatten)	(None, 5184)	0
Dense1 (Dense)	(None, 16)	82960
Norm1 (BatchNormalization)	(None, 16)	64
Dropout1 (Dropout)	(None, 16)	0
Dense2 (Dense)	(None, 16)	272
Norm2 (BatchNormalization)	(None, 16)	64
Dropout2 (Dropout)	(None, 16)	0
Dense3 (Dense)	(None, 4)	68
Total params : 88,516		
Trainable params: 88,452		
Non-trainable params: 64		



DÖRDÜNCÜ BÖLÜM
BULGULAR VE DENEYSEL SONUÇLAR

4.1. BÖBREK HASTALIĞI VERİLERİNİN DEĞERLENDİRİLMESİ

4.1.1. Değerlendirme Metrikleri

Çalışmada, sınıflandırıcının performansını değerlendirmek amacıyla accuracy, precision, recall ve F1-score gibi değerlendirme metrikleri kullanılmıştır. Sınıflandırma doğruluğunu sayısal olarak ifade etmek için karışıklık matrisi kullanılmıştır. Bu matris, makine öğreniminde sıkça kullanılan bir tekniktir ve bir sınıflandırma sistemi tarafından elde edilen gerçek ve tahmini sınıfların ilişkisini gösterir. Karışıklık matrisi, iki boyutlu bir yapıya sahiptir: gerçek ve tahmini sınıflar. Her bir satır, bir gerçek sınıf örneğini temsil ederken, her bir sütun bir tahmini sınıfın durumunu gösterir. Bu matris, sınıflandırma sisteminin performansını anlamak ve analiz etmek için önemli bir bilgi kaynağıdır.

Gerçek Pozitif (TP - True Positive): Sınıflandırıcının pozitif sınıfı doğru bir şekilde tespit ettiği durumların sayısını temsil eder. Örneğin, bir hastalığın varlığını doğru bir şekilde teşhis ettiğimizde bu durumu gerçek pozitif olarak adlandırabiliriz.

Gerçek Negatif (TN - True Negative): Sınıflandırıcının negatif sınıfı doğru bir şekilde tespit ettiği durumların sayısını ifade eder. Örneğin, bir hastanın sağlıklı olduğunu doğru bir şekilde belirlediğimizde bu durumu gerçek negatif olarak adlandırabiliriz.

Yanlış Pozitif (FP - False Positive): Sınıflandırıcının negatif sınıfı hatalı bir şekilde pozitif olarak tespit ettiği durumların sayısını gösterir. Örneğin, bir kişiyi hastalıklı olarak yanlış bir şekilde sınıflandırdığımızda bu durumu yanlış pozitif olarak adlandırabiliriz.

Yanlış Negatif (FN - False Negative): Sınıflandırıcının pozitif sınıfı hatalı bir şekilde negatif olarak tespit ettiği durumların sayısını ifade eder. Örneğin, bir hastalığı olan bir kişiyi sağlıklı olarak yanlış bir şekilde sınıflandırdığımızda bu durumu yanlış negatif olarak adlandırabiliriz.

Şekil 4.1: İkili Sınıflandırma için Karışıklık Matrisi

		True Class	
		Positive	Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

Accuracy (Doğruluk): Bu metrik, bir modelin doğru tahmin ettiği örneklerin toplam veri kümesine oranını temsil eder. Genel performansı ölçer ve doğru tahmin edilen örneklerin veri kümesindeki tüm örneklerin yüzdesini gösterir. Accuracy, aşağıdaki formülle hesaplanır:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

Precision (Kesinlik): Bu metrik, pozitif olarak tahmin edilen verilerin ne kadarının doğru tahmin edildiğini gösterir. Yani, yüksek bir precision, daha az yanlış pozitif ifade eder. Precision, aşağıdaki formülle hesaplanır:

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

Recall (Hassasiyet): Bu metrik, sınıflandırıcının tamamlama yeteneğini ölçer. Yüksek recall, daha düşük yanlış negatifleri gösterir. Recall, aşağıdaki formülle hesaplanır:

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

F1-Score: Recall ve precision'ın bir dengelemesidir. Recall'daki iyileşme genellikle precision'daki azalmayla birlikte gelir ve tamamlama yeteneği ile kesinlik arasında bir denge sağlar. F1-Score, aşağıdaki formülle hesaplanır:

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

Bu metrikler, modelin performansını daha ayrıntılı bir şekilde değerlendirmemizi sağlar ve sınıflandırma sonuçlarına ilişkin çeşitli yönleri göz önünde bulundurur.

4.1.2. ANN

Tezin bu bölümünde önerilen ANN modelinin sonuçları gösterilerek değerlendirilmiştir. Tablo 4.1, ANN (Artificial Neural Network) modelinin eğitim veri setinde elde ettiği performans ölçütlerini içermektedir. "Train Loss" (Eğitim Kaybı) değeri 0.0108, "Train Accuracy" (Eğitim Doğruluğu) değeri ise 0.9998 olarak kaydedilmiştir. Bu sonuçlar, modelin eğitim veri setinde düşük kayıp elde ettiğini ve yüksek bir doğruluk oranına sahip olduğunu gösterir.

Tablo 4.1: ANN Modeli Eğitim Verisi Başarı Oranı

Train Loss	Train Accuracy
0.010826244950294495	0.9997704029083252

Tablo 4.2, ANN modelinin doğrulama (Validation) veri setindeki performansını sunar. "Validation Loss" (Doğrulama Kaybı) değeri 0.0227, "Test Accuracy" (Doğruluk) değeri ise 0.9973 olarak ölçülmüştür. Bu değerler, modelin eğitim veri seti dışındaki verilere karşı da etkili bir performans sergilediğini gösterir.

Tablo 4.2: ANN Modeli Doğrulama (Validation) Verisi Başarı Oranı

Validation Loss	Test Accuracy
0.022701701149344444	0.9973219037055969

Tablo 4.3, ANN modelinin test veri setindeki başarı oranlarını gösterir. "Test Loss" (Test Kaybı) değeri 0.0157, "Test Accuracy" (Test Doğruluğu) değeri ise 0.9979 olarak ölçülmüştür. Bu sonuçlar, modelin yeni ve görmediği verilere karşı da yüksek doğruluk elde ettiğini gösterir.


Tablo 4.3: ANN Modeli Test Verisi Başarı Oranı

Test Loss	Test Accuracy
0.015680138021707535	0.9978575110435486

Kullandığımız böbrek veri seti için çapraz entropi (cross-entropy) hata değerlerinin epok değerlerine bağlı olarak nasıl değiştiğini Şekil 19'da gösterdik. Grafikten açıkça görüldüğü üzere, hata değeri en yüksek seviyeyi 2. epokta, en düşük seviyeyi ise 5. epokta kaydetmiştir. Ağırlıkların sürekli güncellendiği dikkate alındığında, en iyi öğrenme performansının 12. epokta gerçekleştiği Şekil 4.2'de belirtilmiştir. Bu


bulgular, modelin eğitim sürecindeki ilerlemeyi anlamamıza ve optimize etmemize yardımcı olmuştur.

Şekil 4.2: ANN Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu Grafikleri



Şekil 4.3'te ANN modelinin eğitim, doğrulama ve test veri setleri için oluşturulan karışıklık matrislerini göstermektedir. Eğitim (Train) aşamasında Stone tipindeki görüntülerden 2 adet hatalı öğrenildiği, ancak diğer sınıfların tamamının doğru bir şekilde öğrenildiği gözlemlenmektedir. Doğrulama (Validation) aşamasında ise yalnızca Cyst sınıfına ait verilerin doğru bir şekilde tahmin edildiği görülmektedir. Test aşamasında ise sadece Normal olarak sınıflandırılmış olan görüntülerin tamamının doğru bir şekilde tahmin edildiği görülmektedir. Bu değerlendirmeler, modelin eğitim, doğrulama ve test aşamalarındaki performansını belirli sınıflar üzerindeki doğruluk seviyeleriyle göstermektedir.

Şekil 4.3: Yapay Sinir Ağları (Artificial Neural Network- ANN) Modeli Eğitim, Doğrulama ve Test Verisi için Karışıklık Matrisi



Eğitim veri setine dair metrikler incelendiğinde, her sınıf için oldukça yüksek precision, recall ve F1-score değerleri elde edilmiştir. "Cyst," "Normal," "Stone," ve "Tumor" sınıfları için sırasıyla 1.0000, 1.0000, 1.0000 ve 0.9988 hassasiyet değerleri, her bir sınıfın doğru pozitif tahminlerini başarıyla gerçekleştirdiğini göstermektedir. Recall

değerleri de benzer şekilde yüksek olup, her sınıfın gerçek pozitiflerini etkili bir biçimde tespit ettiğini göstermektedir. F1-score değerleri ise hassasiyet ve recall'in dengeli bir kombinasyonunu temsil ederek, her sınıf için başarılı bir performansı işaret etmektedir. Genel doğruluk (accuracy) 0.9998 olarak kaydedilmiştir, bu da modelin toplam örneklerin büyük çoğunluğunu doğru bir şekilde sınıflandırdığını gösterir. Macro avg ve weighted avg metrikleri de tüm sınıfların dengeli bir şekilde değerlendirildiğini göstererek, modelin genel başarısını pekiştirmektedir. Tablo 4.4'te ANN modeli için eğitim aşamasındaki değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir.

Tablo 4.4: ANN Modeli Eğitim Aşaması Değerlendirme Metrikleri

For Train Data				
	precision	recall	f1-score	support
Cyst	1.0000	1.0000	1.0000	2596
Normal	1.0000	1.0000	1.0000	3554
Stone	1.0000	0.9979	0.9990	964
Tumor	0.9988	1.0000	0.9994	1598
accuracy			0.9998	8712
macro avg	0.9997	0.9995	0.9996	8712
weighted avg	0.9998	0.9998	0.9998	8712

Test veri setindeki her sınıf için precision (kesinlik), recall (duyarlılık), ve F1-skoru olmak üzere üç önemli ölçümü içermektedir. Cyst sınıfında, modelin kesinlik değeri 1.0000 ve duyarlılık değeri 0.9982 olarak kaydedilmiştir, bu da modelin Cyst sınıfını tahmin etme konusunda yüksek bir kesinlik sergilediğini, ancak bazı Cyst örneklerini kaçırabileceğini gösterir. Normal sınıfında modelin yüksek bir kesinlik (0.9974) ve tam duyarlılık (1.0000) elde ettiği görülmüştür, bu da modelin Normal örneklerini doğru bir şekilde tanımladığını gösterir. Stone sınıfında modelin kesinlik değeri yüksek olmasına rağmen (0.9951), duyarlılık değeri biraz daha düşüktür (0.9854). Tumor sınıfında ise modelin yüksek kesinlik (0.9971) ve tam duyarlılık (1.0000) elde ettiği gözlemlenmiştir. Genel olarak, modelin test veri setinde yüksek doğruluk (0.9979) ve makro ortalama (0.9974) ile başarılı bir performans sergilediği söylenebilir. Tablo 4.5'te ANN modeli için sırasıyla eğitim aşamasındaki değerlendirme metriklerine göre sınıflandırma sonuçları verilmiştir.

Tablo 4.5: ANN modeli için test aşaması değerlendirme sonuçları

For Test Data				
	precision	recall	f1-score	support
Cyst	1.0000	0.9982	0.9991	556
Normal	0.9974	1.0000	0.9987	762
Stone	0.9951	0.9854	0.9902	206
Tumor	0.9971	1.0000	0.9985	343
accuracy				
macro avg	0.9974	0.9959	0.9966	1867
weighted avg	0.9979	0.9979	0.9979	1867

4.1.3. Classic CNN

Tezin bu bölümünde Classic CNN modelinin sonuçları gösterilerek değerlendirilmiştir. Tablo 4.6, Classic CNN modelinin eğitim veri setinde elde ettiği performans ölçütlerini içermektedir. "Train Loss" (Eğitim Kaybı) değeri 0.0162, "Train Accuracy" (Eğitim Doğruluğu) değeri ise 0.9986 olarak kaydedilmiştir. Bu sonuçlar, modelin eğitim veri setinde düşük kayıp elde ettiğini ve yüksek bir doğruluk oranına sahip olduğunu gösterir.

Tablo 4.6: Classic CNN Modeli Eğitim Verisi Başarı Oranı

Train Loss	Train Accuracy
0. 016215046867728233	0. 9986225962638855

Tablo 4.7, Classic CNN modelinin doğrulama (Validation) veri setindeki performansını sunar. "Validation Loss" (Doğrulama Kaybı) değeri 0.0184, "Test Accuracy" (Doğruluk) değeri ise 0.9957 olarak ölçülmüştür. Bu değerler, modelin eğitim veri seti dışındaki verilere karşı da etkili bir performans sergilediğini gösterir.

Tablo 4.7. Classic CNN Modeli Doğrulama (Validation) Verisi Başarı Oranı.

Validation Loss	Test Accuracy
0. 018497968092560768	0. 9957150220870972


Tablo 4.8, Classic CNN modelinin test veri setindeki başarı oranlarını gösterir. "Test Loss" (Test Kaybı) değeri 0.0209, "Test Accuracy" (Test Doğruluğu) değeri ise 0.9957 olarak ölçülmüştür. Bu sonuçlar, modelin yeni ve görmediği verilere karşı da yüksek doğruluk elde ettiğini gösterir.

Tablo 4.8: Classic CNN Modeli Test Verisi Başarı Oranı.


Test Loss	Test Accuracy
0.020970173180103302	0.9957150220870972

Kullandığımız böbrek veri setinde elde ettiğimiz çapraz entropi hata değerlerinin epoklarla değişimini gösteren Şekil 4.4'teki grafik, modelin eğitim setindeki kayıpların nasıl evrildiğini anlatıyor. Eğitim kaybı başlangıçta hızla düşüyor, ancak 5. epok civarında azalma hızının yavaşladığı ve aynı zamanda doğrulama kaybında bir artışın başladığı bir noktada bir duraklama yaşıyor. 15. epok sonrasında ise eğitim setindeki düşük kayıp ile birlikte doğrulama setindeki artış, modelin aşırı öğrenme durumunda olabileceğine işaret ediyor.

Şekil 4.4: Classic CNN Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu Grafiği



Şekil 4.5'te Classic CNN modelinin eğitim, doğrulama ve test veri setleri için oluşturulan karışıklık matrislerini göstermektedir. Modelin performansını değerlendirmek için kullanılan karşılaştırma matrislerine (confusion matrices) baktığımızda, eğitim, doğrulama ve test veri setlerinde elde edilen sonuçlar arasında benzer eğilimler görülmektedir. Eğitim veri setinde, Cyst ve Normal sınıflarında yüksek doğruluk elde edilmiş, ancak Stone sınıfında bazı hatalar gözlemlenmiştir. Doğrulama ve test veri setlerinde de benzer bir eğilim görülmekte olup, genel olarak Cyst ve Normal sınıflarında yüksek doğruluk elde edilirken, Stone sınıfında hataların devam ettiği gözlemlenmektedir. Özellikle Stone sınıfındaki hataların modelin performansını etkileyebileceği göz önüne alındığında, bu sınıf üzerinde modelin daha dikkatli ve hassas bir şekilde çalışması gerekebilir. Tumor sınıfında ise genel olarak yüksek doğruluk değerleri elde edilmiştir. Sonuç olarak, modelin başarıyla öğrendiği ancak belirli sınıflarda daha fazla iyileştirmeye ihtiyaç duyulan bir yapı gözlemlenmektedir. Modelin performansını daha da artırmak için Stone sınıfındaki hataların nedenlerini inceleyerek ve belki de veri setini bu sınıfa odaklanacak şekilde dengeleyerek daha sağlam sonuçlar elde etmek mümkün olabilir.

Şekil 4.5: Classic CNN Modeli Eğitim, Doğrulama ve Test Verisi için Karşılık Matrisi

Tablo 4.9’de Classic CNN modeli için eğitim veri seti üzerinde elde edilen sonuçları değerlendirdiğimizde, modelin genel performansının oldukça yüksek olduğunu gözlemliyoruz. Her bir sınıf için elde edilen precision, recall ve F1-score değerleri incelendiğinde, Cyst, Normal ve Tumor sınıflarında yüksek oranda doğruluk sağlandığı görülmektedir. Bu durum, modelin bu sınıfları başarılı bir şekilde sınıflandırdığını ve bu sınıflarla ilgili tahminlerin güvenilir olduğunu işaret etmektedir. Ancak, Stone sınıfında recall değerinin bir miktar düşük olması, modelin bu sınıfı tanımlarken bazı zorluklarla karşılaştığını gösterebilir. Stone sınıfında görülen düşük recall, bu sınıfın bazı örneklerinin model tarafından kaçırıldığını gösterir. Genel doğruluk (accuracy) metriği incelendiğinde ise, eğitim veri seti üzerinde elde edilen başarılı sonuçlar dikkat çekicidir. Ancak, her sınıfın örnek sayısının dengesiz olduğu durumları göz önüne alarak, macro avg ve weighted avg metrikleriyle genel bir değerlendirme yapmak daha bilgilendirici olabilir. Bu metrikler, modelin tüm sınıflar üzerindeki performansını dengeleyerek genel bir başarı gösterdiğini ortaya koymaktadır. Sonuç olarak, eğitim veri seti üzerinde elde edilen bu değerlendirme metrikleri, modelin güçlü bir sınıflandırıcı olduğunu göstermektedir.

Tablo 4.9: Classic CNN Modeli Eğitim Aşaması Değerlendirme Metrikleri

For Train				
	precision	recall	f1-score	support
Cyst	0.9973	0.9988	0.9981	2596
Normal	0.9994	1.0000	0.9997	3554
Stone	0.9969	0.9927	0.9948	964
Tumor	1.0000	0.9987	0.9994	1598
accuracy			0.9986	8712
macro avg	0.9984	0.9976	0.9980	8712
weighted avg	0.9986	0.9986	0.9986	8712

Tablo 4.10’da Classic CNN modeli Test veri seti üzerinde elde edilen sonuçları değerlendirdiğimizde, modelin başarılı bir performans sergilediğini gözlemliyoruz. Her bir sınıf hastalık sınıfında oluşan precision, recall ve F1-score sonuçları incelendiğinde,

Cyst, Normal ve Tumor sınıflarında yüksek oranda doğruluk sağlandığı görülmektedir. Bu durum, modelin bu sınıfları başarılı bir şekilde sınıflandırdığını ve bu sınıflarla ilgili tahminlerin güvenilir olduğunu işaret etmektedir. Stone sınıfında elde edilen değerler incelendiğinde, precision ve recall değerlerinin bir miktar düşük olduğu görülmektedir. Bu durum, modelin Stone sınıfında bazı örnekleri doğru bir şekilde tanımlayamadığını ve bu sınıf için bir miktar zorluk yaşandığını gösterebilir. Ancak, bu durumun genel başarıyı olumsuz yönde etkilemediği anlaşılmaktadır. Genel doğruluk (accuracy) metriği incelendiğinde ise, test veri seti üzerinde elde edilen başarılı sonuçlar dikkat çekicidir. Macro avg ve weighted avg metrikleriyle yapılan genel değerlendirmeler, modelin tüm sınıflar üzerinde dengeli bir başarı gösterdiğini ortaya koymaktadır. Bu değerlendirme metrikleri, modelin test veri seti üzerinde güvenilir ve başarılı bir sınıflandırma gerçekleştirdiğini göstermektedir.

Tablo 4.10: Classic CNN Modeli için Test Aşaması Değerlendirme Metrikleri

For Test Data				
	precision	recall	f1-score	support
Cyst	0.9982	0.9910	0.9946	557
Normal	0.9974	1.0000	0.9987	762
Stone	0.9760	0.9854	0.9807	206
Tumor	1.0000	1.0000	1.0000	342
accuracy			0.9957	1867
macro avg	0.9929	0.9941	0.9935	1867
weighted avg	0.9957	0.9957	0.9957	1867

4.1.4. ALEXNET

Tezin bu kısmında ALEXNET modelinin sonuçları gösterilerek değerlendirilmiştir, Tablo 4.11, AlexNet modelinin eğitim veri setinde elde ettiği performans ölçütlerini içermektedir. Eğitim kaybı değeri 0.1802 ve eğitim doğruluğu %92.11 olarak belirlenmiştir. Eğitim kaybı, modelin öğrenme sürecinde gerçek değerlere olan yakınlığını ölçer; bu değer ne kadar düşükse, modelin eğitim verilerini o kadar iyi öğrendiği anlamına gelir. Öte yandan, eğitim doğruluğu, modelin doğru tahmin oranını ifade eder ve yüzde cinsinden belirtilir. %92.11'lik eğitim doğruluğu, modelin eğitim verilerinde yüksek başarı elde ettiğini gösterir.

Tablo 4.11: ALEXNET Modeli Eğitim Verisi Başarı Oranı

Train Loss	Train Accuracy
0.18022404611110687	0.9211432337760925

Tablo 4.12, ALEXNET modelinin doğrulama (Validation) veri setindeki performansını sunar. "Validation Loss" (Doğrulama Kaybı) değeri 0.02158, "Test Accuracy" (Doğruluk) değeri ise 0.8993 olarak ölçülmüştür. Bu değerler, modelin eğitim veri seti dışındaki verilere karşı da etkili bir performans sergilediğini gösterir.

Tablo 4.12: ALEXNET Modeli Doğrulama (Validation) Verisi Başarı Oranı

Validation Loss	Test Accuracy
0.21587049961090088	0.899303674697876


Tablo 4.13, ALEXNET modelinin test veri setindeki başarı oranlarını gösterir. "Test Loss" (Test Kaybı) değeri 0.2234, "Test Accuracy" (Test Doğruluğu) değeri ise 0.8944 olarak ölçülmüştür. Bu sonuçlar, modelin yeni ve görmediği verilere karşı da yüksek doğruluk elde ettiğini gösterir.

Tablo 4.13: ALEXNET Modeli Test Verisi Başarı Oranı

Test Loss	Test Accuracy
0.223430335521698	0.8944831490516663


Çalışmamızda kullanılan böbrek veri setinin çapraz entropi (cross entropy) hata değerlerinin epok değerlerine göre değişimi Şekil 4.6'da gösterilmiştir. Bu grafik, modelin eğitim sürecindeki kayıpların epoklara bağlı olarak nasıl değiştiğini gösterir. İlk beş epok boyunca, eğitim setindeki kayıpların hızla azaldığı ve doğruluğun arttığı görülüyor. Daha sonraki beş epok boyunca, eğitim kaybının ve doğruluğunun üzerindeki iyileşme devam etti. Ancak, doğrulama setindeki kayıpların ve doğruluğunun hala istenilen seviyede olmadığı gözlemleniyor. 11. epokdan itibaren, eğitim kaybının düşüş hızı yavaşladı. Eğitim setindeki doğruluk hala yüksek seviyede olsa da doğrulama setindeki sonuçlar üzerinde olumlu bir etki yaratamadı. Bu durum, modelin aşırı uyuma eğilimli olduğunu gösterebilir.

Şekil 4.6: AlexNet Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu Grafiği



Şekil 4.7’te AlexNet modelinin eğitim, doğrulama ve test veri setleri için oluşturulan karışıklık matrislerini göstermektedir. Karışıklık matrisleri, modelin sınıfları ne kadar doğru tahmin ettiğini ve hangi sınıflarda hatalar yaptığını anlamak için önemli bir araçtır. Şekil 24’te verilerin eğitim, doğrulama ve test setleri üzerinde elde edilen karışıklık matrislerine baktığımızda şu gözlemleri yapabiliriz: Eğitim veri setinde, Cyst için 2421 doğru tahmin ve hiç yanlış tahmin olmamıştır. Normal için 3527 doğru tahmin ve yalnızca 27 yanlış tahmin görülmüştür. Stone için 964 doğru tahmin ve 131 yanlış tahmin bulunurken, Tumor için 1113 doğru tahmin ve 353 yanlış tahmin yapılmıştır. Doğrulama veri setinde, Cyst için 493 doğru tahmin ve hiç yanlış tahmin olmamıştır. Normal için 754 doğru tahmin ve 8 yanlış tahmin görülmüştür. Stone için 207 doğru tahmin ve 42 yanlış tahmin bulunurken, Tumor için 225 doğru tahmin ve 75 yanlış tahmin yapılmıştır. Test veri setinde ise Cyst için 491 doğru tahmin ve 66 yanlış tahmin gerçekleşmiştir. Normal için 753 doğru tahmin ve hiç yanlış tahmin olmamıştır. Stone için 206 doğru tahmin ve 41 yanlış tahmin bulunurken, Tumor için 220 doğru tahmin ve 80 yanlış tahmin yapılmıştır. Bu sonuçlar, modelin genel olarak iyi performans gösterdiğini, ancak belirli sınıflarda daha fazla iyileştirme gerektiğini göstermektedir.

Şekil 4.7: Alexnet Modeli Eğitim, Doğrulama ve Test Verisi için Karışıklık Matrisi



Tablo 4.14’te modelin eğitildiği veri seti üzerinde elde edilen sınıflandırma raporu incelendiğinde, her bir sınıf için precision (kesinlik), recall (duyarlılık) ve F1-score (F1 skoru) değerleri dikkate alındığında şu sonuçlar gözlemlenmektedir: "Cyst" sınıfında model, yüksek bir precision ile sınıflandırma yapıyor, yani bu sınıfa ait tahminlerin büyük bir kısmı gerçekten "Cyst" sınıfına ait. Ancak, recall değeri biraz daha düşük, yani bu sınıfa ait gerçek örneklerin yüzde 93.26'sini doğru bir şekilde tanımlayabiliyor. "Normal" sınıfında model, yüksek precision ve recall ile başarılı bir performans sergiliyor. Yani hem bu sınıfa ait tahminlerin çoğu doğru, hem de gerçek "Normal" sınıfına ait örneklerin büyük bir kısmını doğru bir şekilde tanımlayabiliyor. "Stone" sınıfında modelin precision değeri biraz düşük olsa da, recall ve F1-score oldukça

yüksektir. Bu, "Stone" sınıfına ait örneklerin büyük bir kısmının doğru bir şekilde tanımlandığını ancak bu sınıfın diğer sınıflarla karşılaştırıldığında daha nadir olduğunu gösterir. "Tumor" sınıfında ise precision değeri yüksekken, recall biraz daha düşüktür. Yani, "Tumor" sınıfına ait örnekleri iyi bir şekilde tanımlayabiliyor, ancak bu sınıfın tüm örnekleri arasında doğru bir şekilde tanımlananların oranı biraz daha düşüktür. Bu sonuçlar, modelin genel doğruluğunun yüksek olduğunu göstermekle birlikte, özellikle belirli sınıflarda performansın iyileştirilebileceğini düşündürmektedir. Her sınıf için ayrı ayrı değerlendirme yapmak, modelin güçlü ve zayıf yönlerini anlamak adına önemlidir.

Tablo 4.14: AlexNet Modeli Eğitim Aşaması Değerlendirme Metrikleri

For Train Data				
	precision	recall	f1-score	support
Cyst	0.9996	0.9326	0.9649	2596
Normal	0.9642	0.9924	0.9781	3554
Stone	0.6346	1.0000	0.7765	964
Tumor	1.0000	0.6965	0.8211	1598
accuracy			0.9211	8712
macro avg	0.8996	0.9054	0.8851	8712
weighted avg	0.9448	0.9211	0.9231	8712

Tablo 4.15'te test verilerine uygulanan model değerlendirmesinde, her sınıf için hassasiyet (precision), duyarlılık (recall), ve F1 puanları (F1-score) göz önüne alınmıştır. Cyst (Kist) sınıfı için modelin gösterdiği %99,59 hassasiyet, bu sınıfa ait tahminlerin gerçek kist vakalarının %99,59'unun doğru bir şekilde yapıldığını gösterirken, %88,15 duyarlılık, gerçek kist vakalarının %88,15'inin model tarafından doğru bir şekilde tespit edildiğini göstermektedir. Bu sınıfın F1 puanı ise %93,52 olarak hesaplanmıştır. Normal sınıfı için %94,4 hassasiyet, bu sınıfa ait tahminlerin gerçek normal vakalarının yüzde %94,84'ünün doğru yapıldığını gösterirken, %98,95 duyarlılık, gerçek normal vakalarının %98,95'inin model tarafından doğru bir şekilde tespit edildiğini göstermektedir. Bu sınıfın F1 puanı ise %96,85 olarak hesaplanmıştır. Stone (Taş) sınıfında ise %57,22 hassasiyet ve %100 duyarlılık elde edilmiştir. Bu, modelin taş sınıfındaki tahminlerinin yüzde 57,22'sinin doğru olduğunu, ancak bu sınıfa ait tüm gerçek taş vakalarının tespit edildiğini gösterir. F1 puanı ise %72,79 olarak hesaplanmıştır. Son olarak, Tumor (Tümör) sınıfı için modelin yüzde 100,00 hassasiyet, %64,14 duyarlılık ve %78,15 F1 puanı elde ettiği görülmektedir. Bu, modelin tümör sınıfındaki tahminlerinin yüzde 100,00'ünün doğru olduğunu ancak gerçek tümör vakalarının yüzde 64,14'ünün doğru bir şekilde tespit edildiğini gösterir. Toplamda, modelin genel doğruluk oranı yüzde 89,45'tir ve farklı sınıflar arasında performans farklılıkları bulunmaktadır.

Tablo 4.15: AlexNet Modeli için Test Aşaması Değerlendirme Metrikleri

For Test Data				
	precision	recall	f1-score	support
Cyst	0.9959	0.8815	0.9352	557
Normal	0.9484	0.9895	0.9685	762
Stone	0.5722	1.0000	0.7279	206
Tumor	1.0000	0.6414	0.7815	342
accuracy			0.8945	1867
macro avg	0.8791	0.8781	0.8533	1867
weighted avg	0.9305	0.8945	0.8977	1867

4.1.5. VGG16

Tezin bu kısmında VGG16 modelinin sonuçları gösterilerek değerlendirilmiştir, Tablo 4.16’da VGG16 modelinin eğitim veri setinde elde ettiği performans ölçütlerini içermektedir. VGG16 modeli, eğitim verileri üzerinde değerlendirildiğinde elde edilen sonuçlar şu şekildedir: Eğitim Kaybı (Train Loss) değeri 0.0511 ve Eğitim Doğruluğu (Train Accuracy) değeri 0.9807 olarak hesaplanmıştır. Train Loss, modelin doğrulama verileri üzerindeki tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini ifade eder ve düşük olması istenir. Train Accuracy ise doğru sınıflandırılan örneklerin oranını ifade eder ve yüksek olması arzulanır.

Tablo 4.16: ALEXNET Modeli Eğitim Verisi Başarı Oranı

Train Loss	Train Accuracy
0.05117779225111008	0.9807162284851074

Tablo 4.17, VGG16 modelinin doğrulama verileri üzerinde elde ettiği sonuçlara göre, doğrulama kaybı (Validation Loss) değeri 0.0704 ve doğrulama doğruluğu (Validation Accuracy) değeri 0.9732 olarak belirlenmiştir.

Tablo 4.17: ALEXNET Modeli Doğrulama (Validation) Verisi Başarı Oranı


Validation Loss	Test Accuracy
0.0703543871641159	0.973219096660614

Tablo 4.18’de, VGG16 modelinin test veri setindeki başarı oranlarını gösterir. "Test Loss" (Test Kaybı) değeri 0.0860, "Test Accuracy" (Test Doğruluğu) değeri ise 0.9657 olarak ölçülmüştür. Bu sonuçlar, modelin yeni ve görmediği verilere karşı da yüksek doğruluk elde ettiğini gösterir.

Tablo 4.18: ALEXNET Modeli Test Verisi Başarı Oranı

Test Loss	Test Accuracy
0.08607534319162369	0.9657204151153564


Kullandığımız böbrek veri seti için çapraz entropi kaybı (Cross Entropy Loss) grafiği Şekil 4.8’de verilmiştir, modelin eğitim setindeki kayıpların epoklara göre nasıl değiştiğini gösterir. Eğitim kaybı (mavi noktalar) ile doğrulama kaybı (kırmızı noktalar) arasındaki belirgin fark, modelin eğitim verilerine aşırı ezber (overfitting) yaşamadığını göstermektedir. Her iki kayıp değeri de bir araya yaklaştıkça, modelin sınıflandırma yeteneğini sürdürdüğü ve yeni verilere karşı başarılı bir performans sergilediği söylenebilir. İlk epoklardaki büyük kayıp değerleri, modelin başlangıçta veriyi anlamaya çalıştığını ve daha sonra bu anlamı pekiştirdiğini gösterir. Eğitim doğruluğu (mavi noktalar) ile doğrulama doğruluğu (kırmızı noktalar) arasındaki uyum, modelin eğitim sırasında sürekli bir şekilde performansını artırdığını gösterir. Başlangıçta düşük olan doğruluk oranları, zamanla modelin daha iyi öğrenmesiyle birlikte önemli ölçüde artmıştır.

Şekil 4.8: VGG16 Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu Grafiği

Karışıklık matrisleri, modelin sınıfları ne kadar doğru tahmin ettiğini ve hangi sınıflarda hatalar yaptığını anlamak için önemli bir araçtır. Şekil 4.9’da verilerin eğitim, doğrulama ve test setleri üzerinde elde edilen karmaşıklık matrislerine baktığımızda şu gözlemleri yapabiliriz: Eğitim veri setine baktığımızda, modelin Cyst 2543 kez doğru bir şekilde sınıflandırdığını ancak 53 kez yanlış sınıflandırdığını görüyoruz. Stone için 916 doğru ve 48 kez yanlış sınıflandırma olduğu görülmektedir. Tümör için ise 1531 doğru ve 67 yanlış sınıflandırma gözlemlenmektedir. Doğrulama veri setine geçtiğimizde, Cyst için 541 doğru ve 16 yanlış sınıflandırma, Normal için 762 doğru sınıflandırma, Stone için 12 yanlış sınıflandırma dikkat çekmektedir. Son olarak, test veri setinde, Cyst için 537 doğru ve 19 yanlış sınıflandırma, Normal için 761 doğru sınıflandırma ve Stone için

14 yanlış sınıflandırma görülmektedir. Bu matris, modelin genel performansını değerlendirirken, özellikle hangi sınıfların daha hassas veya daha az hassas olduğunu belirlemekte yardımcı olur. Bu ayrıntılı matrisler, modelin güçlü yönlerini anlamak ve zayıflıklarını geliştirmek için rehberlik sağlar.

Şekil 4.9: VGG16 Modeli Eğitim, Doğrulama ve Test Verisi için Karışıklık Matrisi



Tablo 4.19’da modelin eğitildiği veri seti üzerinde elde edilen her bir sınıf için precision (kesinlik), recall (duyarlılık) ve F1-score (F1 skoru) değerleri dikkate alındığında Cyst sınıfı için modelin yüksek bir kesinlik (0.9996) gösterdiği görülmektedir. Yani, bu sınıfa ait tahminlerin gerçekte ne kadarının doğru olduğu yüksek bir oranda sağlanmıştır. Bununla birlikte, bu sınıfa ait olan örneklerin tahmin edilme oranı (hassasiyet) 0.9796 olarak ölçülmüştür. Normal sınıfı için ise model yüksek bir kesinlik (0.9564) ve tam hassasiyet (1.0000) sergilemiştir. Bu durum, Normal sınıfına ait olan örneklerin doğru bir şekilde tahmin edildiğini ve yanlış pozitif tahminin olmadığını göstermektedir. Stone ve Tümör sınıfları için de benzer şekilde yüksek kesinlik ve hassasiyet değerleri elde edilmiştir. Bu durum, modelin bu sınıflara ait örnekleri doğru bir şekilde sınıflandırdığını ve genel olarak başarılı bir performans gösterdiğini göstermektedir. Ayrıca, raporda bulunan destek (support) değerleri, her bir sınıfa ait gerçek örnek sayısını temsil etmektedir. Modelin genel doğruluğu ise %98.07 olarak ölçülmüştür.

Tablo 4.19: VGG16 Modeli Eğitim Aşaması Değerlendirme Metrikleri

For Train Data				
	precision	recall	f1-score	support
Cyst	0.9996	0.9796	0.9895	2596
Normal	0.9564	1.0000	0.9777	3554
Stone	0.9957	0.9502	0.9724	964
Tumor	0.9993	0.9581	0.9783	1598
accuracy			0.9807	8712
macro avg	0.9878	0.9720	0.9795	8712
weighted avg	0.9815	0.9807	0.9807	8712

Tablo 4.20’te test verilerine uygulanan model değerlendirmesinde, her sınıf için hassasiyet (precision), duyarlılık (recall), ve F1 puanları (F1-score) göz önüne alınmıştır. Cyst sınıfı için modelin gösterdiği kesinlik oldukça yüksek bir değer olan 0.9981’dir, bu da Cyst sınıfına ait tahminlerin gerçekte ne kadarının doğru olduğunu gösterir. Ancak, bu sınıfa ait olan örneklerin tahmin edilme oranı (hassasiyet) biraz daha düşük bir değer olan 0.9658’dir. Normal sınıfında model yüksek bir kesinlik (0.9303) ve tam hassasiyet (1.0000) sergilemiştir. Yani, Normal sınıfına ait olan örneklerin doğru bir şekilde tahmin edildiği ve yanlış pozitif tahmin olmadığı görülmektedir. Stone ve Tümör sınıfları için de model yüksek kesinlik ve hassasiyet değerleri göstermiştir. Bu durum, modelin bu sınıflara ait örnekleri doğru bir şekilde sınıflandırdığını ve genel olarak başarılı bir performans gösterdiğini göstermektedir. Modelin genel doğruluğu ise %96,57 olarak ölçülmüştür. Makro ve ağırlıklı ortalamalar, sınıflar arasında dengeli bir performansın elde edildiğini göstermektedir.

Tablo 4.20: VGG16 Modeli için Test Aşaması Değerlendirme Metrikleri

For Test Data				
	precision	recall	f1-score	support
Cyst	0.9981	0.9658	0.9817	557
Normal	0.9303	1.0000	0.9639	762
Stone	0.9698	0.9324	0.9507	206
Tumor	1.0000	0.9096	0.9527	342
accuracy			0.9657	1867
macro avg	0.9746	0.9520	0.9623	1867
weighted avg	0.9677	0.9657	0.9657	1867

4.1.6. VGG19

Tezin bu kısmında VGG19 modelinin sonuçları gösterilerek değerlendirilmiştir, Tablo 4.21’de, VGG19 modelinin eğitim veri setinde elde ettiği performans ölçütlerini içermektedir. VGG19 modeli, eğitim verileri üzerinde değerlendirildiğinde elde edilen sonuçlar şu şekildedir: Eğitim Kaybı (Train Loss) değeri 0.0049 ve Eğitim Doğruluğu (Train Accuracy) değeri 0.9988 olarak hesaplanmıştır. Eğitim Kaybı (Train Loss), modelin doğrulama verileri üzerindeki tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini ifade eder ve düşük olması istenir. Eğitim Doğruluğu (Train Accuracy) ise doğru sınıflandırılan örneklerin oranını ifade eder ve yüksek olması arzulanır.

Tablo 4.21: VGG19 Modeli Eğitim Verisi Başarı Oranı

Train Loss	Train Accuracy
0.0049275122582912445	0.9988521337509155

Tablo 4.22’de, VGG19 modelinin doğrulama verileri üzerinde elde ettiği sonuçlara göre, doğrulama kaybı (Validation Loss) değeri 0.0164 ve doğrulama doğruluğu (Validation Accuracy) değeri 0.9951 olarak belirlenmiştir.

Tablo 4.22: VGG19 Modeli Doğrulama (Validation) Verisi Başarı Oranı

Validation Loss	Test Accuracy
0.016483215615153313	0.9951794147491455


Tablo 4.23’te, VGG19 modelinin test veri setindeki başarı oranlarını gösterir. "Test Loss" (Test Kaybı) değeri 0.0079, "Test Accuracy" (Test Doğruluğu) değeri ise 0.9978 olarak ölçülmüştür. Bu sonuçlar, modelin yeni ve görmediği verilere karşı da yüksek doğruluk elde ettiğini gösterir.

Tablo 4.23: VGG19 Modeli Test Verisi Başarı Oranı

Test Loss	Test Accuracy
0.007952491752803326	0.9978575110435486


Kullandığımız böbrek veri seti için çapraz entropi kaybı (Cross Entropy Loss) grafiği Şekil 4.10’da verilmiştir, modelin eğitim setindeki kayıpların epoklara göre nasıl değiştiğini gösterir. İlk epoktan itibaren mavi renkli eğitim kaybı ve doğruluk metrikleri üzerindeki değişimleri incelediğimizde, eğitim kaybının giderek azaldığını ve mavi renkli eğitim doğruluğunun sürekli arttığını gözlemliyoruz. Özellikle 6. epoktan sonra eğitim kaybındaki belirgin bir düşüş dikkat çekiyor. Ancak, aynı dönemde kırmızı renkli doğrulama kaybında bazı artışlar gözlemleniyor, bu da modelin belirli epoklarda aşırı uyum yaşayabileceğini işaret edebilir. Eğitim sürecinde, mavi renkli eğitim doğruluğu ve kırmızı renkli doğrulama doğruluğu genel olarak artış gösteriyor. Ancak, mavi renkli eğitim doğruluğu ile kırmızı renkli doğrulama doğruluğu arasındaki farkın incelenmesi, aşırı uyum olup olmadığını değerlendirmek açısından önemlidir. Grafikler incelendiğinde, modelin genel olarak başarılı bir performans sergilediği gözlemleniyor.

Şekil 4.10: VGG19 Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu Grafiği



Karışıklık matrisleri, modelin sınıfları ne kadar doğru tahmin ettiğini ve hangi sınıflarda hatalar yaptığını anlamak için önemli bir araçtır. Şekil 26’te verilerin eğitim, doğrulama ve test veri setleri üzerinde elde edilen karmaşıklık matrislerine baktığımızda şu gözlemleri yapabiliriz: Eğitim veri setine baktığımızda Eğitim sürecinde model, "Cyst," "Normal," "Stone," ve "Tumor" sınıfları için toplamda 8712 örneği değerlendirmiştir. Karmaşıklık matrisi, her bir hastalık türü bağlamında doğru ve yanlış tahmin değerlerini içerir. Özellikle, "Cyst" sınıfında 2587 doğru tahmin yapılırken, "Stone" sınıfında 963 doğru tahmin gerçekleşmiştir. Doğrulama veri setine geçtiğimizde, doğrulama veri setindeki 1867 örneği değerlendirirken, "Normal" sınıfında 762 doğru tahmin elde etmiştir. Son olarak, test veri setinde, "Cyst" sınıfında 553 doğru tahmin elde edilirken, "Stone" sınıfında 1 yanlış tahmin gerçekleşmiştir. Bu ayrıntılı matrisler, modelin güçlü yönlerini anlamak ve zayıflıklarını geliştirmek için rehberlik sağlar.

Şekil 4.11: VGG19 Modeli Eğitim, Doğrulama ve Test Verisi için Karışıklık Matrisi



Tablo 4.24’te modelin eğitim veri seti üzerinde elde ettiği sınıflandırma raporu incelendiğinde, "Cyst," "Normal," "Stone," ve "Tümör" sınıfları için yüksek kesinlik (precision), duyarlılık (recall), ve F1 skorları elde edildiği görülmektedir. "Cyst" sınıfı için %99,65 duyarlılıkla yüksek bir başarı elde edilirken, "Normal" sınıfı %100 duyarlılık

ve %99,99 F1 skoru ile öne çıkmaktadır. "Stone" sınıfında %99,90 duyarlılık ve %99,48 F1 skoru, "Tumor" sınıfında ise %100 duyarlılık ve %100 F1 skoru ile mükemmel bir performans sergilendiği gözlemlenmektedir. Bu değerler, modelin her bir sınıf üzerinde başarılı bir şekilde tahminleme yaptığını ve sınıfları doğru bir şekilde ayırt ettiğini göstermektedir. Ayrıca, weighted avg ve macro avg değerleri, modelin genel başarı oranının yüksek olduğunu, toplam doğruluk oranının %99,89 olduğunu ortaya koymaktadır.

Tablo 4.24: VGG16 Modeli Eğitim Aşaması Değerlendirme Metrikleri

For Train Data				
	precision	recall	f1-score	support
Cyst	1.0000	0.9965	0.9983	2596
Normal	0.9997	1.0000	0.9999	3554
Stone	0.9907	0.9990	0.9948	964
Tumor	1.0000	1.0000	1.0000	1598
accuracy			0.9989	8712
macro avg	0.9976	0.9989	0.9982	8712
weighted avg	0.9989	0.9989	0.9989	8712

Tablo 4.25'te Test veri seti için elde edilen sınıflandırma raporu incelendiğinde, "Cyst," "Normal," "Stone," ve "Tümör" sınıfları için yüksek kesinlik (precision), duyarlılık (recall), ve F1 skorları gözlemlenmiştir. "Cyst" sınıfında %99,46 duyarlılıkla yüksek bir başarı sağlanırken, "Normal" sınıfında %100 duyarlılık ve %100 F1 skoru ile mükemmel bir performans sergilenmiştir. "Stone" sınıfında %99,52 duyarlılık ve %99,04 F1 skoru, "Tümör" sınıfında ise %100 duyarlılık ve %100 F1 skoru elde edilmiştir. Bu sonuçlar, modelin test veri seti üzerinde başarılı bir şekilde sınıflandırma yaptığını ve sınıfları doğru bir şekilde ayırt ettiğini göstermektedir. Ayrıca, weighted avg ve macro avg değerleri, modelin genel başarı oranının yüksek olduğunu, toplam doğruluk oranının %99,79 olduğunu ortaya koymaktadır.

Tablo 4.25: VGG16 Modeli için Test Aşaması Değerlendirme Metrikleri

For Test Data				
	precision	recall	f1-score	support
Cyst	0.9981	0.9658	0.9817	557
Normal	0.9303	1.0000	0.9639	762
Stone	0.9698	0.9324	0.9507	206
Tumor	1.0000	0.9096	0.9527	342
accuracy			0.9657	1867
macro avg	0.9746	0.9520	0.9623	1867
weighted avg	0.9677	0.9657	0.9657	1867

4.1.7. Önerilen Poly-CNN Modeli

Tezin bu kısmında Poly-CNN modelinin sonuçları gösterilerek değerlendirilmiştir, Tablo 4.26’de, Poly-CNN modelinin eğitim veri setinde elde ettiği performans ölçütlerini içermektedir. Eğitim sürecinde elde edilen sonuçlara göre, modelin eğitim veri setindeki kayıp (loss) değeri 0.0183, yani modelin tahminleri ile gerçek etiketler arasındaki ortalama hata oldukça düşüktür. Bu durum, modelin eğitim verilerini başarılı bir şekilde öğrendiğini ve bu verilere uygun tahminlerde bulunduğunu gösterir. Ayrıca, eğitim doğruluğu (accuracy) değeri 0.9999 olarak elde edilmiştir. Bu yüksek doğruluk, modelin eğitim veri setindeki örnekleri doğru bir şekilde sınıflandırdığını ifade eder. Yüksek eğitim doğruluğuna rağmen, modelin sınıflandırma yeteneği, başka veri setlerine nasıl uyum sağladığını değerlendirmek için kullanılan doğrulama veri setindeki performansa bağlıdır. Eğer model, yeni verilere uygun bir şekilde adapte olmuşsa, aynı başarıyı doğrulama veri setinde de göstermesi beklenir.

Tablo 4.26: Poly-CNN Modeli Eğitim Verisi Başarı Oranı

Train Loss	Train Accuracy
0.018333209678530693	0.9998852014541626

Tablo 4.27’de, Poly-CNN modelinin Doğrulama (Validation) veri seti üzerinde elde edilen sonuçlara göre, modelin doğrulama veri setindeki kayıp (loss) değeri 0.0219’dur. Bu değer, modelin doğrulama veri setindeki tahminlerinin gerçek etiketlerden ne kadar uzaklıkta olduğunu gösterir. Düşük bir kayıp değeri, modelin doğrulama veri setinde başarılı olduğunu ve genel olarak iyi performans sergilediğini gösterir. Ayrıca, doğrulama doğruluğu (accuracy) değeri 0.9984 olarak elde edilmiştir. Bu yüksek doğruluk, modelin doğrulama veri setindeki örnekleri doğru bir şekilde sınıflandırdığını ve genel olarak başarılı bir şekilde sınıflandırma yaptığını gösterir. Yüksek doğruluk, modelin eğitim sırasında öğrendiklerini yeni verilere de başarıyla uyguladığını işaret eder.

Tablo 4.27: Poly-CNN Modeli Doğrulama (Validation) Verisi Başarı Oranı

Validation Loss	Test Accuracy
0.021883349865674973	0.9983931183815002

Tablo 4.28’te, Poly-CNN modelinin test veri seti üzerindeki performans değerlendirmeleri: Test Loss (Test Kaybı) değeri 0.0226 olarak ölçülmüştür; bu değer, modelin test veri setindeki tahminlerinin gerçek etiketlere ne kadar yakın veya uzak


olduğunu gösteren bir ölçüdür, düşük bir kayıp değeri arzu edilen bir sonuçtur. Ayrıca, Test Accuracy (Test Doğruluğu) değeri %99,89 olarak elde edilmiştir; bu değer, modelin test veri setindeki örnekleri doğru bir şekilde sınıflandırma yüzdesini ifade eder, Bu sonuçlar, modelin test veri setinde yüksek bir başarı elde ettiğini ve gerçek dünya verileri üzerinde de etkili bir performans sergileme potansiyeline sahip olduğunu göstermektedir.

Tablo 4.28: Poly-CNN Modeli Test Verisi Başarı Oranı

Test Loss	Test Accuracy
0.02259119413793087	0.9989287853240967


Kullandığımız böbrek veri seti için çapraz entropi kaybı (Cross Entropy Loss) grafiği Şekil 4.12’de verilmiştir, modelin eğitim geçmişi (History) incelendiğinde, eğitim sürecinin 15 epok (dönem) boyunca gerçekleştirildiği görülmektedir. İlk epoktan itibaren eğitim kaybının (loss) düşmeye başladığı ve modelin doğruluğunun (accuracy) arttığı gözlemlenmektedir. İlk epok sonunda eğitim kaybı 1.43, doğruluk ise %37,76 olarak ölçülmüş; ancak bu değerlerin ikinci epok ile birlikte iyileştiği görülmektedir. Eğitim süreci boyunca hem eğitim kaybı hem de doğruluk değerlerindeki düzenli bir iyileşme gözlemlenmektedir. Modelin doğruluk değeri, eğitimde başlangıçta %37.76 iken, 15. epok sonunda %89,46’ya yükselmiştir. Benzer şekilde, eğitim kaybı başlangıçta 1,43 iken, eğitim sürecinin sonunda 0,27’ye kadar düşmüştür. Grafikler üzerinden incelendiğinde, mavi renkli noktalar eğitim verisi için kaybı temsil ederken, kırmızı renkli noktalar ise doğruluğu temsil etmektedir. Hem eğitim kaybı hem de doğruluk değerlerindeki benzer iyileşme eğilimi, modelin eğitim setine iyi bir şekilde adapte olduğunu ve eğitim sürecinin başarılı bir şekilde ilerlediğini göstermektedir. Ayrıca, modelin Validation (doğrulama) veri seti üzerindeki performansını gösteren grafikler de incelendiğinde, Validation kaybının ve doğruluğunun eğitimle birlikte düzgün bir şekilde iyileştiği gözlemlenmektedir. Bu durum, modelin genelleme yeteneğinin kuvvetli olduğunu ve yeni verilere de başarılı bir şekilde uygulandığını göstermektedir. **Epok sayısının artmasıyla birlikte, aşırı uyum (overfitting) yaşanmamış ve modelin performansı artmıştır.**

Şekil 4.12: Poly-CNN Modeli için Çapraz Entropi Hatası ve Sınıflandırma Doğruluğu Grafiği



Şekil 4.13'te modelin performansını değerlendirmek için kullanılan karmaşıklık matrisleri, sınıflandırma sonuçlarını detaylı bir şekilde ortaya koymaktadır. Eğitim veri seti için elde edilen sonuçları incelediğimizde, Cyst sınıfında 2596 doğru sınıflandırma yapılmışken, Normal sınıfında 3554 ve Tumor sınıfında 1598 doğru tahmin elde edilmiştir. Stone sınıfında ise 963 örnek doğru bir şekilde 1 örnek ise yanlış sınıflandırılmıştır. Bu durum, modelin eğitim veri setinde genel olarak yüksek bir başarı elde ettiğini gösterir. Doğrulama veri setine baktığımızda, Cyst sınıfında 557 doğru tahmin, Normal sınıfında 761, Stone sınıfında 204 ve Tumor sınıfında 342 doğru tahmin elde edilmiştir. Özellikle Stone ve Cyst sınıfları arasında 1 örnek ile sınırlı bir karışıklık gözlemlenmiştir. Test veri setine baktığımızda, Cyst sınıfında 556 doğru tahmin, Normal sınıfında 762, Stone sınıfında 204 ve Tumor sınıfında 343 doğru tahmin elde edilmiştir. Stone ve Cyst sınıfları arasında 2 örnek ile sınırlı bir karışıklık gözlemlenmiştir. Bu sonuçlar, diğer modellerin test verileri kıyaslandığında en az hatalı tahmin eden modelin Poly-CNN modeli olduğu ortaya çıkmaktadır.

Şekil 4.13: Poly-CNN Modeli Eğitim, Doğrulama ve Test Verisi için Karışıklık Matrisi



Tablo 4.29'da modelin eğitim veri seti üzerinde değerlendirilen modelin performansını ayrıntılı bir şekilde incelediğimizde, her bir sınıf için hesaplanan hassasiyet

(precision), duyarlılık (recall) ve F1 skoru değerleri oldukça yüksek sonuçlar göstermektedir. "Cyst" sınıfı için %99,96 hassasiyet, %100 duyarlılık ve %99,98 F1 skoru, bu sınıfa ait örneklerin neredeyse hatasız bir şekilde sınıflandırıldığını gösterir. "Normal" sınıfında ise %100 hassasiyet, duyarlılık ve F1 skoru elde edilmiştir, yani bu sınıfa ait verilerin tamamının doğru bir şekilde sınıflandırıldığı görülmektedir. "Stone" sınıfında %100 hassasiyet, %99,90 duyarlılık ve %99,95 F1 skoru elde edilmiştir. Bu durum, modelin bu sınıfa ait örnekleri doğru bir şekilde sınıflandırdığını, ancak veri setindeki örnek sayısının daha düşük olmasından kaynaklı olarak duyarlılık değerinde biraz düşüş yaşandığını göstermektedir. "Tümör" sınıfında ise yine %100 hassasiyet, duyarlılık ve F1 skoru elde edilmiştir. Toplam accuracy değeri %99,99 olarak görülmektedir, bu da genel olarak modelin veri setini son derece başarılı bir şekilde sınıflandırdığını gösterir. Bu değerlendirmeler, modelin öğrenme sürecinin etkili olduğunu, veri setindeki çeşitli sınıfları başarılı bir şekilde ayırt etme kabiliyetine sahip olduğunu göstermektedir.

Tablo 4.29: Poly-CNN Modeli Eğitim Aşaması Değerlendirme Metrikleri

For Train Data				
	precision	recall	f1-score	support
Cyst	0.9996	1.0000	0.9998	2596
Normal	1.0000	1.0000	1.0000	3554
Stone	1.0000	0.9990	0.9995	964
Tumor	1.0000	1.0000	1.0000	1598
accuracy			0.9999	8712
macro avg	0.9999	0.9997	0.9998	8712
weighted avg	0.9999	0.9999	0.9999	8712

Tablo 4.30'te Test veri seti üzerinde yapılan değerlendirmeye göre, modelin performansı oldukça yüksek sonuçlar göstermektedir. Her bir sınıf için hesaplanan hassasiyet (precision), duyarlılık (recall) ve F1 skoru değerleri oldukça başarılı sonuçlar görülmektedir. "Cyst" sınıfı için elde edilen %99,64 hassasiyet, %100 duyarlılık ve %99,82 F1 skoru, bu sınıfa ait örneklerin model tarafından başarıyla sınıflandırıldığını göstermektedir. "Normal" sınıfında ise %100 hassasiyet, duyarlılık ve F1 skoru elde edilmiştir, yani bu sınıfa ait verilerin tamamının doğru bir şekilde sınıflandırıldığı görülmektedir. "Stone" sınıfında %100 hassasiyet, %99,03 duyarlılık ve %99,51 F1 skoru elde edilmiştir. Bu durum, modelin bu sınıfa ait örnekleri doğru bir şekilde sınıflandırdığını, *ancak veri setindeki örnek sayısının daha düşük olmasından kaynaklı olarak duyarlılık değerinde biraz düşüş yaşandığını göstermektedir*. "Tümör" sınıfında ise yine %100 hassasiyet, duyarlılık ve F1 skoru elde edilmiştir. Toplam accuracy değeri

%99,89 olarak görülmektedir, bu da genel olarak Poly-CNN modelinin test veri setini son derece başarılı bir şekilde sınıflandırdığını gösterir.

Tablo 4.30: Poly-CNN Modeli için Test Aşaması Değerlendirme Metrikleri

For Test Data				
	precision	recall	f1-score	support
Cyst	0.9964	1.0000	0.9982	556
Normal	1.0000	1.0000	1.0000	762
Stone	1.0000	0.9903	0.9951	206
Tumor	1.0000	1.0000	1.0000	343
accuracy			0.9989	1867
macro avg	0.9991	0.9976	0.9983	1867
weighted avg	0.9989	0.9989	0.9989	1867



BEŞİNCİ BÖLÜM
SONUÇ VE TARTIŞMA

5.1. SONUÇ VE TARTIŞMA

Sonuç olarak, Tablo 5.1'de her bir modelin eğitim, doğrulama ve test veri setlerinde elde ettiği sayısal sonuçlar detaylı bir şekilde incelenmiştir. Bu sonuçlar, modellerin performansını değerlendirmek ve karşılaştırmak amacıyla elde edilen çeşitli metrikleri içermektedir. Eğitim setinde elde edilen doğruluk oranları, doğrulama setindeki performans, test setindeki hassasiyet ve özgüllük değerleri gibi önemli metrikler, her bir modelin sınıflandırma yetenekleri hakkında bilgi vermektedir. "ANN" (Yapay Sinir Ağı) modeli, eğitim setinde %99,97 doğrulama setinde %99,73 ve test setinde %99,78 doğruluk oranlarına ulaşarak yüksek bir performans sergilemektedir. Ayrıca, bu modelin sınıflandırma performansını değerlendiren hassasiyet, geri çağırma ve F1 skorları da oldukça yüksektir, bu da genel başarısını desteklemektedir. "Classic CNN" modeli, eğitim setinde %99,86, doğrulama setinde %99,57 ve test setinde %99,57 doğruluk oranlarına sahiptir. Ancak, "ALEXNET" modeli, diğer modellere göre daha düşük performans sergilemektedir. Eğitim setinde %92,11, doğrulama setinde %89,93 ve test setinde %89,44 doğruluk oranları, bu modelin bu özel görevde diğer modellere göre daha zayıf olduğunu göstermektedir. "VGG16" ve "VGG19" modelleri, genel doğruluk bakımından başarılı sonuçlar elde etmiştir. Her iki model de %96'nın üzerinde doğruluk oranlarına sahip olup, sağlık teşhisi konusunda güçlü bir potansiyeli yansıtmaktadır.

Son olarak, çalışmada önerdiğimiz "Poly-CNN" modeli eğitim setinde %99,97 doğrulama setinde %99,84 ve **test veri setinde %99,94 doğruluk oranlarına ulaşmıştır. Poly-CNN modelinin en başarılı, doğruluk, hassasiyet ve özgüllük değerleri ile öne çıktığı gözlemlenmektedir.** Bu sayısal sonuçlar, modellerin eğitim, doğrulama ve test aşamalarında ne kadar etkili olduklarına dair önemli bilgiler sunmaktadır. Bu bağlamda, Tablo 5.1'deki sonuçlar, her bir modelin böbrek sağlığı teşhisi konusundaki performansını karşılaştırmak için temel bir referans sağlamaktadır.

Tablo 5.1: Tüm Modellerin Başarı (Accuracy) Oranları

Model	Train (Eğitim)	Validation (Doğrulama)	Test
ANN	0,999770	0,997321	0,997857
Classic CNN	0,998622	0,995715	0,995715
ALEXNET	0,921143	0,899303	0,894483
VGG16	0,980716	0,973219	0,965720
VGG19	0,998852	0,995179	0,997857
Poly-CNN	0,999770	0,998393	0,999464

KAYNAKÇA

- Ackley, D. H., Hinton, G. E. & Terrence, J. S. (1985). A learning algorithm for boltzmann machines. *Cognitive Science*, 9(1), 147-169. https://doi.org/10.1207/s15516709cog0901_7.
- Alakwaa, W., Nassef, M., & Badr, A. (2017). Lung cancer detection and classification with 3D convolutional neural network (3D-CNN). *International Journal of Advanced Computer Science and Applications*, 8(8), 409-417. <https://doi.org/10.14569/IJACSA.2017.080853>.
- Alzu'bi, D., vd. (2022). Kidney Tumor Detection and Classification Based on Deep Learning Approaches A New Dataset in CT Scans. *Journal of Healthcare Engineerin*, 2022, 1-22. <https://doi.org/10.1155/2022/3861161>.
- Amidi, A., & Amidi, S. (2023). Convolutional Neural Networks cheatsheet. Stanford University. Retrieved from: <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-convolutional-neural-networks>.
- Arık, N., & Dilek, M. (2023). Kronik Böbrek Hastalığı Nedir. Erişim adresi: <https://www.drnurolarik.com/tr/kronik-bobrek-hastaligi-nedir-a>.
- Bastien, F., vd. (2012). Theano: new features and speed improvements. *arXiv preprint arXiv:1211.5590*. <https://doi.org/10.48550/arXiv.1211.5590>.
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and Trends in Machine Learning*, 2(1), 1–127. <https://doi.org/10.1561/22000000006>.
- Bhaskar, N., & Manikandan, S. (2019). A deep-learning-based system for automated sensing of chronic kidney disease. *IEEE Sensors Letters*, 3(10), 1-4. <https://doi.org/10.1109/LSSENS.2019.2942145>.
- Bingol, H., vd. (2023). Automatic classification of kidney CT images with relief based novel hybrid deep model. *PeerJ Computer Science*, 9:e1717. <https://doi.org/10.7717/peerj-cs.1717>.
- Black, K., vd. (2020). Deep learning computer vision algorithm for detecting kidney stone composition. *BJU international*, 125(6), 920-924. <https://doi.org/10.1111/bju.15035>.

- Böbrek Taş Hastalığı. (2023, 25 Ekim). Urokllinik. Erişim Adresi: <https://www.urokllinik.com.tr/bobrek-tas-hastaligi>.
- Brown, S. (2023). Machine learning explained. Stanford University. Retrieved from: <https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained>.
- Caniklioğlu, M., vd. (2022). Böbrek fonksiyon bozukluğu olan hastalarda endoskopik üreter taşı cerrahisinin glomerüler filtrasyon hızı üzerine etkisi. *The Medical Journal of Mustafa Kemal University*, 13(46), 107-112. <https://doi.org/10.17944/mkutfd.930695>.
- Cao, S., & Nevatia, R. (2016). Exploring Deep Learning Based Solutions in Fine Grained Activity Recognition in the Wild. *2016 23rd International Conference on Pattern Recognition (ICPR)*, Mexico, 384-389. <https://doi.org/10.1109/ICPR.2016.7899664>.
- Chavan, J., vd. (2017). A Survey of Deep-Learning Frameworks. *2017 International Conference on Inventive Systems and Control (ICISC)*, India, 19-20. <http://doi.org/10.1109/ICISC.2017.8068684>.
- Coates, A. Ng, A. & Lee, H. (2011). An Analysis of Single-Layer Networks in Unsupervised Feature Learning. *Proceedings of Machine Learning Research*, 15, 215–223.
- Columbia Engineering Boot Camps. (2023, 20 Kasım). Columbia University. Retrieved from: <https://bootcamp.cvn.columbia.edu/blog/machine-learning-applications>.
- CT Kidney Dataset. (2023, 06 Haziran). Retrieved from: <https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone>.
- Cruz L. B., vd. (2022). Kidney tumor segmentation from computed tomography images using DeepLabv3+2.5D model. *Expert Systems with Applications*, 192. <https://doi.org/10.1016/j.eswa.2021.116270>.
- Dalal, N., & Triggs, B. (2005). Histograms of Oriented Gradients for Human Detection. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, USA, 886-893. <http://doi.org/10.1109/cvpr.2005.177>.
- Doulamis, N., & Voulodimos, A. (2016). FAST-MDL: Fast Adaptive Supervised Training of Multi-Layered Deep Learning Models for Consistent Object Tracking

- and Classification. *2016 IEEE International Conference on Imaging Systems and Techniques, Turkiye*, 318-323. <https://doi.org/10.1155/2018/8141259>.
- Fukushima, K. (1980). A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36, 193–202. <https://doi.org/10.1007/BF00344251>.
- Graves, A., & Jaitly, N. (2014). Towards End-To-End Speech Recognition with Recurrent Neural Networks. *ICML*, 32(2), 1764–1772.
- Green, J. B., vd. (2023). Design of the COmbination effect of FInerenone and EmpaglifloziN in participants with chronic kidney disease and type 2 diabetes using a UACR Endpoint study. *Nephrology Dialysis Transplantation*, 38(4), 894-903. <https://doi.org/10.1093/ndt/gfac198>
- Hebb, D. O. (1949). *The organization of behavior a neuropsychological theory*. New York: John Wiley and Sons.
- Heller, N., vd. (2021). The state of the art in kidney and kidney tumor segmentation in contrast-enhanced CT imaging: Results of the KiTS19 challenge. *Medical image analysis*, 67, 101821. <https://doi.org/10.1016/j.media.2020.101821>.
- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the Dimensionality of Data with Neural Networks. *Science*, 313(5786), 504-507. <https://doi.org/10.1126/science.1127647>.
- Hinton, G. E., Simon O., & Yee-Whye T. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural Comput*, 18(7), 1527-1554. <https://doi.org/10.1162/neco.2006.18.7.1527>.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>.
- Islam, M. N., vd. (2022). Vision transformer and explainable transfer learning models for auto detection of kidney cyst stone and tumor from CT-radiography. *Scientific reports*, 12(1), 1-14. <https://doi.org/10.1038/s41598-022-15634-4>.
- Keras. (2023, 20 Kasım). In Wikipedia. Retrieved from: <https://tr.wikipedia.org/wiki/Keras>.

- Kidney Biopsy. (2023, 15 Kasım). Mayo Clinic. Retrieved from: <https://www.mayoclinic.org/tests-procedures/kidney-biopsy/about/pac-20394494>.
- Kidney Cyst. (2023, 05 Kasım). Mayo Clinic. Retrieved from: <https://www.mayoclinic.org/diseases-conditions/kidney-cysts/multimedia/kidney-cyst/img-20007545>.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Image Net Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25, 1097-1105.
- Larochelle, H., & Bengio, Y., (2008). Classification using discriminative restricted Boltzmann machines. *25th international conference on Machine learning – ICML, Finland*, 536–543. <https://doi.org/10.1145/1390156.1390224>.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436–444. <https://doi.org/10.1038/nature14539>.
- LeCun, Y., vd. (1990). Handwritten Digit Recognition with a Back-Propagation Network. *Advances in Neural Information Processing Systems*, 396–404.
- LeCun, Y., vd. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324. <http://doi.org/10.1109/5.726791>.
- Liou, C. Y. Vd. (2014). Autoencoder for words. *Neurocomputing*, 139, 84–96. <http://doi.org/10.1016/j.neucom.2013.09.055>.
- Long, J., Shelhamer, E. & Darrell, T. (2015). Fully Convolutional Networks for Semantic Segmentation. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR), USA*, 3431-3440. <http://doi.org/10.1109/CVPR.2015.7298965>.
- Mamani, G. E. H., vd. (2023). Kidney abnormality segmentation in thorax-abdomen CT scans. *arXiv preprint arXiv:2309.03383*. <https://doi.org/10.48550/arXiv.2309.03383>.
- Matplotlib. (2023, 20 Kasım). In Wikipedia. Retrieved from: <https://tr.wikipedia.org/wiki/Matplotlib>

- McCulloch, W.S. & Pitts, W. A. (1943). logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115–133.
<https://doi.org/10.1007/BF02478259>.
- National Health Service. (2023, 20 Ekim). Retrieved from:
<https://www.nhs.uk/conditions/kidney-stones>
- Netter F. H. (1987). Anatomy structure and embryology In Kidneys Ureters and Unirary Bladder. *The CIBA Collection of Medical Illustration*, 37, 2-35.
- Nithya, A., vd. (2020). Kidney disease detection and segmentation using artificial neural network and multi-kernel k-means clustering for ultrasound images. *Measurement*, 149, 106952.
<https://doi.org/10.1016/j.measurement.2019.106952>.
- Numpy. (2023, 2 Kasım). In Wikipedia. Retrieved from:
<https://en.wikipedia.org/wiki/NumPy>.
- Oquab, M., vd. (2015). Is object localization for free? weakly-supervised learning with convolutional neural networks. *In Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR), USA*, 685-694.
<https://doi.org/10.1109/CVPR.2015.7298668>
- Ouyang, W., vd. (2017). DeepID-Net: Object Detection with Deformable Part Based Convolutional Neural Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(7), 1320-1334.
<https://doi.org/10.1109/tpami.2016.2587642>.
- Pandas. (2023, 20 Kasım). In Wikipedia. Retrieved from:
<https://tr.wikipedia.org/wiki/Pandas>.
- Pfizer. (2023, 01 Kasım). Pfizer. Erişim adresi:
<https://www.pfizer.com.tr/sagliginiz/hastaliklar-ve-tedavileri/renal-hucrelilikarsinom>.
- Rogel-Salazar, J., (2023, 15 Kasım). Tensorflow PyTorch or Keras for Deep Learning. Domino. Retrieved from: <https://domino.ai/blog/tensorflow-pytorch-or-keras-for-deep-learning>

- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>.
- Rumelhart, D.E., Hinton, G.E., & Williams, R.J. (1986). Learning representations by back-propagating errors. *Nature*, 323, 533-536. <https://doi.org/10.1038/323533a0>.
- Sabarinathan, D., Parisa Beham, M., & Mansoor Roomi, S. M. (2020). Hyper vision net: kidney tumor segmentation using coordinate convolutional layer and attention unit. *NCVPRIPG*, 7, 609-618. <http://doi.org/10.24926/548719.076>.
- Salakhutdinov, R., & Hinton, G. (2009). Deep Boltzmann Machines. *Proceedings of the Twelfth International Conference on Artificial Intelligence and Statistics, USA*, 448-455. https://doi.org/10.1007/978-3-642-35289-8_33.
- Santosh, K., Das, N., & Ghosh, S. (2022). Deep learning: a review. *Deep Learning Models for Medical Imaging*, 1, 29-63. <http://doi.org/10.1016/B978-0-12-823504-1.00013-1>.
- Sasikaladevi, N., & Revathi, A. (2024). Digital twin of renal system with CT-radiography for the early diagnosis of chronic kidney diseases. *Biomedical Signal Processing and Control*, 88, 105632. <https://doi.org/10.1016/j.bspc.2023.105632>.
- Smolensky, P. (1986). Information Processing in Dynamical Systems: Foundations of Harmony Theory. *Parallel Distributed Processing*, 1, 194–281.
- Sudharson, S., & Kokil, P. (2020). An ensemble of deep neural networks for kidney ultrasound image classification. *Computer methods and programs in biomedicine*, 197, 105709. <https://doi.org/10.1016/j.cmpb.2020.105709>.
- Sumida, K., vd., (2020). Conversion of urine protein–creatinine ratio or urine dipstick protein to urine albumin–creatinine ratio for use in chronic kidney disease screening and prognosis: an individual participant–based meta-analysis. *Annals of internal medicine*, 173(6), 426-435. <https://doi.org/10.7326/M20-0529>.
- TensorFlow. (2023, 20 Kasım). In Wikipedia. Retrieved from: <https://tr.wikipedia.org/wiki/TensorFlow>.
- Toshev, A., & Szegedy, C. (2014). Deeppose: Human pose estimation via deep neural networks. *In Proceedings of the IEEE conference on computer vision and pattern*

- recognition, Singapore, 1653-1660. https://doi.org/10.1007/978-981-10-8108-8_6.*
- Türk F., Lüy M., & Barışçı N. (2020). Kidney and Renal Tumor Segmentation Using a Hybrid V-Net-Based Model, *Mathematics*, 8(10), 1-17. <https://doi.org/10.3390/math8101772>.
- Tüzün, B. N., & Özdemir, D. (2023). Classification of Brain Tumors with Deep Learning Models. *Journal of Scientific Reports-A*, 54, 296-306. <http://dx.doi.org/10.59313/jsr-a.1293119>.
- Tygart, M., vd. (2016). A Mathematical Motivation for Complex-Valued Convolutional Networks. *Neural Computation*, 28(5), 815-825. https://doi.org/10.1162/NECO_a_00824.
- Uçar, E. (2022). Classification of myositis from muscle ultrasound images using deep learning. *Biomedical Signal Processing and Control*, 71, 103277. <https://doi.org/10.3389%2Ffmed.2023.1286085>.
- Urology Care. (2023, 28 Ekim). Urology Health. Retrieved from: <https://www.urologyhealth.org/urology-a-z/k/kidney-cancer>.
- Urinalysis Dipstick. (2023, 28 Ekim). Bristol. Retrieved from: <https://www.bristol.ac.uk/media-library/sites/vetscience/documents/clinical-skills/Urinalysis%20Dipstick.pdf>.
- Üstündağ, Y., vd. (2013). Süt çocuklarında kültür pozitifliği öngörüsünde idrar analiz sonuçlarının değerlendirilmesi. *Türk Klinik Biyokimya Dergisi*, 11, 87-92. <http://dx.doi.org/10.5222/buchd.2015.088>.
- Voulodimos, A., vd. (2018). Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*, 2018, 1-13. <http://dx.doi.org/10.1155/2018/7068349>.
- Werbos, P. J. (1974). *Beyond regression : New tools for prediction and analysis in the behavioral sciences*. Harvard University, Cambridge
- Zhao, Z. Q., vd. (2019). Object detection with deep learning: A review. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11), 3212-3232. <https://doi.org/10.1109/tnnls.2018.2876865>.

DİZİN

A

ALEXNET 1, 28, 37, 38, 39, 54, 55, 58,
59, 71
ANN... 1, 28, 33, 34, 35, 48, 49, 50, 51,
52, 71, 76

B

Bilgisayarlı Tomografi..... 16, 25
BT..... 5, 6, 25

C

Caffe..... 21
Classic CNN... 1, 28, 35, 36, 51, 52, 53,
54, 71
CNN. 1, 4, 5, 6, 7, 9, 20, 21, 22, 30, 31,
32, 33, 36, 37, 39, 41, 42, 65, 71, 72,
77
Cystv, 25, 26, 27, 39, 49, 50, 51, 52, 53,
54, 56, 57, 58, 59, 60, 61, 63, 64, 67,
68, 69, 73

D

DBN 23
DeepLearning4j..... 21
Derin İnanç Ağları..... 23
Destek Vektör Makineleri 23

E

ESA 6, 29, 30
evrişim..... 21, 31, 32, 35, 39, 41, 42
Evrişimli Sinir Ağları.. 5, 20, 21, 22, 30,
37, 38, 39

G

GPU..... 20, 21

K

Karışıklık matrisleri..... 56, 59, 63
Kist 25, 57

P

Poly-CNN. 1, 28, 42, 43, 44, 65, 66, 67,
68, 69, 71

R

RBM 22, 23
RNN..... 22

S

Stone. 25, 26, 27, 39, 49, 50, 51, 52, 53,
54, 56, 57, 58, 60, 61, 63, 64, 67, 68,
69, 73
SVM 5, 23, 76

T

Taş 11, 25, 58, 72
TensorFlow..... 20, 21, 28, 76
Theano 21, 72
Torch 21
Tümör 25, 58

V

VGG16 1, 4, 5, 6, 28, 39, 40, 41, 58, 59,
60, 61, 64, 69, 71
VGG19 ... xv, 1, 5, 6, 28, 41, 42, 61, 62,
63, 71

Y

Yapay Sinir Ağı. 1, 4, 34, 36, 37, 39, 41,
71
Yapay Sinir Ağları..... 19, 33, 34, 49