

**LENF KANSERİ GÖRÜNTÜLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE
SINIFLANDIRILMASI**

EMİNE ÖZGÜR

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Doç. Dr. Ahmet SAYGILI

2022

T.C.
TEKİRDAĞ NAMIK KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



LENF KANSERİ GÖRÜNTÜLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE
SINIFLANDIRILMASI

EMİNE ÖZGÜR

ORCID: 0000-0001-5606-0967

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ
Danışman: Doç. Dr. Ahmet SAYGILI

EKİM-2022
Her hakkı saklıdır.

ARAŐTIRMA FONU DESTEĐİ BEYANI

Tekirdađ Namık Kemal Üniversitesi Bilgisayar Mühendisliđi Anabilim Dalında Yüksek Lisans Tezi olarak sunulan ve Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışması; Tekirdađ Namık Kemal Üniversitesi BAP tarafından NKUBAP.06.GA.21.317 numaralı proje ile desteklenmiştir.

Emine ÖZGÜR

24/11/2022



ÖZET

LENF KANSERİ GÖRÜNTÜLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE SINIFLANDIRILMASI

Emine ÖZGÜR

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Doç. Dr. Ahmet SAYGILI

Lenf kanseri veya diğer bir adıyla lenfoma, vücudun savunma hücrelerinin kanserleşerek kontrolsüz çoğalmasıdır. Lenfoma, kan kanserleri grubunda yer almaktadır ve bu grupta yer alan diğer kanserlere göre görülme sıklığı daha fazladır. Bu hastalıkta erken ve doğru teşhis çok önemlidir. Tehlikeli ve ciddi bir kanser türü olan lenfoma, duruma göre ölümle sonuçlanabilir. Uzmanların erken ve doğru teşhis yapabilmesine yardımcı olmak için uzman destek sistemleri geliştirilmektedir. Sağlık alanındaki uzman destek sistemler, belli bir hastalığa ait verileri makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak sınıflandırılmasını sağlar. Literatürdeki çalışmalar incelendiğinde uzman destek sistemlerinin başarıları görülmektedir. Çalışmada lenf kanserine ait histopatolojik görüntüleri içeren bir veri setiyle çalışıldı. Veri setinde CLL, FL ve MCL türünde lenfomalara ait görüntüler bulunmaktadır. Veri setinde artırım yapmak için 90, 180, 270 ve 360 derecelik açılarda dönme işlemi yapılmıştır. Bu görüntülerdeki özellikleri çıkarmak için ilk yaklaşımda GLCM ve diğer yaklaşımlarda transfer öğrenme metoduyla derin öğrenme mimarileri kullanılmıştır. Özellik seçimi ve boyut azaltımı için PCA kullanılmıştır. Sınıflandırma aşamasında; makine öğrenmesi algoritmalarından RF, KNN, NB, DT ve derin öğrenme mimarilerinden VGG16, ResNet50 ve DenseNet201 kullanılmıştır. Model eğitimleri ikili ve üçlü sınıflar için ayrı ayrı yapılarak sonuçlar incelenmiştir. MCL ve CLL türündeki lenfomalara kendi içerisinde ayırt edilmeleri zordur. Bu yüzden bu lenfomanın sınıflandırma sonuçları diğer sınıflandırma sonuçlarına göre daha düşüktür. FL, diğer iki lenfomayla özellikleri ayırt edilebileceği için FL ile sınıflandırma sonuçları yüksektir. Çalışmada en yüksek başarıyı FL ve CLL'yi %94 doğrulukla sınıflandırarak DenseNet201 göstermiştir.

Anahtar Kelimeler: Lenfoma, Makine öğrenmesi, Derin öğrenme, Histopatolojik görüntü, Transfer öğrenme, GLCM

ABSTRACT

CLASSIFICATION OF LYMPH CANCER IMAGES WITH MACHINE LEARNING METHODS

Emine ÖZGÜR

Department of Computer Engineering

MSc. Thesis

Supervisor: Assoc. Prof. Dr. Ahmet SAYGILI

Lymph cancer, or lymphoma, is the uncontrolled proliferation of the body's defense cells by becoming cancerous. Lymphoma is in the group of blood cancers and its frequency is higher than other cancers in this group. Early and correct diagnosis is very important in this disease. Lymphoma, a dangerous and serious type of cancer, can result in death depending on the situation. Specialist support systems are being developed to help specialist early and correct diagnosis. Specialist support systems in the healthcare field provide classification of the data of a certain disease using machine learning and deep learning methods. When the studies in the literature are examined, wonderwork of specialist support systems are seen. In this study, a dataset containing histopathological images of lymph cancer was studied. The dataset includes images of lymphomas of the CLL, FL and MCL types. In order to increase the dataset, rotation at 90, 180, 270 and 360 degree angles was performed. In order to extract features from these images, GLCM was used in the first approach and transfer learning method was used in other approaches. PCA was used for feature selection and dimension reduction. At the classification stage; machine learning algorithms RF, KNN, NB, DT and deep learning architectures VGG16, ResNet50 and DenseNet201 were used. Model trainings were performed separately for double and triple classes and the results were examined. It is difficult to distinguish between MCL and CLL lymphomas. Therefore the classification results of this lymphoma are lower than the other classification results. The results of the classification with FL are high because FL can be distinguished from the other two lymphomas. DenseNet201 was over performed in classifying FL and CLL with 94% accuracy rate.

Keywords: Lymphoma, Machine learning, Deep learning, Histopathological image, Transfer learning, GLCM

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ÇİZELGELER DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
SİMGELER DİZİNİ	ix
KISALTMALAR DİZİNİ	x
TEŞEKKÜR	xii
1. GİRİŞ	1
1.1 Literatür Özeti	3
1.2 Çalışmanın Amacı ve Kapsamı	7
1.3 Çalışmada İzlenen Metodoloji	7
1.4 Çalışmanın Bilime Katkıları	10
2. LENFOMA	11
2.1 Lenfoma Belirtileri	11
2.2 Lenfoma Türleri.....	12
2.2.1 Hodgkin Lenfoma (HL)	12
2.2.1.1 Klasik Hodgkin Lenfoma (cHL)	13
2.2.1.2 Nodüler Lenfosit Baskın Hodgkin Lenfoma (NLBHL)	13
2.2.2 Hodgkin Olmayan Lenfoma (NHL)	13
2.2.2.1 CLL.....	14
2.2.2.2 FL	14
2.2.2.3 MCL.....	14
2.3 Lenfoma Teşhisi ve Tedavisi	15
2.4 Lenfoma Yaşam Süresi.....	15
2.5 Patolojik Görüntüler.....	16
3. GÖRÜNTÜ İŞLEME	18
3.1 Gözün Görmesi	19
3.2 Görüntü İşlemeyle İlgili Kavramlar	20
3.2.1 Piksel	20
3.2.2 Çözünürlük	21
3.2.3 Renk.....	21
3.2.4 Karşıtlık.....	21

3.2.5 Gürültü	21
3.3 Pikseller Arası İlişkiler	22
3.4 Görüntü İşleme Kullanım Alanları.....	23
3.5 Görüntünün Sayısallaştırılması.....	23
3.6 Görüntü İşleme Teknikleri	23
3.6.1 Keskinleştirme.....	24
3.6.2 Bulanıklaştırma	24
3.6.3 Gürültü Temizleme.....	24
3.6.4 Kenar Bulma.....	24
3.6.5 Histogram Eşitleme	25
3.6.6 Morfolojik İşlemler.....	25
3.6.7 Bölütleme	25
3.6.8 Özellik Çıkarımı.....	25
3.6.8.1 GLCM.....	25
3.6.8.1.1 Korelasyon.....	27
3.6.8.1.2 Homojenlik.....	27
3.6.8.1.3 Kontrast	27
3.6.8.1.4 ASM.....	27
3.6.8.1.5 Enerji	28
3.6.8.1.6 Benzersizlik	28
3.6.8.1.7 Entropi.....	28
3.6.9 Özellik Seçimi	28
3.6.9.1 PCA	28
3.7 Sağlıkta Görüntü İşleme	29
4. YAPAY ZEKA	31
4.1 Makine Öğrenmesi Yöntemleri	31
4.1.1 Makinelerin Öğrenimi	32
4.1.2 Makine Öğrenmesi Çeşitleri.....	33
4.1.2.1 Denetimli Öğrenme	33
4.1.2.1.1 Naive Bayes (NB).....	34
4.1.2.1.2 Decision Tree (DT).....	34
4.1.2.1.3 Random Forest (RF).....	35
4.1.2.1.4 KNN	35
4.1.2.2 Denetimsiz Öğrenme	36
4.1.2.2.1 K-Means Algoritması.....	36

4.1.2.3 Pekiştirmeli Öğrenme.....	37
4.1.3 Algoritmalarda Kullanılan Uzaklık Ölçüleri.....	37
4.1.3.1 Öklid Uzaklığı.....	37
4.1.3.2 Manhattan Uzaklığı.....	38
4.1.3.3 Minkowski Uzaklığı.....	38
4.1.4 Makine Öğrenmesi Süreci Adımları.....	38
4.1.4.1 İşin Anlaşılması.....	39
4.1.4.2 Verinin Anlaşılması.....	39
4.1.4.3 Verinin Hazırlanması.....	40
4.1.4.4 Modelleme.....	40
4.1.4.5 Model Seçimi ve Değerlendirme.....	41
4.1.4.6 Canlıya Alma.....	41
4.1.5 Derin Öğrenme Yöntemleri.....	41
4.1.5.1 Yapay Sinir Ağları.....	42
4.1.5.1.1 Yapay Sinir Ağlarının Kullanım Alanları.....	43
4.1.5.2 Derin Öğrenme Mimarileri.....	44
4.1.5.2.1 ESA.....	44
4.1.5.2.2 GAN.....	45
4.1.5.3 Derin Öğrenme Mimarilerindeki Katmanlar.....	45
4.1.5.3.1 Giriş Katmanı.....	45
4.1.5.3.2 Konvolüsyon Katmanı.....	46
4.1.5.3.3 Aktivasyon Katmanı.....	46
4.1.5.3.4 Havuzlama Katmanı.....	47
4.1.5.3.5 Düzleştirme Katmanı.....	47
4.1.5.3.6 Ezberleme Katmanı.....	47
4.1.5.3.7 Tam Bağlantı Katmanı.....	47
4.1.5.3.8 Sınıflandırma Katmanı.....	48
4.1.5.4 Hazır ESA Mimarileri.....	48
4.1.5.4.1 VGGNet.....	48
4.1.5.4.2 ResNet.....	49
4.1.5.4.3 DenseNet.....	50
4.1.5.5 ESA ile Transfer Öğrenme.....	50
5. DENEYSEL ÇALIŞMALAR.....	52
5.1 Çalışmada Kullanılan Veri Seti.....	52
5.2 Python ve Kullanılan Kütüphaneler.....	54

5.2.1 Python.....	54
5.2.2 Sklearn.....	55
5.2.3 OpenCV.....	55
5.2.4 Numpy.....	56
5.2.5 Tensorflow.....	56
5.2.6 Keras.....	56
5.2.7 Skimage.....	57
5.2.8 Pandas.....	57
5.2.9 OS.....	57
5.3 Visual Studio 2019.....	57
5.4 Performans Metrikleri.....	58
5.5 Özellik Çıkarımı.....	59
5.5.1 GLCM.....	59
5.5.2 Transfer Öğrenme.....	59
5.6 Özellik Seçimi.....	63
5.7 Çalışmadaki Yaklaşımlar ve Sonuçları.....	63
6. SONUÇ VE ÖNERİLER.....	75
KAYNAKLAR.....	77

ÇİZELGELER DİZİNİ

Çizelge 2.1. FL, MCL ve CLL'ye ait özellikler	15
Çizelge 5.1. Veri arttırım öncesi GLCM kullanarak sınıflandırma sonuçları	64
Çizelge 5.2. Veri arttırım öncesi histogramı eşitlenmiş görüntülere GLCM uygulanması sonrası sınıflandırma sonuçları	64
Çizelge 5.3. Veri arttırım öncesi GLCM ve PCA kullanarak sınıflandırma sonuçları.....	65
Çizelge 5.4. Veri arttırım öncesi histogramı eşitlenmiş görüntülere GLCM ve PCA uygulaması sonrası sınıflandırma sonuçları	65
Çizelge 5.5. Veri arttırım sonrası GLCM uygulayıp sınıflandırma yapıldığındaki sonuçlar ...	66
Çizelge 5.6. Veri arttırım sonrası histogramı eşitlenmiş görüntülere GLCM uygulaması sonrası sınıflandırma sonuçları	66
Çizelge 5.7. Veri arttırım sonrası GLCM ve PCA uygulayıp sınıflandırma yapıldığındaki sonuçlar.....	67
Çizelge 5.8. Veri arttırım sonrası histogramı eşitlenmiş görüntülere GLCM ve PCA uygulayıp sınıflandırma yapıldığındaki sonuçlar	67
Çizelge 5.9. Veri arttırım öncesi VGG16 ve PCA() uygulandıktan sonraki sınıflandırma sonuçları	68
Çizelge 5.10. Veri arttırım öncesi VGG16 ve PCA(0,5) uygulandıktan sonraki sınıflandırma sonuçları	68
Çizelge 5.11. Veri arttırım öncesi VGG16 ve PCA(0,4) uygulandıktan sonraki sınıflandırma sonuçları	69
Çizelge 5.12. Veri arttırım sonrası VGG16 ve PCA() uygulandıktan sonraki sınıflandırma sonuçları	69
Çizelge 5.13. Veri arttırım öncesi VGG16 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar	71
Çizelge 5.14. Veri arttırım sonrası VGG16 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar	71
Çizelge 5.15. Veri arttırım öncesi DenseNet201 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar	72
Çizelge 5.16. Veri arttırım sonrası DenseNet201 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar	72
Çizelge 5.17. Veri arttırım öncesi ResNet50 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar	73
Çizelge 5.18. Veri arttırım sonrası ResNet50 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar	73
Çizelge 5.19. Çalışmamızın literatürdeki benzer çalışmalarla kıyaslanması	74

ŞEKİLLER DİZİNİ

Şekil 1. 1. Çalışmadaki ilk yaklaşımın akış şeması.....	8
Şekil 1. 2. Çalışmadaki ikinci yaklaşımın akış şeması.....	9
Şekil 1. 3. Çalışmadaki üçüncü yaklaşımın akış şeması.....	9
Şekil 2. 1. Lenf bezlerinin bulunduğu yerlerin gösterimi.....	11
Şekil 2. 2. Örnek lenfoma patolojik görüntüsü.....	17
Şekil 3. 1. Görüntü işleme aşamaları.....	18
Şekil 3. 2. Gözde görme işleminin şeması.....	20
Şekil 3. 3. Kesiti alınmış görselin piksel değerlerinin gösterimi.....	20
Şekil 3. 4. RGB formatındaki görüntünün kanallarına ayrıldığındaki halleri.....	21
Şekil 3. 5. Bir pikselin komşuluklarını P temsiliyle gösteren şema.....	22
Şekil 3. 6. Bir pikselin komşuluklarını koordinatlarıyla gösteren şema.....	22
Şekil 3. 7. Bir görüntünün sayısallaştırılmasının şeması.....	23
Şekil 3. 8. 4x4'lük bir görüntüden elde edilen üç farklı yöndeki GLCM.....	26
Şekil 3. 9. GLCM şeması.....	26
Şekil 4. 1. Yapay zeka ve kapsadığı alanların şeması.....	31
Şekil 4. 2. Yapay zeka ve bilgisayarın ilişkisini gösteren temsili şema.....	32
Şekil 4. 3. DT algoritmasının yapısı.....	34
Şekil 4. 4. Örnek bir RF modeli.....	35
Şekil 4. 5. KNN algoritmasının sınıf belirleme işlemi şeması.....	36
Şekil 4. 6. K-Means algoritmasının akış şeması.....	37
Şekil 4. 7. CRISP-DM adımları ve akışı.....	39
Şekil 4. 8. Sıçramalı ve kademeliye ek sıçramalı iyileştirme.....	41
Şekil 4. 9. Derin öğrenme mimarisi.....	42
Şekil 4. 10. Yapay sinir ağlarının matematiksel gösterimi.....	43
Şekil 4. 11. Biyolojik sinir hücresi ve yapay sinir hücresinin modellenmesi.....	43
Şekil 4. 12. ESA'nın genel mimarisi.....	44
Şekil 4. 13. GAN çalışma prensibinin şeması.....	45
Şekil 4. 14. Aktivasyon fonksiyonları.....	46
Şekil 4. 15. Bir ESA üzerinde dropout katmanının uygulaması.....	47
Şekil 4. 16. VGG ağ konfigürasyonu.....	49
Şekil 4. 17. ResNet ağ konfigürasyonu.....	49
Şekil 4. 18. DenseNet'te bir dense katmanının temel mimarisi.....	50
Şekil 4. 19. DenseNet ağ konfigürasyonu.....	50
Şekil 4. 20. Transfer öğrenme akış şeması.....	51
Şekil 4. 21. ESA ağ konfigürasyonu.....	51
Şekil 5. 1. Veri setinde bulunan orijinal görüntülerin bir kısmı.....	52
Şekil 5. 2. Veri artırımı öncesi veri setindeki sınıflara göre görüntülerin dağılımı.....	53
Şekil 5. 3. Bir histopatolojik görüntünün belirtilen açılarda döndürülmüş halleri.....	53
Şekil 5. 4. Veri artırımı sonrası veri setindeki sınıflara göre görüntülerin dağılımı.....	54
Şekil 5. 5. Visual Studio 2019 logosu.....	58
Şekil 5. 6. İkili sınıflandırma için CM.....	58
Şekil 5. 7. VGG16 mimarisinin son hali.....	61
Şekil 5. 8. DenseNet201 mimarisinin son hali.....	62
Şekil 5. 9. ResNet50 mimarisinin son hali.....	62
Şekil 5. 10. Çalışmadaki birinci ve ikinci yaklaşımın birlikte bulunduğu akış şeması.....	70
Şekil 5. 11. Çalışmadaki son yaklaşımın görselleri eklenmiş akış şeması.....	71

SİMGELER DİZİNİ

Σ	Toplama Sembolü
$ $	Mutlak Değer
$\sqrt{\quad}$	Karekök
μ	Ortalama
σ	Standart Sapma
N	Neighborhood (Komşuluk)



KISALTMALAR DİZİNİ

Acc	Accuracy (Doğruluk)
ASM	Angular Second Moment
AUC	Area Under the ROC Curve
BBN	Bayessian Belief Networks
CB	Centro Blast
cHL	Classic Hodgkin Lymphoma
CLL	Chronic Lymphocytic Leukemia (Kronik Lenfositik Lösemi)
CM	Confusion Matrix (Karışıklık Matrisi)
DNA	Deoksirübo Nükleik Asit
DT	Decision Tree (Karar Ağacı)
E	Eosin
ELM	Extreme Learning Machine (Aşırı Öğrenme Makinesi)
ESA	Evrişimli Sinir Ağı
FL	Follicular Lymphoma (Foliküler Lenfoma)
FN	False Negative (Hatalı Negatif)
FP	False Positive (Hatalı Pozitif)
G/Ç	Giriş/Çıkış
GB	GigaByte
H	Hematoksilen
HE	Hematoksilen Eosin
HL	Hodgkin Lymphoma
HSV	Hue Saturation Value
IDE	Integration Development Environment (Entegre Geliştirme Ortamı)
LPQ	Local Phase Quantization (Yerel Faz Niceleme)
MCL	Mantle Cell Lymphoma (Mantle Hücreli Lenfoma)
MR	Magnetic Resonance
NB	Naive Bayes
NHL	Non-Hodgkin Lymphoma
NLBHL	Nodüler Lenfosit Baskın Hodgkin Lenfoma
PCA	Principal Components Analysis (Temel Bileşenler Analizi)
PET	Positron Emission Tomography (Pozitron Emisyon Tomografi)
PÖ	Pekiştirmeli Öğrenme

QDA	Quadratic Discriminant Analysis (Kuadratik Diskriminant Analizi)
RBF	Radial Basis Function (Radyal Tabanlı Fonksiyon)
RF	Random Forest (Rastgele Orman)
RGB	Red Green Blue (Kırmızı Yeşil Mavi)
SAE	Stacked Autoencoder
SVM	Support Vector Machine (Destek Vektör Makinesi)
TN	True Negative (Doğru Negatif)
TP	True Positive (Doğru Pozitif)
VGG	Visual Geometry Group
WND	Weighted Neighbor Distances (Ağırlıklı Komşu Mesafeleri)
WSI	Whole Slide Image
YSA	Yapay Sinir Ağı
YZ	Yapay Zeka

TEŐEKKÜR

Beni Yüksek Lisans eğitimi almam için öğrencisi olarak seçip bana şans veren ve bana yüksek lisans eğitimim boyunca desteğini esirgemeyen değerli hocam Doç. Dr. Ahmet SAYGILI'ya çok teşekkür ederim. Hayatımın her anında yanımda bulunan, beni destekleyen ve bana yardımcı olan aileme de çok teşekkür ederim.

Emine ÖZGÜR

Bilgisayar Mühendisi



1. GİRİŞ

Bilgisayarların insanoğlundan daha hızlı işlem yapabildiği bilinen bir gerçektir fakat bilgisayarların karar verme yeteneklerinin kısıtlı olduğu da bilinmektedir. Günümüzde bilgisayarların karar verme yeteneklerini artırmak için çeşitli yapay zeka yöntemleri geliştirilmektedir. Yapay zeka yöntemleriyle kastedilen makine öğrenmesi ve derin öğrenme yöntemleridir. Bu yöntemler bilgisayarların karar vermedeki doğruluğunu arttırmakta ve farklı alanlarda uzmanlara destek olacak uzman sistemlerin geliştirilmesine imkan sunmaktadır (Selvi, 2019). Uzman sistemlerin tıp alanında kullanılmasının temel amaçlarından biri hastalıkları erken teşhis etme konusunda doktorlara yardımcı olmasıdır. (Eyüpoğlu & Yavuz, 2020). Makine öğrenmesi ve derin öğrenme yöntemleri medikal işlemlerde sıklıkla tahmin ve tanı için kullanılmaktadır. Bu yöntemler sayesinde zamandan ve iş yükünden tasarruf edilerek hastalara hızlı ve kaliteli sağlık hizmeti verilmesi amaçlanmaktadır (Veranyurt, Devenci, Esen, & Veranyurt, 2020). Makine öğrenimi tabanlı görüntü analiz işlemleri, patoloji alanında giderek daha fazla dikkat çekmektedir (Yang, et al., 2021).

Teknoloji alanındaki son gelişmelerle görüntülerdeki ve videolardaki artış sınıflandırılmamış verilerin artmasına sebep olmuştur. Dolayısıyla bu verilerden anlamlı sonuçlar çıkarmak ve analizlerini yapmak üzerinde detaylıca düşünmeyi gerektirecek bir mesele haline gelmiştir (Tan, Yüksel, Aydemir, & Ersoy, 2021). Dijital patolojik görüntülerin işlenerek anlamlı sonuçlar çıkarılacak hale getirilmesinde makine öğrenmesi ve görüntü işleme tekniklerinin başarılı sonuçlar ortaya koyduğu görülmektedir. Yüksek başarımları makine öğrenmesi temelli yaklaşımların patoloji alanında karar destek sistemi olarak kullanılabileceğini göstermektedir (Varol & İşeri, 2019). Histopatolojik görüntülerin otomatik analizi, hesaplamalı görüntü işleme yöntemleri ve modern makine öğrenimi tekniklerinden yararlanılarak yaygın olarak kullanılmaktadır (Zhang, Liu, Dündar, Badve, & Zhang, 2015).

Patoloji Laboratuvarları şu anda tamamen dijital bir iş akışına doğru bir dönüşüm geçiriyor (Veta, Pluim, Diest, & Viergever, 2014). Patolojik analiz için cam slaytlar hazırlama süreci, cam slaytların üretiminde tutarlılık ihtiyacını anlayan yetenekli laboratuvar personeli gerektirir. Bununla birlikte, bu slaytları rutin olarak yapmak, tekrarlayan ve genellikle zaman açısından kritik bir iştir ve bu nedenle, görünümdeki tutarsızlıklar yaygındır (Wright, Dunn, Hale, Hutchins, & Treanor, 2021).

Geleneksel olarak, yıllarca profesyonel tıp eğitimi almış patoloğlar doku örneklerini mikroskop altında değerlendirir ve kanserlerin varlığını ve saldırganlığını belirler (Vuong, Song, Kim, Cho, & Kwak, 2022). Dokunun mikroskopik incelemesi, patoloğun doğru teşhis koymasını ve tedaviyi yönlendirmesini sağlayan bilgileri ortaya çıkarır (Cooper, et al., 2012). Patoloğlar, tüm görüntü yerine yüksek çözünürlüklü görüntüdeki belirli yapılar hakkında sorgulama yapmakla ilgilenirler. Yüksek çözünürlüklü görüntüde belirli bir ilgilenilen yapı seçmeyi amaçlarlar ve sistemin bu özel durum için teşhis bilgileriyle birlikte benzer yapıları almasına izin verirler (Mehta, Alomari, & Chaudhary, 2009). Bu durumlar dikkate alındığında, patoloğların yıllar içerisinde edindikleri bilgileri makinelere aktararak teşhis aşamasında patoloğlara büyük ölçüde yardımcı olunabilir. Makinelere aktarım sonrası zaman, maliyet ve iş gücü gibi faktörler incelendiğinde büyük bir tasarruf yapılacağı görülmüş olur. Sağlık sisteminin her alanında böyle uygulamaların hayata geçirilmesi doktorları büyük ölçüde rahatlatılabilir.

Vücutta farklı dokular bir araya gelerek bir organ oluşturur. Türüne bağlı olarak kanser, bu dokularda farklı türde değişikliklere neden olur. Bu nedenle kanser tanı ve derecelendirmesinde patoloğlar doku tipini dikkate alarak doku değişikliklerini inceler ve farklı doku bölgelerinde meydana gelen değişikliklere farklı derecelerde önem verebilirler (Gültekin, Koyuncu, Sokmensuer, & Demir, 2015). Erken teşhis edilebildiği sürece kanser ölümlerinin büyük ölçüde azaltılabileceği doğrulanmıştır. Patoloğların gözlemine dayanarak tümörün doku kaynağını, yapısını ve kapsamını belirleyebilen patolojik inceleme, erken kanser tespitinin altın standardıdır (Wang, et al., 2020). Patoloğlar bir insandır ve insanlar hangi alanda ne kadar uzman olursa olsun yorgunluk, psikolojik etkenler gibi faktörlerden etkilenecek yanlış karar verebilirler. Belli bir enerji düzeyleri vardır. Makinelerin ise yorgunluk veya ruhsal etkenler gibi etkilenebilecekleri insana özgü faktörleri yoktur. Bu sebeple makine öğrenmesi ve görüntü işleme teknikleri kullanılarak geliştirilen sistemlerle hızlı ve patoloğların doğruluk seviyesinde teşhisler yapılabilir. Böylece hastalığın erken teşhisi yapılabilir ve ölümle sonuçlanma riski azaltılmış olur.

1.1 Literatür Özeti

Literatürde lenf kanserlerinin histopatolojik görüntüler yardımıyla teşhisini amaçlayan çok sayıda çalışma bulunmaktadır. Bu çalışmaların en temel amacı erken tanı ve tedaviye olanak sağlamak ve hekimlere alacakları kararlarda destek olabilmektir.

Zorman ve diğ. (2007) yaptıkları çalışmada, İspanya Tenerife Üniversite Hastanesi Patoloji Laboratuvarı tarafından sağlanan mikroskopik görüntülerde folikül bularak lenfomaların otomatik tanımlanmasını sağlayan bir sistem önermişlerdir. Çalışmada kullanılan veri setinde 3627 tane görüntü eğitim ve 1813 tane görüntü ise test için ayrılmıştır. Çalışma iki aşamadan oluşmaktadır. İlk aşamada görüntü ön işleme ve özellik çıkarımı yapılmıştır ve ikinci aşamada piksel sınıflandırması için farklı kaba küme yaklaşımları kullanılmıştır. Ön işlem aşamasında RGB olan görüntü kanallarına ayrıştırılarak R bileşeni alınıp görüntü işleme teknikleri uygulanmıştır. R bileşenindeki piksellerin ortalama parlaklık değeri Otsu eşikleme yöntemi için eşik değeri olarak belirlenmiştir. Eşikleme sonrası görüntü üzerinde 0, 45, 90 ve 135 derecelere karşılık gelen dönüşüm matrisleriyle görüntü taranıp dönüşüm işlemi yapılmıştır. Bu işlemler sonucunda her görüntü için ayrı ayrı öznitelik vektörleri elde edilmiştir. Öznitelik vektörleri karar ağacı (Decision Tree, DT) algoritmasına verilerek sınıflandırma yapılmıştır. Çalışmada elde ettikleri sonuçlar temel yaklaşımların görüntü analizi uygulamalarında başarılı olabileceğini ortaya koymuştur.

Boussaid ve arkadaşları (2009) yaptıkları çalışmada, foliküler lenfoma doku örneklerinin bilgisayar destekli değerlendirilmesi için CB olmayan hücrelerden CB hücrelerini tanımak için yeni bir otomatik yöntem önerilmiştir. Çalışmada kullanılan veri setinde 218 tane CB ve 218 tane de CB olmayan histopatolojik görüntü bulunmaktadır. Eğitim için kullanılacak görüntülerin CB olup olmamasına göre değerlendirmesini uzman patologlar yapmıştır. Oluşturulan veri setindeki görüntülere önerilen yöntem uygulanmıştır. Yöntem, QDA sınıflandırıcısının eğitimi ve testine dayanmaktadır. Bu yöntemin yeni yönleri, CB nesnesinin önceden bilgi ile tanımlanması ve renk dokusu özelliklerini çıkarmak için spektral alanda PCA tanıtılmasıdır. Sınıflandırmayı gerçekleştirmek için hem geometrik hem de doku özellikleri kullanılır. Gerçek foliküler lenfoma görüntülerinde deneysel sonuçlar, kombine özellik alanının sistemin performansını önemli ölçüde artırdığını göstermektedir. Uygulanan yöntem, CB olmayan ve CB hücrelerini % 82,56 sınıflandırma doğruluğu ile tanımlamaktadır.

Orlov ve arkadaşları (2010) yaptıkları çalışmada; basit ve bileşik dalgacık dönüşümü uygulanmış lenfoma histopatolojik görüntülerini WND algoritmalarıyla sınıflandırmayı önermişlerdir. Daha önce yaptıkları bir çalışmanın devamı niteliğinde bu çalışmayı yapmışlardır. Çalışma MATLAB ortamında gerçekleştirilmiştir. Çalışmada CLL, FL ve MCL tipi lenfomaların biyopsi görüntülerinden oluşan bir veri seti kullanılmıştır. Sınıflandırma aşamasında WND, BBN ve RBF algoritmaları kullanılmıştır. Çalışma sonucunda WND ve RBF algoritma sonuçları birbirlerine çok yakın olduğu görülmüştür. HE boyalı veri setiyle üç lenfoma tipinin en iyi sınıflandırıldığı görülmüştür. BBN ile %88 ve diğer iki sınıflandırıcı ile %98 doğruluk değeri elde edilmiştir. RGB veri seti ikinci en iyi sonucu %90 ile vermiştir. Gri seviyeli görüntülerin sınıflandırılmasında en iyi doğruluk sonucu olan %85 değeriyle ikinci sırada yer alırken, $L*a*b$ dönüşümlü veri seti tüm veri setleri arasında en kötü sınıflandırma sonucunu vermiştir. $L*a*b$ dönüşümlü veri setiyle en fazla %74 doğruluk değeri elde edilmiştir. BBN algoritması ise diğer iki algoritmanın sonuçlarını hiçbir testte elde edememiştir. MCL sınıfı, diğer iki sınıfla sınıflandırıldığında doğruluk değerleri sırasıyla CLL ile sınıflandırmada %72 ve FL ile sınıflandırmada %86 doğrulukla sınıflandırılmıştır. Üç lenf kanseri türünün sınıflandırılması yapıldığında %65 doğruluk değeri elde edilmiştir.

Ribeiro ve arkadaşları (2018) yaptıkları çalışmada, lenfoma görüntülerinin sınıflandırılmasında renk normalleşmesinin etkisini analiz etmek için bir yöntem önerilmiştir. Bu yaklaşım çok boyutlu fraktal teknikleri, eğri dönüşümleri ve Haralick özelliklerini bir araya getirmektedir. Yöntem; DT, RF, SVM, NB ve K-Star gibi algoritmaları değerlendirmek için bir özellik seçme tekniği ve farklı sınıflandırma yaklaşımları olarak değerlendirildi. Sınıflandırmalarda üç tip lenfoma kullanılmıştır. Bunlar; MCL, FL ve CLL'dir. En iyi sonuç, rastgele orman sınıflandırıcısı kullanılarak elde edilmiştir. Testler 10 kat çapraz doğrulama ile değerlendirildi ve AUC değeri %96,3 elde edilmiştir. Renk normalizasyonunun ilgili sınıflandırma oranlarını iyi yönde etkilemediği gözlemlenmiştir. Farklı özellik tipleri, sınıflandırıcılar ve renk normalleştirme etkisi üzerinde yapılan analizlerle elde edilen performans lenfoma kanserinin tanımlanmasında önemli bir katkı sunmuştur.

Jiang ve arkadaşları (2018) yaptıkları çalışmada; Hodgkin olmayan lenfomalardan CLL, FL ve MCL türü lenfomaların sınıflandırılması için hibrit bir sistem önermişlerdir. Çalışmada kullanılan veri setinde 3 sınıf ve toplamda 48620 tane görüntü bulunmaktadır. Her bir H&E patolojik görüntüsü gri seviyeye dönüştürülüp 100x100 boyutlarına yeniden şekillendirilmiştir. Daha sonra görüntülerdeki özellikleri çıkarmak için SAE, LPQ ve GLCM algoritmaları

kullanılmıştır. Bu algoritmaların çıktıları ayrı ayrı alınıp birleştirilerek tek bir özellik vektörü haline getirilmiştir. Veri setinin %60'ı eğitim için %40'ı da test için kullanılmak üzere ayrılmıştır. MCL ve CLL arasındaki özellik farkları çok küçük olduğu için FL'yi onlardan ayrıca sınıflandırmak için ELM algoritmasına özellik vektörü eğitimi için verilmiştir. ELM sınıflandırması sonrası MCL ve CLL'ye ait özellikler SVM algoritmasına verilerek ayrıca sınıflandırılır. MCL ve CLL'nin SVM ile sınıflandırmasındaki sonuçlar ve FL'nin diğerlerinden ELM algoritmasıyla sınıflandırılması sonucu elde edilen veriler olasılık füzyonuna verilmiştir. Böylece %97,96 doğruluk oranıyla hibrit sınıflandırma gerçekleştirilmiştir. Literatürdeki diğer benzer çalışmalarla sonuçlar kıyaslandığında çok daha yüksek doğrulukta bir sonuç elde edilmiştir.

Varol ve İşeri (2019) yaptıkları çalışmada, lenf kanserine ait patolojik görüntülerinden özellik çıkarımı yapıp makine öğrenmesi algoritmalarıyla otomatik sınıflandıran bir yöntem önermişlerdir. Çalışmada kullanılan veri setinde CLL, FL ve MCL kanserlerine ait patoloji görüntüleri bulunmaktadır. Veri setindeki veri dağılımı homojendir ve her kansere ait 45'er görüntü olmak üzere toplamda 135 görüntü bulunmaktadır. Patolojik görüntülerden özellik çıkarımı yapabilmek için görüntü renk yoğunluğu, görüntü piksel yoğunluğu ve entropi hesabı yapılmıştır. Bu işlemler sonucu elde edilen özellik vektörü sırasıyla ayrı ayrı; RF, K-NN, Naive Bayes, SVM ve K-Star algoritmalarına eğitim için girdi olarak verilmiştir. Modelleri kıyaslamak için özgüllük (specificity), hassasiyet (precision), geri çağırma (recall) ve doğruluk (accuracy) performans parametrelerine bakılmıştır. Çalışmanın sonucunda %89,72 doğruluk oranıyla RF algoritmasıyla diğer algoritmalara göre daha başarılı bir sonuç elde edilmiştir.

Bhattacharjee ve arkadaşları (2019) yaptıkları çalışmada, prostat kanserine ait histopatolojik görüntülerde iyi huylu, kötü huylu ve bunların 3 alt derecelendirmesine göre kanser ayrımını görüntü işleme yöntemleri ve SVM algoritmasıyla otomatik yapan bir öneride bulunmuşlardır. Çalışmada kullanılan görüntüler Yonsei Üniversitesi Severance Hastanesi'nden toplanmıştır. 400 tane görüntü toplanmıştır ve toplanan bu verilerle hastaların onayıyla veri seti oluşturmuştur. Veri setinde benign ve malign olmak üzere 2 sınıf bulunmaktadır. Patologların Gleason skoru hesabına göre görüntüler Grade3, Grade4 ve Grade5 olmak üzere 3 alt gruba ayrılmıştır. Prostat kanserine ait biyopsi hücrelerinde 3 önemli bileşen vardır. Bu bileşenlere göre segmentasyon yapmak için K-Means kümeleme algoritması kullanılmıştır. Algoritmanın k parametresi 3 olarak ayarlanmıştır. Görüntü içi kümeleme sonrası özellik çıkarım işlemi uygulanıp elde edilen öznelik vektörü SVM algoritmasına

eğitim için girdi olarak verilmiştir. Önerilen yöntemle kötü huylu ve iyi huylu için SVM ikili sınıflandırma doğruluğu, duyarlılığı, özgüllüğü sırasıyla %88,7; %91,8; %86,0 ve %70,2'dir. Grade 3 ve Grade 4+5 için; sınıflandırma doğruluğu, duyarlılık ve özgüllük sırasıyla %85,0; %81,8 ve %88,8'dir. 4. Derece ve 5. Derece için; sınıflandırma doğruluğu, duyarlılık ve özgüllük sırasıyla %92,5; %94,7 ve %95,0'dır.

Hao ve arkadaşları (2021) yaptıkları çalışmada, meme kanserine ait histopatolojik görüntülerin benign veya malign olup olmasına göre makine öğrenmesi ve görüntü işleme tekniklerini kullanarak histopatolojik tanıma sistemi önerdi. Çalışmada BreaKHis veriseti kullanılmıştır. Meme kanserine ait biyopsi görüntülerini içermektedir. Önerilen yöntemde ilk olarak histopatolojik görüntüler kanallarına ayrıştırılır. Daha sonra her bir kanaldaki görüntüye özellik çıkarımı için sırasıyla gri seviye eş oluşum matrisi (GLCM), dört yönde gri seviye eş oluşum matrisi, her kanalın ortalama piksel değeri, Hu değişmez moment, dalgacık özellikleri, Tamura, tamamlanmış yerel ikili desen, yerel ikili desen, Gabor ve yönlendirilmiş gradyan histogramı yöntemleri uygulanmıştır. Özellik çıkarım metotları uygulandıktan sonra görüntüye ait işlenmiş kanallar birleştirilir ve SVM algoritmasına girdi olarak verilir. BreaKHis veri seti üzerinde yapılan deneyler; tek yönden GLCM, dört yönden GLCM ve her kanalın ortalama piksel değerinin görüntü seviyesinde %90,2-94,97 doğrulukla yüksek bir başarı elde edilmiştir.

Yamashita ve arkadaşları (2021) yaptıkları çalışmada, patolojik görüntülerinde etki alanının dışındaki elementleri ayırt edebilmek için sanatsal resimleri kullanarak bir veri büyütme tekniği olan STRAP önerilmiştir. Çalışmada LF-CRC-DX-TEST veri setindeki patolojik görüntüler kullanılmıştır. Bu yaklaşım sayesinde patolojik görüntülerdeki yüksek düzey anlamsal içeriği korurken düşük düzeydeki anlamsal içeriği seçilen herhangi bir sanatsal görüntüdeki stilin aktarımı yapılır. Rastgele tıbbi olmayan görüntülerden patolojik görüntülere stil aktarımı yapılarak sonucunda tıbbi olmayan görüntü sayısı kadar görüntü elde edilir. Bu sayede veri setindeki veri sayısı da artırılmış olunur. Daha sonra ESA mimarileriyle sınıflandırma yapılır. Bu çalışmada elde edilen doğruluk değeri % 93,7'dir.

Karakurt ve İşeri (2021) yaptıkları çalışmada, ESA mimarisini kullanarak meme patoloji görüntülerinin sınıflandırmasını önermişlerdir. Çalışmada meme patoloji görüntülerinden oluşan bir veri seti kullanılmıştır. Veri setinde iki sınıf bulunmaktadır. Sınıflar, kanserli ve normal görüntülerden oluşmaktadır. Veri seti içerisindeki görüntüler sınıflarda homojen olarak bulunmaktadır ve toplamda 60000 görüntü bulunmaktadır. Görseller birbirinden farklı boyutlarda olduğu için görseller yeniden boyutlandırılıp her biri 50x50 boyutuna getirilmiştir.

Görüntüler çalışmada kurulan ESA mimarisine girdi olarak verilmiştir. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanıldığında %87 doğruluk değeri elde edilirken softmax fonksiyonu kullanıldığında %46 doğruluk değeri elde edilmiştir.

Zhang ve arkadaşları (2021) yaptıkları çalışmada, rahim ağzı kanserine ait patolojik görüntüleri sınıflandırmak için Yığılmış Genelleme sınıflandırma modelini önermektedir. Çalışmada özellik çıkarımı için ResNet50 modeli kullanılmıştır. Özellik çıkarım sonrası sınıflandırma için geleneksel makine öğrenmesi algoritmalarını kullanmayı önermişlerdir. KNN algoritmasıyla %85,83, RF algoritmasıyla %80,33 ve SVM algoritmasıyla %86,7 doğruluk elde edilmiştir.

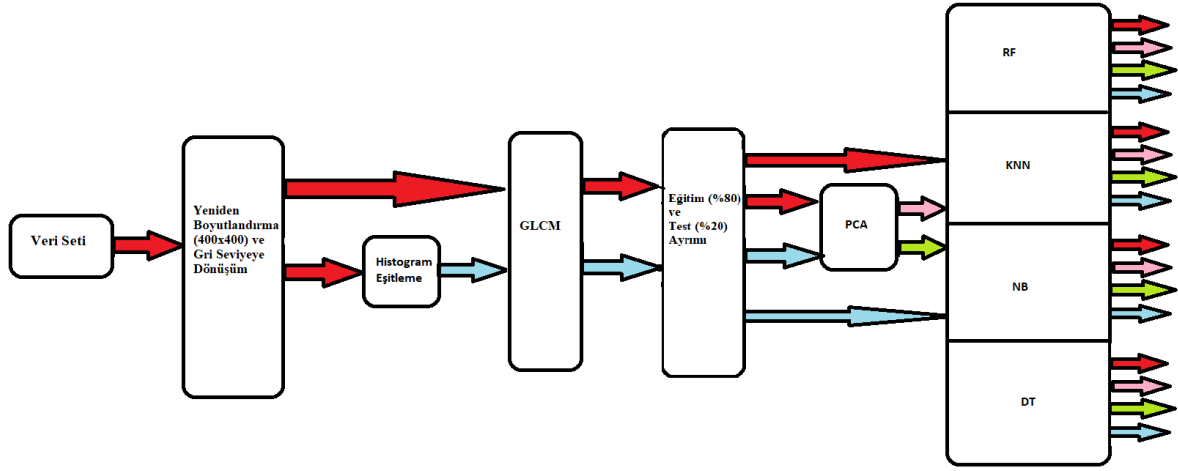
1.2 Çalışmanın Amacı ve Kapsamı

Lenf kanseri veya diğer bir adıyla lenfoma, vücudun savunma hücrelerinin kanserleşerek kontrolsüz çoğalmasıdır. Bir çeşit kan kanseri olan bu hastalık tehlikeli ve ciddi bir kanser türüdür ve ölümlerle sonuçlanabilir. Bu nedenle bu hastalığın erken ve doğru teşhisi ölüm oranlarının azalması sağlamaktadır. Gerçekleştirdiğimiz bu çalışmada da temel amacımız erken tanı ve tedaviye destek olabilecek bilgisayar temelli bir sistem ortaya koyabilmektir. Bu sayede hekimlerin kararlarında yardımcı olacak bir karar destek sistemi oluşturulmuş olacaktır. Çalışmamızda lenf kanserine ait histopatolojik görüntülerden oluşan bir görüntü seti kullanılmıştır. Bu çalışmada histopatolojik görüntülerin özelliklerini farklı yöntemlerle çıkardıktan sonra özellik seçimi ve boyut azaltımında kullanılan PCA uygulanarak makine öğrenmesi ve derin öğrenme yöntemlerinin sınıflandırma sonuçları incelenmiştir. Veri setinde artırım yapılarak veri artırım öncesi ve sonrasındaki sınıflandırma sonuçları incelenerek etkileri takip edilmiştir. Patologların sınıflandırma yaparken zorluklarla karşılaştıkları CLL, FL ve MCL türündeki lenfomalar ikili ve üçlü olarak eğitilerek kendi aralarındaki sınıflandırma sonuçları incelenmiştir.

1.3 Çalışmada İzlenen Metodoloji

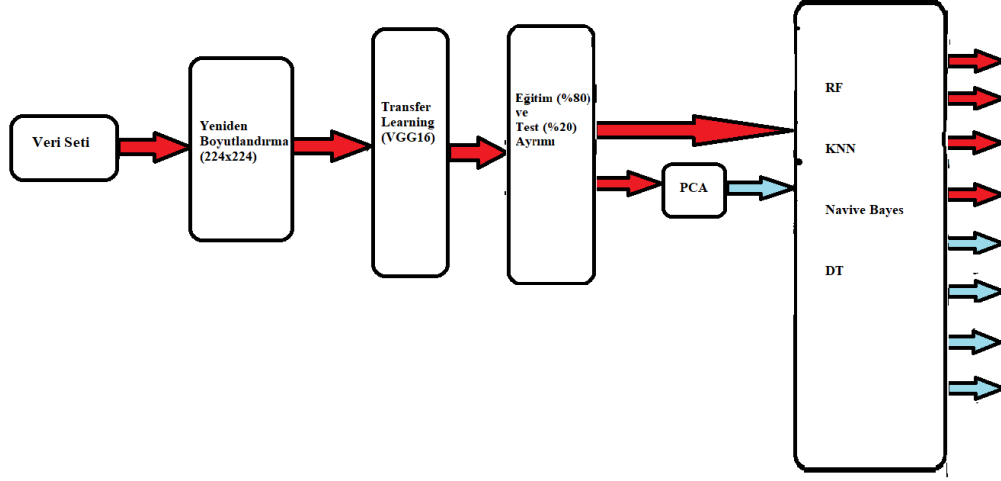
Çalışmada birden fazla metodoloji izlenmiştir. İlk yaklaşımda histopatolojik görüntüler gri seviyeye dönüştürülüp yeniden boyutlandırma işlemi yapılmıştır. Bu işlem veri artırım öncesinde ve sonrasında ayrı ayrı uygulanmıştır. Ayrıca görüntüler gri seviyeye dönüştürüldükten sonra histogramı eşitlenerek performans sonuçları karşılaştırılmıştır. Daha sonra işlenmiş her bir görüntü etiketiyle birlikte bir diziye eklenerek bir veri yığını oluşturulmuştur. Bu veri yığına GLCM uygulayarak özellik çıkarımı yapılmıştır. Çıkarılan

özellikler bir DataFrame'e gönderilerek tablo üzerinde işlemlere devam edilmiştir. Elde edilen tablonun son kolonu etiketlere ait olup etiket kolonu hedef kolon olarak tablodan ayrıştırılmıştır. Bu işlem sonrası veri seti eğitim ve test olarak ayrıştırıldı. Veri setinin %80'i eğitim %20'si test için kullanılmak üzere ayrıştırıldı. Eğitim için ayrılan kısım RF, KNN, NB ve DT algoritmalarına girdi olarak verilmiştir. Çalışmada ki ilk yaklaşımın akış şeması Şekil 1.1'de gösterilmektedir.




Şekil 1. 1. Çalışmadaki ilk yaklaşımın akış şeması

Çalışmadaki ikinci yaklaşım, histopatolojik görüntülerin yeniden boyutlandırılıp VGG16 mimarisiyle transfer öğrenme (transfer learning) uygulayıp özelliklerinin çıkarılması ve ardından özellik seçimi için PCA kullanarak makine öğrenmesi yöntemleriyle sınıflandırılmasıdır. Yani hibrid bir yapıda çalışmalar yapılmıştır. Görüntülerin sınıflandırılmasındaki başarısından dolayı özellik çıkarmak için VGG16 modeli seçilmiştir. VGG16 modelinin tam bağlantılı katmanı çıkarılıp geri kalan katmanların öğrenmesi engellenmiştir. Yeniden boyutlandırılmış görüntüler VGG16 modeline girdi olarak verilmiştir ve sonucunda özellik yığını elde edilmiştir. Elde edilen yığına PCA uygulaması yapılarak özellik seçimi ve boyut azaltımı yapılmıştır. Bu işlemler sonrası yığın %80'i eğitim %20'si test için kullanılmak üzere ayrıştırıldı. Eğitim için ayrılan kısım RF, KNN, NB ve DT algoritmalarına girdi olarak verilmiştir. Çalışmanın ikinci yaklaşımı Şekil 1.2'de gösterilmektedir.



Şekil 1. 2. Çalışmadaki ikinci yaklaşımın akış şeması

Çalışmadaki son yaklaşım; özellik çıkarımı ve sınıflandırma aşamalarında VGG16, ResNet50 ve DenseNet201 mimarilerini kullanarak tamamen derin öğrenmeye dayalı bir sınıflandırmadır. Özellik çıkarım aşaması için ikinci yaklaşımdaki gibi Transfer Öğrenme uygulanmıştır. Bu mimarilerin tam bağlı katmanları çıkarılıp geri kalan katmanlarının eğitimi engellenmiştir. Sınıflandırma işlemi için ek olarak katmanlar eklenmiştir ve sadece bu katmanlarda eğitim gerçekleşmiştir. İlk olarak histopatolojik görüntüler yeniden boyutlandırılarak ön işleme yapıldı. Ardından görüntülerin matris değerleri bir diziye eklenmiştir. Görüntülerin etiketleri de ayrı bir diziye eklenmiştir. Matris değerlerini ve etiketleri içeren diziler %80’i eğitim %20’si test için kullanılmak üzere ayrıştırıldı. Eğitim için ayrılan matris değerleri ve etiketleri VGG16, ResNet50 ve DenseNet201 mimarilerine girdi olarak verildi. Sonuçlar incelenerek çıkarımlar yapıldı. Yapılan çıkarımlar Sonuçlar ve Öneriler bölümünde açıklanmıştır. Çalışmada yer verilen son yaklaşımın akış şeması Şekil 1.3’te gösterilmektedir.



Şekil 1. 3. Çalışmadaki üçüncü yaklaşımın akış şeması


1.4 Çalışmanın Bilime Katkıları

Sağlık alanında makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak hastalık teşhisi yapılmasıyla ilgili literatürde birçok çalışma bulunmaktadır. Bu çalışmada histopatolojik görüntülerin sınıflandırılması için 3 farklı yöntem önerilmiştir. Bu yöntemlerin veri artırımı öncesinde ve sonrasındaki performansları incelenmiştir. Bu alanda araştırmalar ve çalışmalar yapmak isteyen kişilere yol gösterici nitelikte bir çalışma ortaya konulmuştur. Gerçekleştirilen çalışma sayesinde hekimlere destek olabilecek nitelikte bir Karar Destek Sistemi oluşturulduğu söylenebilir.



2. LENFOMA

Lenfoma, vücudun mikropla mücadelesinde yer alan lenfatik sistemin bir kanseridir. Lenfatik sistem, lenf düğümlerini, dalak, timus bezi ve kemik iliğini içerir (Ansell, 2022). Lenfoma, baş ve boyun bölgesinde en sık görülen üçüncü tümördür (Harrizi, Ibourk, & Yahya, 2022). Spesifik olarak, lenfoma, bir tür beyaz kan hücresi olan lenfositleri etkileyen bir kanserdir. Lenfositler, vücudu bakteri ve virüs gibi yabancı istilacılara karşı savunmak için kan ve lenfatik sistemden geçer. Lenfomalar genellikle bir lenfosit içinde anormal hücrenin normal bir lenfositten daha hızlı çoğalmasına veya normal bir lenfositten daha uzun yaşamasına neden olan bir değişiklik meydana geldiğinde gelişir. Normal lenfositler gibi kanserli lenfositler de kan ve lenfatik sistemde dolaşabilir ve lenf düğümleri, dalak, kemik iliği ve diğer organlar dahil olmak üzere vücudun birçok yerine yayılabilir ve büyüyebilir (About lymphoma and lymphoma subtypes, t.y.). Lenf bezlerinin vücuttaki yerlerini gösteren şema Şekil 2.1’de verilmektedir.



Şekil 2. 1. Lenf bezlerinin bulunduğu yerlerin gösterimi (Lenf dolaşımı nedir?, 2020)

2.1 Lenfoma Belirtileri

Lenfoma hastalığının ilk belirtileri genellikle hastanın vücudunda büyüyen bir kitledir. Lenfoma, daha çok lenf bezi denilen bezelerin patolojik olarak büyümesiyle ortaya çıkar. Bu nedenle hasta kişilerin büyük bölümü boyun, koltuk altı ve kasık bölgelerinde lenf bezlerinin büyüdüğünü fark edip hastaneye gitmektedir. Lenfoma belirgin etkilerinden bir diğeri de bağışıklık sisteminin yeterli çalışmamasıdır. Bu sebepten grip gibi bulgular gösterebilmektedir.

Bununla birlikte sinüzit, akciğer enfeksiyonları gibi durumlar ortaya çıktığında iyileşme süresi uzayabilmektedir (Memorial Tıbbi Yayın Kurulu, 2022).

Vücutta bulunan binlerce lenf bezi, enfeksiyon ve hastalıklara karşı direnç sağlayan bağışıklık sisteminin en önemli parçasıdır. Enfeksiyonlar sırasında lenf bezleri büyümektedir. Hastalık sona erdiğinde ise lenf bezleri yeniden eski boyutlarına dönmektedir. Bu durum son derece normal olan bir mekanizmanın göstergesidir (Acıbadem Web ve Yayın Kurulu, 2022). Her yıl ortaya çıkan kan kanserlerinin yaklaşık yarısı lenfomalar veya lenfatik sistem kanserleridir. Boyun, koltuk altı, kasık, göğüs ve karın bölgesindeki lenf düğümlerinden oluşan bu sistem, vücudunuzdaki fazla sıvıyı uzaklaştırır ve bağışıklık hücreleri üretir. Enfeksiyonla savaştan bir tür beyaz kan hücresi olan anormal lenfositler, çoğalan ve lenf düğümlerinizde toplanan lenfoma hücreleri haline gelir. Zamanla, bu kanserli hücreler bağışıklık sisteminizi bozar (Lymphoma, t.y.).

Harrizi ve arkadaşları (2022) yaptıkları bir çalışmada, biyopsi sonrası patolojik görüntülerin incelenmesini ve patologların karar verme aşamalarını açıklamıştır. 72 yaşında erkek bir hasta Eylül 2019'da sağ lateral servikal kitle bulgusu hastaneye kaldırılmış ve sonrasında Hodgkin dışı lenfoma manto hücresi teşhisi konulmuştur. Aralık 2019'da konsültasyonun bir ayından beri sol üst çenede büyüme şikayeti ile diş hastanesine başvurmuş, yapılan fiziksel muayenede damağın sert ve yumuşak kısımlarında kitleler tespit edilmiştir. Sorunlu bölgenin tomografisi çekilip patolojik inceleme için ilgili bölgeye biyopsi yapılmıştır. Patolojik görüntüler uzmanlar tarafından incelenip hastalığın teşhisi yapılmıştır. Uzman, teşhis sonrası tedavi stratejisini hastaya bildirmiştir.

2.2 Lenfoma Türleri

Lenfoma genel itibariyle Hodgkin Lenfoma (HL) ve Hodgkin Dışı Lenfoma (NHL) olmak üzere iki grupta yer almaktadır. Tüm lenfomaların yaklaşık %60'ını Hodgkin dışı, %40'ını Hodgkin lenfoma oluşturmaktadır (Özdoğan, Arslan, Taş, & Balamtekin, 2020). Bu bölümde Hodgkin ve Hodgkin olmayan lenfomalar detaylıca açıklanmıştır.

2.2.1 Hodgkin Lenfoma (HL)

Hodgkin hastalığı olarak bilinen şeyin ilk tanımları, seçkin İngiliz patolog Thomas Hodgkin'in lenfadenopati ve dalak genişlemesi olan bir otopsi vaka serisini tanımladığı 1832 yılına kadar uzanmaktadır. HL, enflamatuar bir arka planda kanserli Reed-Sternberg hücreleri

ile karakterize benzersiz bir hematopoetik neoplazmadır (Shanbhag & Ambinder, 2018). HL, genç erişkinlerde en sık görülen kanserlerden biridir (Momotow, Borchmann, Eichenauer, Engert, & Sasse, 2021). HL bir sonraki lenf düğümü bölgesine aşama aşama yayılmaktadır. Genellikle hareket yönü önce boyundan mediastene doğru, sonrasında çölyak lenf düğümlerine, oradan da dalak, karaciğer ve kemik iliğine doğrudur (Ünal).

HL, en sık 20-40 yaş arasındaki genç erişkinlerde görülmektedir ve görülme sıklığı 55 yaşından sonra ikinci bir pik yapmaktadır (Güneş & Çınarsoy, 2021). HL oldukça tedavi edilebilir bir hastalıktır. Çoğu hasta ilk basamak tedavisinden sonra tam yanıt alsa da, 60 yaşından büyük hastalarda hastalık, tedaviye bağlı morbidite ve yaşam kalitesinin bozulması gibi kötü sonuçlarla karşılaşmamış temel klinik ihtiyaçlar devam etmektedir (Mohty, et al., 2021). Hodgkin lenfoma 2 alt gruba ayrılır. Bu alt gruplar klasik Hodgkin lenfoma ve NLBHL'dir. Bu bölümde klasik Hodgkin lenfoma ve NLBHL'den bahsedilmiştir.

2.2.1.1 Klasik Hodgkin Lenfoma (cHL)

Klasik Hodgkin lenfoma, esas olarak 15-30 yaş arası ve 55 yaş üstü kişilerde görülen en yaygın HL tipidir (Zhang, et al., 2022). Klasik Hodgkin lenfoma dört alt gruba ayrılır: nodüler skleroz, lenfositten zengin, karışık selülarite ve lenfositten yoksundur. Dört özellik Hodgkin lenfomalarını karakterize eder. Genellikle servikal lenf düğümlerinde ortaya çıkarlar ve hastalık genç erişkinlerde daha sık görülür (Kaseb & Babiker, 2022).

2.2.1.2 Nodüler Lenfosit Baskın Hodgkin Lenfoma (NLBHL)

NLBHL, cHL tiplerinden ayrı patolojik özellikler gösteren, az görülen bir HL alt tipidir (Gökgöz, Gemici, & Aydoğdu, 2015). NLBHL çoğunlukla oldukça sakin bir seyir izler ve hastalar genellikle erken evrelerde teşhis edilir (Eichenauer & Engert, 2017). Tüm HL'ların %85'ini cHL ve %15'ini NLBHL oluşturmaktadır. NLBHL tedavi ve yaklaşımı cHL' dan oldukça farklı olup yavaş seyirli Hodgkin dışı lenfomalara benzerdir.

2.2.2 Hodgkin Olmayan Lenfoma (NHL)

NHL'ler; B, T ve doğal öldürücü hücrelerden kaynaklanan, klonal lenfoid sistem tümörleridir. NHL, yaş, cinsiyet, çevresel etmenler, ırksal ve enfeksiyonlara maruz kalma gibi sebeplere bağlı olarak gelişim ve oluşum süreçleri değişkenlik gösterir (Akay, ve diğerleri, 2018). NHL DNA'nın hasarlanmasıyla ortaya çıkan, tek bir özelliği paylaşan farklı kan kanserleri grubu için kullanılan bir terimdir. DNA'nın kötü huylu (malign) şekil değiştirmesine

neden olmaktadır. Bu şekil değiştirme lenfositin kontrolsüz ve aşırı çoğalmasıyla sonuçlanmaktadır. Lenfoma hücreleri vücudun bir veya birçok bölgesinde gelişebilir.

Bu anomali anormal B lenfositlerden ortaya çıkan B hücreli lenfomalar ve anormal T lenfositlerden ortaya çıkan T hücreli lenfomalar olarak 2 gruba ayrılır. B hücreli lenfomalar daha çok görülmektedir. Hastalık çoğunlukla lenf düğümlerinde gelişmektedir. Malign lenfoid hücreler kan ve lenf dolaşımı aracılığı ile vücudun diğer kısımlarına da yayılabilir (Okutan, 2021). En sık görülen olgun B hücreli neoplazmalar FL, Burkitt lenfoma, diffüz büyük B hücreli lenfoma, manto hücreli lenfoma ve marjinal bölge lenfomasıdır. En sık görülen olgun T hücreli lenfoma tipleri; erişkin T hücreli lenfoma ve mikoz fungoidlerdir (Sapkota & Shaikh, 2022). Bu çalışmada Hodgkin dışı lenfomalardan CLL, FL ve MCL ile çalışılmıştır. Çizelge 2.1’de CLL, FL ve MCL’ye ait özellikler verilmiştir. Bu bölümde çalışmada kullanılan Hodgkin dışı lenfomalar açıklanmıştır.

2.2.2.1 CLL

CLL, batı dünyasındaki en yaygın lösemi şeklidir (Hakim & Farooq, 2022). CLL'nin altında yatan moleküler nedene ilişkin anlayış ve hipotezler teknolojik ilerlemeler kaydedildikçe gelişmiştir. Tarihsel olarak, ışık mikroskobu ile analiz edildiğinde, CLL hücreleri küçük, olgun, istirahat eden B lenfositleri olarak kabul edilmiştir. (Ng & Chiorazzi, 2021)

2.2.2.2 FL

FL, oluşum aşamasında merkez B hücrelerinden oluşan ve durgun klinik seyri olan bir lenfoid neoplazmadır (Suknuntha, Subramanian, Racchumi, & Tam, 2022). FL, tüm Hodgkin dışı lenfoma vakalarının %20'sini oluşturan, Hodgkin olmayan lenfomanın ikinci en yaygın alt tipidir. Hastalığın sıkça geliştiği bölgeler; dalak, karaciğer ve kemik iliğidir (Meghpara, et al., 2022).

2.2.2.3 MCL

MCL, nadir görülen bir B hücreli malignitedir (Hansen, Nyvold, & Hansen, 2022). MCL, çok sayıda B-hücreli lenfomanın alt tiplerinden biridir. En sık kemik iliği, karaciğer, dalak gibi bölgelerde gözlenir. Tüm lenfomalarda olduğu gibi tanı için biyopsi tercih edilmektedir (Akay, ve diğerleri, 2018). MCL, özellikle yaşlıları etkileyen nadir fakat tehlikeli bir lenfoma türüdür (Ekberg, et al., 2022).

Çizelge 2.1. FL, MCL ve CLL'ye ait özellikler (Battula & Sharma, 2018)

Tip	Hücre Boyutu	Konum	Histopatolojik Özellikler
FL	Sentrosit	Lenf düğümü ve germinal merkez	Bol atipik folikül, açılmış sinüsler ve dağınık büyük hücreler
MCL	Küçük ve monomorfik	Lenf düğümü ve mantle zone	Monomorfik lenfoid, hızlı bölünerek çoğalan
CLL	Küçük	Lenf düğümü	Hızlı çoğalan, genişleyen sınırlar

2.3 Lenfoma Teşhis ve Tedavisi

Lenfoma teşhisinden öncelikle hastalar bazı semptomlarla doktorlara başvururlar. Doktorlar ilk olarak hastanın hastalık geçmişi hastadan öğrenir ve daha sonra fiziksel muayene yapar. Doktor hastalık geçmişi ve yaptığı fiziksel muayene sonucunda semptomların lenfoma sonucu olabileceğinden şüphelenirse belirli tetkiklerin yapılması istenir. Kemik iliği aspirasyonu veya biyopsisi, göğüs röntgeni, MR, PET taraması, moleküler test ve kan testleri tetkikler arasında yer almaktadır (Watson & Ratini, 2022). Bu tetkikler sonucu doktor teşhisi koyar ve gerekli tedavilere başlar. Hastalığın seyrine göre tedavi yöntemi veya ilaçların dozajları değiştirilebilir. Tedavi sürecindeki değişiklikler tamamen doktor kontrolünde yapılmaktadır ve diğer tıp branşlarıyla birlikte süreçte ilerlenir.

Lenfoma hastalarında genellikle kemoterapi tedavisi uygulanmaktadır. Kemoterapiden kaynaklı hastalarda anemi, kanama, ağrı, bulantı, kusma, saç dökülmesi, enfeksiyon, halsizlik, periferik nöropati gibi semptomlar çok sık meydana gelmektedir (Arts, et al., 2017).

2.4 Lenfoma Yaşam Süresi

Lenfomaların klinik seyrine göre ikiye ayrılmaktadır. Hızlı ve yavaş olarak ayrılmaktadır. Hızlı seyirli lenfomalar kısa sürede içerisinde belirtilerini göstermektedir. Kitle çok kısa sürede büyüyerek, aylar hatta haftalar içinde kendini gösterebilir. Yavaş seyirli lenfomalarda, kitlenin büyüme hızı çok yavaştır. Yıllarca sürebilecek bir zamanı kapsayabilir. Lenfoma yaşam süresi, lenfomaların seyrine göre değişkenlik göstermektedir. Hızlı seyirli lenfomaların tedavisinde geç kalındığında ya da tedavi olunmadığında hastalar aylar ya da haftalar içinde kaybedilebilir. Yavaş seyirli olanlarında ise hiç tedavi olmasa bile

hasta uzun süre hatta 15-20 yıl yaşayabilir. Bu nedenle iki farklı lenfoma grubundaki hastalara uygulanan tedavi yöntemlerinde farklılaşmalar vardır. Hızlı seyirli lenfomalarda erken teşhis ve tam iyileşme hedeflenerek tedavi yöntemleri izlenmelidir. Yavaş seyirli olanlarında ise çoğunlukla rutin takip edilmesi yeterli olmaktadır (Memorial Tıbbi Yayın Kurulu, 2022).

Ölümlerle sonuçlanabilecek bir tanının konulması, hastaların kanama veya sepsis gibi nedenlerle hayatlarını kaybetmeleri, kemoterapiden kaynaklanan belirtileri daha yoğun yaşamaları, tanı ve tedavi süreçlerinin uzun olması gibi nedenlerle hastaların ve hasta yakınlarının günlük yaşamlarının olumsuz etkilendiği düşünülmektedir (Sezgin & Bektaş, 2021).


2.5 Patolojik Görüntüler

Patolojik görüntüleme, hastalıklı organların çıplak gözle veya biyopsi yapılması sonrası biyopsi görüntülerinin mikroskop altındaki anormal görünümlerinin incelenmesi amacıyla ortaya atılan görüntüleme tekniğidir (Karakurt & İşeri, 2021). Otomatik görüntü analiz araçları kullanılarak, hücre sayımı gibi karmaşık rutin faaliyetler için patologlar desteklenebilir. Dijital patoloji kullanımı ayrıca patolojik raporların oluşturulmasını hızlandırmaya yardımcı olmalıdır. Standartlaştırılmış, yapılandırılmış raporlar, hastanın tedavisine dahil olan çeşitli kurumlar arasındaki iletişimi ve iş birliğini hızlandırabilir ve hatta geliştirebilir (Pallua, Brunner, Zelger, Schirmer, & Haybaeck, 2020).

Mikroskop altında cam slaytlar üzerine biyopsi sıvısının veya parçasının incelenmesi yerini günümüzde dijital görüntüleme almıştır. Dijital patoloji görüntüleri; bir bilgisayar ekranında görüntülenebilen, kayıpsız ve çözünürlüğü yüksek dijital görüntüler sağlamak amacıyla bir tarama cihazı kullanılarak elde edilmektedir. İncelenecek olan dokular amacı doğrultusunda özel geliştirilmiş cihazlarla taranmakta ve bilgisayar ortamına dijital görüntüler olarak aktarılmaktadır (Veta, Pluim, Diest, & Viergever, 2014). Şekil 2.2’de örnek patolojik görüntü verilmektedir.

Günümüzde birçok hastalığa kesin teşhis için patolojik incelemeler yapılmaktadır. Histopatolojik WSI’lerde yer alan bilgiler, görüntüleme için kullanılan mikroskop veya tarayıcının tipi ve kalitesi, görüntünün boyutu ve büyütülmesi, dış etkenlerin neden olduğu titreşimler, boyama nedeniyle fiziksel renk değişimi gibi birçok faktörden etkilenir. Sonuç olarak, YZ algoritmalarını uygulamadan önce görüntülerin kalitesini iyileştirmek için

histopatolojik WSI'lerin ön işlenmesi gerekebilir. Dijital patoloji, modern görüntüleme yöntemlerinin gelişmesi ve yeni teknolojilerdeki ilerlemelerle hızla önem kazanmaktadır.




Şekil 2. 2. Örnek lenfoma patolojik görüntüsü

Tıp bilimi; hastalık veya yaralanma gibi durumlarda insan vücudunun yapısını ve işlevini anlamak, yorumlamak ve bunların sonucunda sorunların çözümüne odaklanmaktadır. Biyolojik ve tıbbi süreçler hakkında bilgi edinmek için insan vücudunun görüntülerinden yararlanmak sadece klinik tıpta değil onu destekleyen biyomedikal araştırma alanlarında da kullanılmaktadır (Kumrular & Polat, 2021). Tıbbi görüntü işleme, daha fazla analiz için ham tıbbi verilerin görüntü kalitesini artırmak için sayısallaştırılmış bir görüntü üzerinde bir algoritmanın uygulanmasıyla ilgilenir. Giriş görüntüsünün görsel bilgilerini iyileştirmek için tıbbi görüntüleme uygulamalarında çeşitli ön işleme teknikleri kullanılır (Shyni & Chitra, 2022).

3. GÖRÜNTÜ İŞLEME

Görsel algılama sürecinin gerçekleşmesi için ön koşul ışığın varlığıdır (Ceran, 2022). İnsan gözü, nesnelere yansıyan ışığı toplar ve beynin ilgili merkezine iletir. Işığın toplanarak görselleştirilmesi, yaklaşık iki yüz yıl önce fotoğraf makinesinin icadıyla yapılmaya başlanmıştır. Fakat makinelerin insanların biyolojik yapısındaki gibi görüntüyü işlemesi ve görüntüdeki nesnelere anlaması için işlemcilerin gücünün artması gerekmektedir. Bunun için görüntü işlemenin bir teknik olarak gerçek zamanlı kullanılması 1970’lerde mümkün olabilmektedir (Görüntü işleme nedir?, 2020). Teknolojideki gelişmelerle birlikte görüntü işleme kavramı ortaya çıkmıştır. Görüntü işleme, günümüzde hızla büyüyen teknolojilerden biridir (Sharadhi, Gururaj, Shankar, Supriya, & Chogule, 2022).

Görüntü işleme, algoritmalar ve görüntü işleme yöntemleri ile kaydedilmiş görüntüyü istenilen amaca uygun hale getirme biçimidir. Her görüntü ham haliyle analize uygun olmayabilir. Görüntü işleme teknolojisi ile birlikte artık her görüntü amaca uygun kullanım için işlenebilmektedir. Görüntü işleme temel olarak görüntünün elde edilmesi, sayısallaştırılması ve analiz edilmesi safhalarından oluşmaktadır (Soyhan, Gürel, & Tekin, 2021). Şekil 3.1’de görüntü işleme aşamalarının gösterimi verilmiştir.



Şekil 3. 1. Görüntü işleme aşamaları (Gonzales & Woods, 2014)



3.1 Gözün Görmesi

Görüntü işleme yapabilmek için gerekli görüntüleri elde etmemizi sağlayan kameraya sahip cihazlar, insan gözünün görme işleminden esinlenilerek geliştirilmiştir. Görüntü işlemeyi tam olarak anlamak için öncelikle gözün görme işlemi nasıl gerçekleştirdiğinin anlaşılması gerekir. Bu bölümde gözün görmesiyle ilgili detaylı bilgiler verilmiştir.

Görmenin nasıl gerçekleştiğine dair tartışmaların 2000 yıllık bir geçmişi vardır. Gözün tam olarak ne gördüğü, nasıl gördüğü ve nesnelerin görülmesi için hangi özelliklere sahip olması gerektiği gibi sorulara yıllarca cevap aranmıştır ve bu konuda deneysel çalışmalar yapılmıştır (Yıldırım & Demirarslan, 2019).

İnsan konuşmadan önce çevresini görerek algılar ve öğrenir. Göz ve görme eylemi fotoğrafın icadı ile farklı bir boyut kazanmıştır. Fotoğraf makinasının ardından kameranın icadı ile göz ve görme eylemine algılama, yorumlama ve gerçeklik boyutu da eklenmiştir (Çelik & Çiçekli, 2022). Canlıların nesnelere tanıyabilmesi ve anlamlandırabilmesi farklı koşullardaki ayrıntılı görebilme yeteneğinden kaynaklanmaktadır (Gülperçin, 2015). Bu yeteneği sağlayan organ, farklı bölümler ve parçalardan oluşmaktadır. Her parçanın amacı ve yapısı birbirinden farklıdır. Her bir bölüm görmeyi sağlamak için birlikte çalışmaktadır (Koç, 2021).

Gözün üç temel bölümü vardır. Bunlar; ışık odaklama sistemi, otomatik diyafram sistemi ve ışığa duyarlı algılama sistemidir (Yakalı, 2017). İnsan gözünün parçaları sklera, kornea, oküler kaslar, koroid, retina, iris, kas dokusu, lens ve göz bebeğidir (Yalman & Ertürk, 2013). İlk olarak ışık korneadan geçer. Kornea bir kubbe şeklindedir ve gözün odaklanmasına yardımcı olmak için ışığı büker. Bu ışığın bir kısmı, göz bebeği adı verilen bir açıklıktan göze girer. İris, göz bebeğinin ne kadar ışık alacağını kontrol eder. Daha sonra ışık mercekten geçer. Mercek, ışığı retinaya doğru olacak şekilde odaklamak için kornea ile birlikte çalışır. Işık çarptığında, fotoreseptör adı verilen özel hücreler ışığı elektrik sinyallerine dönüştürür. Bu elektrik sinyalleri retinadan optik sinir yoluyla beyne gider. Sonra beyin, sinyalleri gördüğümüz görüntülere dönüştürür (National Eye Institute, 2022). Şekil 3.2'de gözde görüntü oluşumunun şeması gösterilmektedir.




Şekil 3. 2. Gözde görme işleminin şeması (Üstündağ, 2015)

3.2 Görüntü İşlemeyle İlgili Kavramlar

Bu çalışmada görüntüler üzerinde çalışılmıştır. Görüntüler üzerinde yapılan işlemlerin iyi anlaşılması için bu bölümde bazı temel görüntü işleme ile ilgili kavramlar açıklanmıştır.

3.2.1 Piksel

Dijital bir görüntüdeki satır ve sütunlarda bulunan her bir elemana piksel denmektedir. Dijital görüntüyü oluşturan en küçük birim pikseldir. Şekil 3.3'te kesiti alınmış bir görüntünün piksel değerleri gösterilmektedir.




Şekil 3. 3. Kesiti alınmış görselin piksel değerlerinin gösterimi (Pişkin, 2016)

3.2.2 Çözünürlük

Cep telefonu, televizyon ve monitör gibi dijital ekrana sahip donanımlarla gösterilen bir görüntü içerisindeki piksellerin sayısını belirten değere çözünürlük denir. Çözünürlük görüntünün netliğini tanımlamak için kullanılmaktadır.

3.2.3 Renk

Renk; Güneş'ten gelen beyaz ışığın belirli dalga boylarına göre kırılması sonucu oluşan ışığın, gözün retina tabakasına ulaşması sonucu ortaya çıkan bir algılamadır. Renkleri temsil edebilmek için bazı renk modelleri bulunmaktadır. RGB ve HSV gibi renk modelleri bulunmaktadır. Şekil 3.4'te RGB formatındaki bir görüntünün kanallarına ayrıştırılmış halleri gösterilmektedir.



Şekil 3. 4. RGB formatındaki görüntünün renk kanallarına ayrıldığındaki halleri (Sever, 2018)

3.2.4 Karşıtlık

Karşıtlık veya kontrast, bir görüntünün ayırt edilebilirliğini ifade etmektedir. Görüntü üzerindeki renk değerlerinin birbirine çok yakın olması görüntünün düşük kontrastlı olduğu anlamına gelmektedir. Düşük kontrastlı görüntülerde detaylar net bir şekilde ayırt edilemeyebilir. Bu yüzden karşıtlık işlemleri yapılarak görüntüler yüksek kontrastlı yapılır.

3.2.5 Gürültü

Dijital görüntülerin elde edilmesi sürecinde görüntü sinyallerinde oluşan hatalara gürültü denmektedir. En sık karşılaşılan gürültü tipi tuz biber gürültüsüdür. Gürültü görüntünün

analiz edilmesini olumsuz etkilemektedir. Bu yüzden gürültü temizleme işlemleri uygulanmaktadır.

3.3 Pikseller Arası İlişkiler

İki boyutlu düzlem üzerinde ki bir p pikselinin çeşitli komşulukları vardır. Şekil 3.5'te bir pikselin komşuluklarını P temsiliyle gösterimi verilmiştir. Ele alınan piksel, komşusu olan piksellere birim uzaklığındadır. Bu p pikselinin koordinatlarını (x,y) olarak aldığımızda yatayda ve dikeyde ki komşularının koordinatları $(x+1, y)$, $(x-1, y)$, $(x, y-1)$ ve $(x, y+1)$ 'dir. Bu piksel kümesi p 'nin 4-komşusu olarak adlandırılır ve $N4(p)$ ile gösterilir. P pikselinin dört köşegen komşusu; $(x-1,y+1)$, $(x+1,y-1)$, $(x+1,y+1)$ ve $(x-1, y-1)$ koordinatlarına sahiptir ve $N D(p)$ ile gösterilir. P pikselinin yatay, dikey ve köşegenlerinde ki komşuluklar birleştirildiğinde p 'nin 8-komşu'su olarak adlandırılır ve $N8(p)$ ile gösterilir. Şekil 3.6'da bir pikselin komşuluklarını koordinatlarıyla gösteren şema verilmiştir.

P_1	P_2	P_3
P_4	P_9	P_5
P_6	P_7	P_8

Şekil 3. 5. Bir pikselin komşuluklarını P temsiliyle gösteren şema (Güvenç & Karagül, 2009)

$x-1,$ $y-1$	$x-1,$ y	$x-1,$ $y+1$
$x,$ $y-1$	$x,$ y	$x,$ $y+1$
$x+1,$ $y-1$	$x+1,$ y	$x+1,$ $y+1$

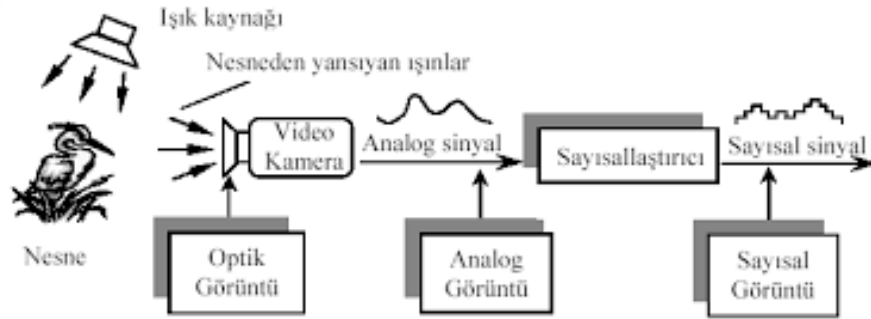
Şekil 3. 6. Bir pikselin komşuluklarını koordinatlarıyla gösteren şema (Güvenç, Elmas, & Demirci, 2008)

3.4 Görüntü İşleme Kullanım Alanları

Görüntü işlemenin faydaları kullanım yerlerine göre değişkenlik göstermektedir. Görüntünün işlenmesinde kullanılan bu tekniklerin her biri görüntüyü farklı açılardan değerlendirmektedir. Görüntü işleme üzerine yapılan çalışmaların asıl amacı görüntüyü çözümlene ve dolayısıyla sayısallaştırmadır. Günümüzde görüntü işleme; imalat, güvenlik, tıp, elektronik, tasarım, mimari gibi birbirinden farklı birçok alanda kullanılmaktadır (Samtaş & Gülesin, 2011). Çeşitli alanlarda görüntü işleme tekniklerinin kullanılması ile farklı çalışmalar yapılarak literatüre katkı sağlanmaktadır.

3.5 Görüntünün Sayısallaştırılması

Görüntü işleme, kaydedilen görüntüler üzerine bilgisayar aracılığıyla iyileştirmeler yapılması olarak açıklanır (Edizer, 2006). Görüntünün dijitalleştirilmesi, kamera üzerindeki görüntünün elektriksel sinyallere dönüştürülmesi işlemidir. Mercekte oluşan görüntü kameranın sensörleri yardımıyla alınır. Şekil 3.7’de şematik olarak bu durum gösterilmiştir. Bu sinyaller bilgisayar ortamına görüntünün aktarılması için kullanılan analog sinyallerdir (Yaman, Sarucan, Atak, & Aktürk, 2001).



Şekil 3. 7. Bir görüntünün sayısallaştırılmasının şeması (Er & Temurtas, 2005)

3.6 Görüntü İşleme Teknikleri

Görüntüler üzerinde belli görüntü işleme teknikleri kullanarak görüntü analiz süreçlerinde daha iyi sonuçlar alınabilir. Görüntüdeki gürültüleri temizlemek ve kenar bulma gibi işlemler görüntü işleme teknikleriyle gerçekleştirilmektedir. Bu bölümde bazı görüntü işleme teknikleri açıklanmıştır.

3.6.1 Keskinleştirme

Keskinleştirme, görüntüdeki sınırların iyileştirilerek kenarların belirginleştirilmesi işlemidir. Görüntüdeki yüksek frekanslı bileşenler baskın hale getirilmeye çalışılır. Bu işlemler, keskinleştirme filtreleriyle yapılmaktadır. Oluşturulan keskinleştirme filtreleri görüntü üzerinde gezdirilerek kenarlar belirginleştirilir.

3.6.2 Bulanıklaştırma

Bulanıklaştırma, görüntü üzerindeki ayrıntıları azaltmak için kullanılan bir görüntü işleme tekniğidir. Kenarların yumuşatılması sağlanır. Bu yöntem düşük geçiş filtresi olarak da adlandırılmaktadır. Düşük frekansa sahip bileşenlerin geçişi sağlanırken yüksek frekanslı bileşenler elenir. Bu yöntemi uygulamak için bir birim kare matrisi oluşturulur. Bu matrisin bir kenar uzunluğunun karesi alınarak matriste bulunan her bir eleman bu sayıya bölünür. Medyan (Median) filtresi de denen bir filtre veya matris oluşturulur. Bu matris görüntü üzerinde gezdirilerek bulanıklaştırma işlemi gerçekleştirilir. Bulanıklaştırma ile görüntüdeki gürültüyü azaltmak için de kullanılmaktadır.

3.6.3 Gürültü Temizleme

Görüntüler elde edilirken ki süreçte görüntü üzerinde farklı sebeplere bağlı olarak tuz biber gürültüsü ve Gauss gürültüsü gibi pek çok gürültü bulunabilir. Bu gürültüler görüntüyü kusurlu hale getirmektedir. Görüntü üzerindeki gürültüyü temizlemek için Ortalama (Mean), Medyan ve Gauss filtreleri sıkça kullanılmaktadır.

3.6.4 Kenar Bulma

Kenar bulma işleminde nesnelerin sınırlarını çıkartmak için kullanılmaktadır. Kenarlar yüksek frekansa sahip olduğu için kenar bulma işleminde yüksek geçiş filtreleri kullanılmaktadır. Bu filtreler yüksek frekansların geçmesini sağlarken düşük frekanslı bileşenlerin elenmesini sağlamaktadır. Bu işlem için sıkça kullanılan Canny, Sobel ve Laplasyan (Laplacian) metotlarıyla görüntüler üzerinde kenarlar bulunmaktadır. Bu metotlar çıktı olarak ikili (binary) bir görüntü vermektedir.

3.6.5 Histogram Eşitleme

Histogram, bir görüntüde bulunan piksel değerlerinin sayılarını gösteren grafikdir. Görüntünün histogram grafiği incelendiğinde piksel değerleri bir yerde kümелendiği gözlemlenirse histogram eşitleme yöntemi uygulanabilir. Bu sayede piksel dağılımlarında denge sağlanır.

3.6.6 Morfolojik İşlemler

Biyolojide morfoloji, farklı organizmaların yapısal özelliklerini ve şekillerini inceleyen bilim dalıdır. Matematiksel anlamda morfoloji; temel küme işlemleriyle görüntüdeki imgelerin sınırlarını çıkarılması, gürültüyü giderimi ve bölütleme gibi işlemlerin uygulanması sağlanır. Aşındırma, yayma, açma ve kapama işlemleri en bilinen morfolojik işlemlerdir.

3.6.7 Bölütleme

Bölütleme, görüntüyü her biri içerisinde farklı özelliklerin olduğu anlamlı bölgelere ayırma işlemidir. Eşikleme, kümeleme ve derin öğrenme yöntemleriyle bölütleme işlemi gerçekleştirilebilmektedir. Kümelemede makine öğrenmesi algoritmalarından biri olan K-Means sık kullanılan ve en bilinen kümeleme yöntemlerinden birisidir. Derin öğrenmede ise segmentasyon için sıklıkla Mask R-CNN ve U-Net kullanılmaktadır.


3.6.8 Özellik Çıkarımı

Örüntü tanıma ve sınıflandırma işlemlerinde en temel adımlardan birisi özellik ya da öznitelik çıkarım aşamasıdır. Bu aşamada görüntünün ayırt edici kısımları tespit edilerek özellikleri belirlenmektedir. Sınıflandırma aşamasında kullanılacak olan bu özellikler örüntülerin diğer örüntülerden ayırt edebilmesine imkan sağlayan yapısal bölümlerdir (Şişeci & Cetişli, 2012). Çalışmada özellik çıkarımı için kullanılan metotlardan biri GLCM'dir. Bu bölümde GLCM açıklanmıştır.

3.6.8.1 GLCM


Doku, bir desen ya da desenlerin bir bölge üzerinde tekrarlanmasıdır. Bu desenler nitelik bakımından ince, pürüzsüz, rasgele ya da çizgili gibi değişik özelliklerde sahip olabilir. Doku, farklı yerlerdeki iki farklı piksel arasındaki gri seviyenin farklarının kıyaslanmasıdır. Farklı dokular, doku analizleriyle ortaya çıkarılarak keşfedilebilir (Demirhan & Güler, 2010). Gri

seviye görüntülerde dokuların özelliklerini çıkarmak için kullanılan yöntemlerden biri GLCM'dir. GLCM bir kare matristir ve boyutu görüntüdeki farklı piksel değeri sayısı kadardır. GLCM belli bir geometrik uzaklık ile birbirinden ayrılmış aynı piksel değerlerine sahip piksel çiftlerinin tekrarlanma sayılarının hesaplanması sonucu oluşturulur. GLCM çeşitli uygulamalarda doku analizi için sıkça kullanılmaktadır (Sathyamoorthy, 2013). Bir görüntünün üç farklı yönde çıkarılmış GLCM'i Şekil 3.8'de gösterilmektedir.



Şekil 3. 8. 4x4'lük bir görüntüden elde edilen üç farklı yöndeki GLCM (Durmuş & Bayazit, 2017)

GLCM ile analiz yapıldığında enerji ölçümü, zıtlık ölçümü, homojenlik, korelasyon ve entropi gibi öznitelikler çıkarılabilir. Bu çalışmanın bir bölümünde, veri setindeki görüntüler gri seviyeye dönüştürülüp GLCM ile verilerin özellikleri çıkarılmıştır. Korelasyon, homojenlik, kontrast, ASM, enerji ve benzersizlik özniteliklerini içeren bir özellik vektörü elde edilerek gri seviye görüntülerde özellik çıkarımı yapılmıştır. Çalışmada kullanılan açı değerlerini de gösteren örnek GLCM şeması Şekil 3.9'da gösterilmektedir. Bu bölümde çalışmada çıkarılan özelliklerin açıklamalarına yer verilmiştir.



Şekil 3. 9. GLCM şeması (Demirhan & Güler, 2010)

3.6.8.1.1 . Korelasyon

Korelasyon, GLCM’de bulunan değerlerden piksel çiftlerinin birlikte olma olasılıklarını ölçmektedir. Bu değer komşu piksellerin birbirleriyle ne kadar ilişkili olduğunu gösteren değerdir. Korelasyon, -1 ile 1 arasında değer üretmektedir. Benzer gri seviyeli bölgelerde korelasyon değeri daha yüksektir. Formülde $P_{i,j}$ piksel çiftlerini, M ise matris boyutunu temsil etmektedir.

$$\text{Korelasyon} = \sum_{i,j=0}^{M-1} P_{i,j} \left[\frac{(i-\mu_i)*(j-\mu_j)}{\sqrt{(\sigma_i)^2*(\sigma_j)}} \right] \quad (3.1)$$

3.6.8.1.2 Homojenlik

Homojenlik, GLCM’deki değerlerin dağılımının GLCM köşegenine yakınlığını ölçen değerdir. Homojenlik, 0 ile 1 arasında değer üretmektedir.

$$\text{Homojenlik} = \sum_{i,j=0}^{M-1} P_{i,j} * \frac{1}{1+(i+j)^2} \quad (3.2)$$

3.6.8.1.3 Kontrast

Kontrast, görüntüdeki mevcut yerel çeşitliliği ifade eden bir ölçüdür. Sabit görüntülerde kontrast 0’dır. Kontrast, 0 ile GLCM’in sütun sayısının 1 eksiğinin karesi olan değer arasında değer üretmektedir.

$$\text{Kontrast} = \sqrt{\sum_{i,j=0}^{M-1} P_{i,j} (i - j)^2} \quad (3.3)$$

3.6.8.1.4 ASM

ASM, bir görüntünün tekdüzeliğini gösteren değerdir. GLCM’deki değerlerin karelerinin toplamını veren ASM, 0 ile 1 arasında değer üretmektedir. Pikseller birbirine çok benzer olduğunda ASM değeri büyük olmaktadır. Sabit görüntülerde ASM değeri 1’dir.

$$\text{ASM} = \sum_{i,j=0}^{M-1} (P_{i,j})^2 \quad (3.4)$$

3.6.8.1.5 Enerji

Enerji, ASM'nin karekökü alınarak hesaplanır. Komşu piksel çiftlerinin ne kadar düzenli olduğunu gösterir.

$$\text{Enerji} = \sqrt{\sum_{i,j=0}^{M-1} (P_{i,j})^2} \quad (3.5)$$

3.6.8.1.6 Benzersizlik

Benzersizlik, GLCM'de bulunan değerlerin komşu elemanlarıyla arasındaki farkı veya değişimi ölçen değerdir.

$$\text{Benzersizlik} = \sum_{i,j=0}^{M-1} P_{i,j} |i - j| \quad (3.6)$$

3.6.8.1.7 Entropi

Entropi, GLCM'deki değerlerden görüntünün yoğunluğunu ölçer. Homojen görüntülerin entropi değerleri heterojen görüntülere göre daha düşüktür. Görüntüde homojenlik arttıkça entropi değeri düşmektedir.

$$\text{Entropi} = \sum_{i,j=0}^{M-1} P_{i,j} (\log_2(P_{i,j})) \quad (3.7)$$

3.6.9 Özellik Seçimi

Özellik seçimi, analiz edilecek veri setindeki verileri en iyi şekilde temsil edecek altkümelerin oluşturulması işlemidir. Özellik seçimi, amaca uygun bir şekilde ilgilenilen problem için en önemli özellikleri verilerden seçerek veri kümesindeki temsili özellik sayısının azaltılmasını hedeflemektedir. Özellik sayısının azaltılması işlem maliyetinin de azalmasını sağlamaktadır (Budak, 2018). Çalışmada özellik seçimi ve boyut azaltımı için PCA yöntemi kullanılmıştır ve bu bölümde açıklanmıştır.

3.6.9.1 PCA

Veri analizinde analiz edilecek olan verinin herhangi bir makine öğrenmesi veya derin öğrenme yöntemlerine girdi olarak verilmeden önce belli optimizasyon işlemlerinin uygulanması önemlidir. Optimizasyon işlemi uygulamadan büyük boyutlu verilerle eğitim yapıldığında eğitim süresinin uzaması ve aşırı öğrenme gibi problemlerle karşılaşmaktadır.

Bu problemleri aşmak için özellik seçimi ve boyut azaltım yöntemleri uygulanmaktadır. Bu yöntemlerden biri de PCA'dır. PCA, özellik seçimi, boyut azaltımı, veri sıkıştırma ve özellik çıkarımı için kullanılan yöntemlerden biridir. Temel amacı yüksek boyutlu ve birbiriyle ilişkili veriler içerisinde bulunan değerli bilgileri seçip boyutu azaltmaktır. Özellik seçimi yaparken verileri niteleyen genel özelliklerin seçilmesi daha sonraki aşamalarda verinin analizi için çok önemlidir. Genel özellikleri seçerken belli bir kayıp meydana gelmektedir. Bu kaybın genel yani verileri niteleyen önemli özelliklerden olmaması gerekir. Kodlama yaparken PCA'nın en değerli özellikleri içeren bir öznelik vektörü elde edilir. Verileri nitelirmede daha az etkili olan özellikler öznelik vektöründe yer almayarak daha kaliteli bilgiler çıkarılmış olunur. Böylece boyut azaltımı yapılmış olunur. Bu çalışmada PCA, özellik seçimi ve boyut azaltımı için kullanılmıştır.

3.7 Sağlıkta Görüntü İşleme

Teknoloji alanındaki gelişmeler hayatın neredeyse her alanına uyarlanmaktadır. Sağlık alanı da bunlardan biridir. Günümüzde uzmanların hastalıkları teşhis etmesinde yardımcı olması için uzman sistemler geliştirilmektedir. Bu sistemler çok kısa sürede uzmanların doğruluk seviyesinde hastalıkları teşhis edip erken teşhis konmasını sağlamaktadır. Böylece erkenden tedaviye başlanıp yaşamsal risk oluşturan hastalıkların teşhisinde ve tedavisine başlanmasında önemli rol oynamaktadır. Bu sistemler sayesinde sağlık hizmetleri süreçlerinde iyileştirmeler yapılmaktadır. Sağlık alanında giderek artan uzman ihtiyacı ve hasta yoğunluğu gibi nedenlerden uzman sistemlere daha da ihtiyaç duyulmaktadır.

Uzmanlar teşhis koyabilmek için hastalardan tetkikler istemektedir. Bu tetkikler uzmanın şüphelendiği hastalığa bağlı olup değişkenlik göstermektedir. Görüntü işlemenin sağlıktaki uygulamaları incelendiğinde; histopatolojik görüntüler, MR ve BT gibi görüntülere belirli görüntü işleme yöntemleri uygulanarak hastalıklı bölgenin belirginleştirilmesi ve bölütlenmesi sağlanmaktadır. Burada hastalıklı bölgenin yapısı da çok önemlidir. Görüntü işleme uygulamalarının uygulanabilmesi veya başarılı olabilmesi için hastalıklı bölgenin görüntü içerisinde benzersiz özelliklere sahip olması gerekir. Örneğin; beyin MR görüntülerinde tümör tespitini yapmak için belli başlı görüntü işleme işlemleri uygulandığında başarılı sonuçlar elde edilmektedir. Bu başarı tümörün belli sınırlarının olması, tek veya çoksa bile benzer özelliklerde olmaları görüntüde diğer elementlere göre ayırt ediciliğinin olmasından kaynaklanmaktadır. Histopatolojik görüntüler ele alındığında, bazı hastalıklara ait histopatolojik görüntülerde analiz yapılması görüntünün yapısı dolayısıyla zordur. Bu zorluk

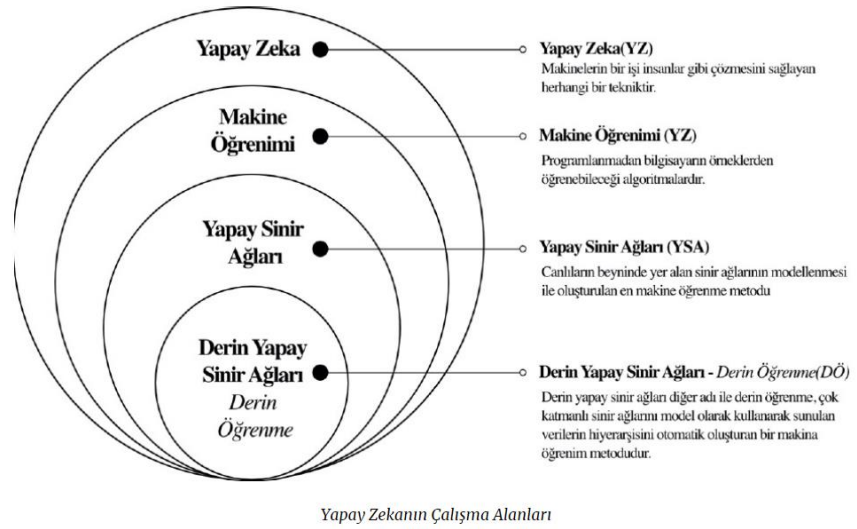
hastalıklı ve sađlıklı bölgelerin birbirlerine benzer özellikler göstermesidir. Bu gibi durumlarda görüntü işleme uygulamaları başarılı olamayabilir. Uzmanların teşhiste zorlandığı bir hastalığın uzman sistemler tarafından çok kolayca teşhis edebilmesi beklenmemelidir. Hastalıklı bölgenin bölütlenmesi ya da teşhis edilmesinde derin öğrenme yöntemleri kullanılmaktadır. Derin öğrenme mimarilerinde görüntüler belirli katmanlardan geçmektedir. Geçtikleri katmanlarda görüntülere filtreler uygulanarak özellikleri çıkarılmaktadır. Literatürdeki çalışmalar incelendiğinde bu gibi görüntülerde derin öğrenme yöntemlerinin başarılı olduğu görülmektedir.



4. YAPAY ZEKA

Yapay zekâ; insanlarda bulunan karar verme ve problem çözüme yeteneklerini, belli algoritmalarla matematiksel ifadelerle makinelere insanlarda olan bu yetenekleri kazandırmayı amaçlayan bir bilim dalıdır (Kuruca, Üstüner, & Şimşek, 2022). En basit açıklamasıyla yapay zekâ, insan yapımı araçların insan özelliklerini ve karar verme gibi akıl süreçlerini taklit edebilmesidir. Yapay zekâ temelde insanın uzun zaman veya uzun bilgi birikimi gerektiren yapıları daha kolay bir şekilde çözmek veya gerçekleştirebilmek amacıyla geliştirilmiştir.

Derin öğrenme, makine öğrenmesi ve yapay zeka birbiri ile hiyerarşik bir ilişki içerisindedirler. Şekil 4.1'de de görüldüğü üzere yapay zeka derin öğrenme ve makine öğrenmesini kapsar. Makine öğrenmesi de derin öğrenmeyi kapsamaktadır (Aylak, Oral, & Yazıcı, 2021).



Şekil 4. 1. Yapay zeka ve kapsadığı alanların şeması (Yapay zeka nedir?, 2020)

4.1 Makine Öğrenmesi Yöntemleri


Makine öğrenimi, bir sistemin büyük ölçekli verilerden otomatik olarak bilgi edinme, bütünleştirme ve daha sonra bilgiyi geliştirme ve daha sonra bunu yapmak için özel olarak programlanmadan yeni bilgileri keşfederek edinilen bilgiyi özerk olarak genişletme yeteneğidir. Yapay zekânın bir alt dalı olan makine öğrenmesi, bilgisayarların öğrenme işlemini gerçekleştirmesini sağlayacak algoritma ve yöntemlerin gelişimiyle ilgilenen bir çalışma alanıdır.

Matematiksel modeller, biyolojik bir sistemin davranışını destekleyen mekanizmalar hakkındaki varsayımlara dayanır. Bunlar genellikle, sınırlarında model parametrelerinin ve sistem davranışının sağlanmasına dayanan kısmi diferansiyel denklem sistemleri aracılığıyla tanımlanan koruma yasaları (örneğin kütle, momentum, enerji) cinsinden formüle edilir. Örneğin, Navier-Stokes denklemleri kan akışı dinamiklerini tanımlamak için yaygın olarak kullanılmıştır, kan yoğunluğu viskozitesi ve giriş veya çıkışlardaki akış hızları veya basınçları gibi hemodinamik parametrelerin reçete edilmesini gerektirir (Berg, et al., 2022).

Algoritmaya dayalı bilgisayarlar tarafından gerçekleştirilen işlemlerde hata payı yoktur ve işlem belirli adımları takip eder. Bir girdiye dayalı bir çıktıya sahip olmak için yazılan komutlardan farklı olarak, bilgisayarların mevcut örnek verilere dayalı kararlar aldığı bazı durumlar vardır. Bu gibi durumlarda, bilgisayarlar karar verme sürecindeki insanlar gibi hata yapabilir (Çelik & Altunaydın, 2018). Makine öğreniminin temel amacı, önceki verileri kullanarak kendi kendilerini geliştirebilecek, karmaşık kalıpları algılayacak ve yeni sorunlara çözüm bulabilecek modeller oluşturmaktır.

4.1.1 Makinelerin Öğrenimi

Makine öğrenmesi; olasılık, istatistik ve optimizasyon gibi matematiğin alt alanları ile ilişkilidir. Model oluşturulur ve modele eğitim verileri girdi olarak verilerek eğitimi sağlanıp daha önce karşılaşmadığı veriler hakkında iyi tahminler yapması beklenir. Makine öğrenmesi ile verilerden istatistiksel çıkarımlar yapılarak modelin performansı analiz edilir. (Nacar & Erdebilli, 2021). Şekil 4.2’de temsili yapay zeka ve bilgisayar ilişkisi gösterilmektedir.



Şekil 4. 2. Yapay zeka ve bilgisayarın ilişkisini gösteren temsili şema (Discover the main benefits of machine learning, t.y.)

İnsanların öğrenme süreci, kişiden kişiye değişiklik gösterir. Her insanın kendine has öğrenme yöntemleri vardır ve bu zamanla kişinin öğrenme sürecini esneyemez hale getirebilir. İnsanların zihnine öğrenme sürecinden farklı bir yöntemle girildiğinde kalıplaşmış sistemi değiştirmek daha da zordur. Ancak, makine öğreniminde farklı algoritmalar seçerek öğrenme yöntemini değiştirmek basittir (Akademi 4.0 Ekibi, 2020).

Matematikçiler ve yazılımcılar, ele aldıkları problemi çözmek için büyük veya küçük veri setlerine çeşitli yaklaşımlarda bulunarak deneysel çalışmalar yaparlar. Veri bilimciler bir problemi çözmek için kullanılacak en uygun algoritma türünü seçerek veriyi algoritmanın girdi olarak kabul edebileceği şekilde hazırlar. Kullanılan algoritmanın türü, çözülmek istenen problemin türü, çalışılacak veri setindeki verileri yapısı ve değişkenlerin sayısı gibi özelliklere bağlı olarak değişkenlik gösterir.

4.1.2 Makine Öğrenmesi Çeşitleri

Makine öğrenmesi algoritmaları kullanım amacına ve kullanılacak veri setine göre genel olarak 3 gruba ayrılır. Bu gruplar; denetimli, denetimsiz ve pekiştirmeli öğrenmedir. Bu bölümde bu gruplar ve o grupların içinde olan algoritmaların bir kısmı açıklanmıştır. Çalışmada etiketli verilerle çalışılmıştır. Bu yüzden denetimli öğrenme algoritmaları kullanılmıştır. Pekiştirmeli öğrenme ve görüntüler içerisinde segmentasyonda denetimsiz öğrenme algoritmalarından K-Means algoritması ilerleyen çalışmalarda kullanılabileceği için fikir vermek adına açıklanmıştır.

4.1.2.1 Denetimli Öğrenme


Denetimli öğrenme algoritmalarında etiketli veriler kullanılmaktadır. Algoritmaya girdi olarak verilen verilerin çıktı değerleri bellidir. Çıktı değeri belli olan verilerle denetimli öğrenme algoritmaları eğitilir. Eğitim sonunda eğitilmiş modele daha önce girdi olarak verilmemiş veriler verildiğinde elde edilen sonuçlar modelin performansını göstermektedir. Amaç, eğitilmiş sisteme daha önce görmediği etiketli bir veri verildiğinde verilerin etiketlerine göre yüksek doğrulukta sınıflandırabilmesidir. Modeli eğitmek için veri setinin eğitim için ayrılan bölümü kullanılır. Eğitim veri seti içerisinde eğer etiketlenmemiş veriler varsa veriler incelenerek sınıflandırılır ve eğitime dahil edilir. Bu verilerin etiketlerini yazılım geliştiriciler programda ayrıca belirtir (Kızılkaya & Oğuzlar, 2018).

4.1.2.1.1 Naive Bayes (NB)

NB sınıflandırıcıları, adını matematikçi Thomas Bayes'ten almaktadır. NB sınıflandırıcıları, Bayes teoreminin özellikleri arasında güçlü bağımsızlık varsayımlarıyla uygulamaya dayanan basit olasılıksal sınıflandırıcılardır. Naive Bayes sınıflandırıcıların eğitimi aşamasında, bir dizi olasılıksal hesaplamayla sınıflandırıcıya girdi olarak sunulan girdi verilerinden çıkarımlar yapıp test verilerinin kategorilerini tespit etmeyi amaçlamaktadır. Olasılık değeri en yüksek olan sınıfa göre veriler sınıflandırılır. NB istatistik ve bilgisayar bilimi literatüründe saf Bayes modelleri, basit Bayes ve bağımsız Bayes gibi çeşitli isimler adı altında bilinmektedir. Ancak tüm bu isimler, sınıflandırıcının karar kuralında Bayes teoreminin kullanımına atıfta bulunmaktadır. En basit Bayes ağ modelleri kenar yoğunluğu tahmini ile birleştirilebilmekte ve daha yüksek doğruluk seviyeleri elde edilebilmektedir (Özbay & Özbay, 2021).

4.1.2.1.2 Karar Ağacı (Decision Tree (DT))

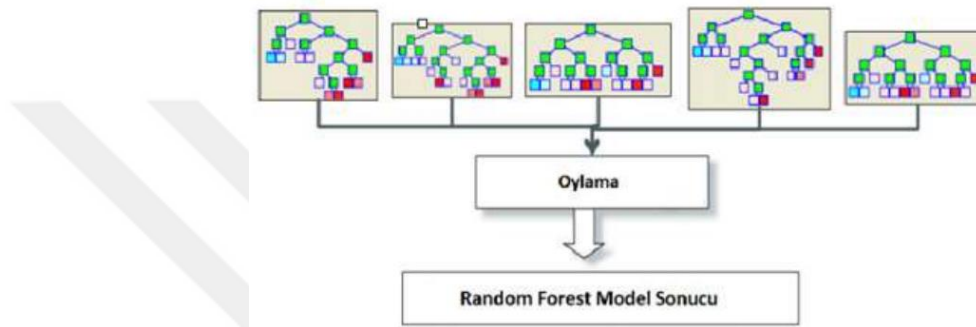
DT yöntemi, sınıflandırma ve tahmin etmede kullanılan önemli bir makine öğrenmesi yöntemidir. DT, girdisi olmayan bir kök düğüm ve her biri birer girdi alan iç düğümlerden oluşan yönlü bir ağaçtır. Çıktıları bir başka düğüm tarafından girdi olarak alınan düğümler iç ya da test düğümü, çıktıları bir başka düğüme girdi olmayan düğümler ise yaprak düğümler olarak adlandırılmaktadır. DT'de her bir iç düğüm, girdi özellik değerlerinin belirli bir fonksiyona tabi tutulmasına dayalı olarak iki veya daha fazla parçaya ayrılmaktadır. DT'nin iç düğümleri özellikleri temsil etmektedir. Yaprak düğümleri sınıfın etiketlerini temsil etmektedir (Onan, 2015). Şekil 4.3'te DT algoritmasının yapısı verilmiştir.



Şekil 4. 3. DT algoritmasının yapısı (Kavzaoğlu & Çölkesen, 2010)

4.1.2.1.3 Rastgele Orman (Random Forest (RF))

RF algoritması, bir sınıflandırıcı yerine birden çok sınıflandırıcı üreten ve sonrasında onların tahminlerinden alınan oylar ile yeni veriyi sınıflandıran öğrenme algoritmalarıdır. Şekil 4.4'te RF modeli verilmektedir. Oy çoğunluğuna göre model karar vererek sınıflandırma yapmaktadır. RF; tüm değişkenler arasından en iyi dalı kullanarak her bir düğümü dallara ayırmak yerine, her bir düğümde rastgele olarak seçilen değişkenler arasından en iyisini kullanarak her bir düğümü dallara ayırır. (Akar & Güngör, 2021). Birçok karar ağacının oluşmasıyla RF meydana gelmektedir. Her bir özelliğin sınıflandırmadaki etkisi ele alınır.

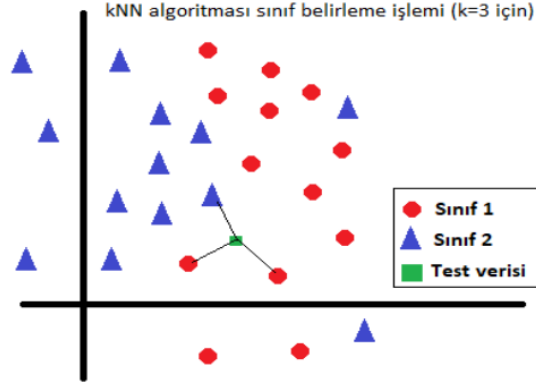


Şekil 4. 4. Örnek bir RF modeli (Akyiğit & Taşçı, 2022)

Diğer makine öğrenmesi algoritmalarına göre avantajı, ilgili özellikleri tanımlamak veya değişken seçimi yapmak için kullanılabilen değişken önem ölçütleridir. Gini endeksi gibi bölünmelerdeki kirliliğin azaltılmasına dayalı ölçütler yaygın olarak kullanılmaktadır. Gini endeksi; sınıflandırma ağaçlarında bölme kriteri olarak sıklıkla kullanılmaktadır (Şirin, 2020). RF algoritması büyük veya küçük boyutlu veri setlerinde kolayca kullanılabilir (Kormaz, Çelik, & Kapar, 2018).

4.1.2.1.4 En yakın k-komşuluğu (KNN)

KNN algoritması, sınıflandırılacak veriyi eğitim verilerine yakınlık ilişkisine göre sınıflandırma yapan bir algoritmadır. Bu algoritma hem sınıflandırma hem de regresyon problemlerinin çözümünde kullanılmaktadır. KNN algoritmasında sınıfları belli olan verilerle çalışılmaktadır. Test verilerinin eğitim verisindeki bütün verilere olan uzaklıkları seçilen uzaklık ölçüsüyle hesaplanır ve KNN algoritmasının aldığı k parametresine verilen değer sayısı kadar komşuluğuna bakılır. Bu sayede test verileri sınıflandırılmış olunur. Şekil 4.5'te KNN algoritmasının sınıflandırmasını gösteren şema verilmektedir.



Şekil 4. 5. KNN algoritmasının sınıf belirleme işlemi şeması (Çavuşoğlu & Kaçar, 2019)


4.1.2.2 Denetimsiz Öğrenme

Denetimsiz öğrenme algoritmaları etiketsiz verilerle çalışır. Girdi verilerine karşılık çıktı değerleri belli değildir. Bu durumlarda sadece girdi değerleri ele alınarak bu veriler arasında örüntüler bulunmaya çalışılır. Girdi verileri küme yoğunluğuna veya benzerliklerine göre gruplara ayrılır. Burada yazılım geliştiricilerin veya bu alanda çalışan herhangi birisinin müdahalesi yoktur. Denetimsiz öğrenme algoritmaları, girdi olarak verilen veriler içerisinde gizli kalmış ilişkileri/örüntüleri kendi başına bulmaya çalışır.

Benzerlik ilkesi temelde tüm bilim alanları için önemli bir konudur. Eğer ele alınan veriler arasında benzersizlik ölçülebilirse bir nesne diğerinden ayırt edilebilir. Analiz edilecek verilerin karakteristik özellikleri iyi tanımlanmalıdır (Güvenç & Karagül, 2009). Burada yazılım geliştiricilerin veya bu alanda çalışan herhangi birisinin müdahalesi yoktur. Denetimsiz öğrenme algoritmaları, girdi olarak verilen veriler içerisinde gizli kalmış ilişkileri/örüntüleri kendi başına bulmaya çalışır.

4.1.2.2.1 K-Means Algoritması

K-means algoritması ilk olarak 1967 yılında J. MacQueen tarafından kullanılan bir denetimsiz öğrenme algoritmasıdır. Bu yöntem orta noktaya ya da en yakın merkeze göre var olan sınıfları baz alarak nesneyi bölümlere ayırarak çalışır (Saplıoğlu & Acar, 2020). Şekil 4.6'da K-Means algoritmasının akış şeması verilmektedir.



Şekil 4. 6. K-Means algoritmasının akış şeması (Yıldız, Arıkan, Erenoğlu, & Kekezoğlu, 2021)

En eski kümeleme yöntemlerinden biri olan K-Means algoritmasının genel mantığı n adet veri nesnesinden oluşan bir veri setini giriş parametresi olarak verilen k adet kümeye bölümlenektir. Amaç; gerçekleştirilen bölümlenme işlemi sonunda elde edilen kümelerin, küme içi benzerliklerinin en fazla ve kümeler arası benzerliklerinin en az olmasını sağlamaktır (Demiralay & Çamurcu, 2005). Bu algoritma görüntü işlemede de kullanılmaktadır. K-Means algoritması, görüntülerde bölümlenme işlemlerinde kullanılan yöntemlerden biridir. Bu algorithmada k parametresine verilen değere göre görüntü içerisinde bölümlenme yapılabilir. Görüntü işlemede bölümlenme işlemi için sıkça kullanılan bir yöntemdir. Bu çalışmanın ilerleyen aşamalarında bu algoritma kullanarak çalışmalar yapılabileceği öngörülmektedir.

4.1.2.3 Pekiştirmeli Öğrenme (PÖ)

PÖ, doğrudan uygulanacağı çevrede deneme yanılma yöntemi ile doğru karar verebilmeyi ödül veya ceza ile sağlanabileceğini savunan bir denetimsiz öğrenme algoritmasıdır. PÖ'nün temelinde gözlem yatmaktadır. PÖ, robot kontrolü veya karmaşık kontrol problemlerini çözmek için kullanılan yöntemlerden biridir. PÖ, denetimli veya denetimsiz öğrenme gibi bir veri kümesine ihtiyaç duymadığı için diğer yöntemler ile kıyaslandığında daha maliyetsizdir (Bingöl, 2021).

4.1.3 Algoritmalarda Kullanılan Uzaklık Ölçüleri

Makine öğrenmesi ve derin öğrenme algoritmalarındaki parametrelerden biri uzaklık ölçüsüdür. Bir düzlemde iki nesnenin aynı özelliklerinin uzaklık bazında benzerliklerinin hesaplanmasını sağlayan ölçüttür. Bu bölümde, uzaklık ölçülerinden bazıları açıklanmıştır.

4.1.3.1 Öklid Uzaklığı

Öklid uzaklığı, iki veya daha fazla nokta arasındaki mesafeyi Pisagor bağlantısı kullanarak noktalar arası uzaklığı ölçmeyi sağlamaktadır. Formülde yer alan x ve y iki farklı noktayı, i indis değerini ve n ise boyut sayısını temsil etmektedir.

$$d_{\text{öklid}}(x,y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.1)$$

4.1.3.2 Manhattan Uzaklığı

İki nokta arasındaki uzaklık, bu noktalardan geçen ve dik kesişen doğru parçalarının uzaklığı kadardır.

$$d_{\text{Manhattan}}(x,y) = \sum_{i=1}^n |x_i - y_i| \quad (4.2)$$

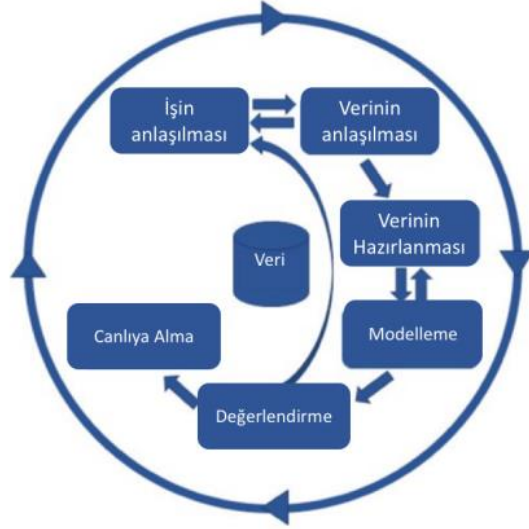
4.1.3.3 Minkowski Uzaklığı

P sayıda değişken göz önüne alınarak gözlem değerleri arasındaki uzaklığın hesaplanması için Minkowski uzaklık ölçüm metodu kullanılır. Formüldeki p bir hiperparametredir. Değiştirilebilir. Formülde p değeri 1 yapıldığında Manhattan, 2 yapıldığında Öklid ve ∞ yapıldığında Chebychev hesaplaması yapılır. Makine öğrenmesi algoritmalarında varsayılan değeri 2'dir.

$$d_{\text{Minkowski}}(x,y) = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (4.3)$$

4.1.4 Makine Öğrenmesi Süreci Adımları

Makine öğrenmesi ile veri madenciliği yakın ilişki içindedir. Veri madenciliği olarak bilinen alanda, makine öğrenmesi algoritmaları, donanım bakım kayıtları, kredi başvuruları, finansal işlemler, tıbbi kayıtları vb. bilgileri içeren büyük ticari veri tabanlarından değerli bilgiyi keşfetmek için sıklıkla kullanılmaktadır (Mitchell, 1997). Bir şeyin gelecekte daha iyi performans gösterecek biçimde davranışını değiştirdiği zaman öğrendiği anlaşılmaktadır. Bu davranışın öğrenmeyi bilgiden çok performans ile ilişkilendirmekte olduğunu belirterek makine öğrenmesinin performans iyileştirmesine odaklandığı vurgulanmıştır. Aralarındaki yakın ilişki dikkate alındığında, veri madenciliğinde izlenen sürece benzer bir yolun makine öğrenmesinde de izlenmesi olanaklıdır (Balaban & Kartal, 2018). Bu çalışmada izlenen veri madenciliği süreci CRISP-CM'dir. Şekil 4.7'de CRISP-DM şeması verilmiştir.



Şekil 4. 7. CRISP-DM adımları ve akışı (Şeker, 2018)

4.1.4.1 İşin Anlaşılması

Bu aşama problemin tanımlanması olarak da adlandırılmaktadır. Bu aşama veri madenciliği sürecinin en önemli aşamasıdır. Veri madenciliği çalışmalarında başarılı olmanın en önemli ön koşulu, projenin hangi amaç için yapılacağını ve elde edilecek sonuçların başarısının nasıl ölçüleceğinin belirlenmesidir. Yanlış tahminlerde katlanarak artacak maliyetler ve doğru tahminler yapıldığında kazanılacaklara bu aşamada yer verilerek düşünülmelidir. Araştırma probleminin tanımlanması aşaması araştırmanın amacını, mevcut durumun değerlendirilmesini, veri madenciliğinin amaçlarını ve proje planlama sürecinin belirlenmesinin tümünü kapsamaktadır (Savaş, 2020).

4.1.4.2 Verinin Anlaşılması

Başarılı sonuçların altında iyi bir analiz yatmaktadır. Makine öğrenmesi süreçlerinde analiz edilecek verinin iyi bir şekilde kavranması önemlidir. Verinin yapısını iyi bir şekilde öğrenmeden analiz yapmak ve ilerlemek yanlış sonuçları beraberinde getirir. İlerleyen aşamalarda elde edilen sonuçların yorumlanabilmesi ve buna göre doğru kararlar alınabilmesi bu adımda ki başarıya bağlıdır. Örneğin sağlık sektöründe bir doktor herhangi bir tıbbi görüntüye baktığında hastalık olup olmadığını, hastalık teşhisini nasıl yaptığını, görüntüde nerelere dikkat ettiğini gibi sorulara yanıtlar arayarak ve cevaplarını bularak analiz edeceğimiz veride aslında ne yapmak istediğimizi daha iyi anlamış oluruz. Makineler, insanlar sayesinde

insanları taklit etmeye çalışan aletlerdir. Önce insanlar anlamalı ki makinelere daha doğru sonuçlar üretmelerini sağlayabilsinler. Bu yüzden bu aşama kritiktir.

4.1.4.3 Verinin Hazırlanması

Modelin kurulması aşamasında ortaya çıkacak sorunlar, bu aşamaya sık sık geri dönülmesine ve verilerin yeniden düzenlemeler yapmak durumunda kalınacak sorunlara ve zaman kaybına neden olmaktadır. Bu durum verilerin hazırlanması ve modelin kurulması aşamaları için veriyi analiz edecek kişinin veri keşfi sürecinin toplamı içerisinde enerji ve zamanının %50 - %85'ini harcamasına neden olmaktadır. Verilerin hazırlanması aşaması kendi içerisinde toplama, birleştirme ve temizleme, seçme ve dönüştürme adımlarından meydana gelmektedir (Ayık, Özdemir, & Yavuz, 2010). Seçilen veri setinde eksik olan verilerin tamamlanması, gereksiz olduğuna karar verilen verilerin çıkarılması, normalizasyon işlemlerinin yapılması, verilerin sıkıştırılması gibi işlemler bu aşamada uygulanmaktadır.

4.1.4.4 Modelleme

Tanımlanan problem için en uygun modelin bulunabilmesi için çok sayıda modelin kurulup denenmesi gerekir. Burada analiz edilecek verinin etiketli veya etiketsiz oluşuna göre modellemeler yapılır. En doğru modele karar verinceye kadar verinin hazırlanması ve modelleme aşamalarında yinelemeli bir döngü kurulmalıdır. Yinelemeli döngünün kurulmasının sebebi bu iki aşamadan birinde hata varsa denemeler sonucu tespit edip müdahale edebilmektir. Veri hazırlama aşamasında eksik veya yanlış uygulamalar sonucu modelleme aşamasında kurulan model başarılı olamayabilir. Modelleme aşamasında da kötü kurulmuş bir modele veri hazırlama aşamasından başarıyla çıkmış veriler verildiğinde yine istenilen sonuç elde edilemeyebilir. Modele karar vermeden önce bu iki aşama iyice gözden geçirilmelidir. İlerleyen süreçlerde elde edilecek başarılı sonuçlar önceki süreçlere bağlıdır. Sürekli iyileştirmeler yapılmalıdır. Şekil 4.8'de sıçramalı ve kademeliye ek sıçramalı iyileştirmeyi kıyaslayan şema verilmektedir.



Şekil 4. 8. Sıçramalı ve kademeliye ek sıçramalı iyileştirme (Yalçın & Şen, 2012)

4.1.4.5 Model Seçimi ve Değerlendirme

Model seçimi sonrası işlenen ve analize hazır olan veriler eğitim için modele girdi olarak verilir. Modelin performansını değerlendirmek için belli metrikler kullanılır. Accuracy, precision, recall, F1 score gibi metriklerin sonuçları değerlendirilir ve modelin başarısı ölçülmüş olunur. Bu aşamada; model istenilen başarıyı gösterdi mi, yapılan testlerin sonuçları tutarlı mı ve seçilen model ilerleyen süreçte geliştirilebilir mi gibi sorular sorulmalıdır. Bu sorulara verilecek cevaplara göre son aşamaya geçilmelidir. Modelin sonuçları tatmin edici değilse sürecin başındaki yani problemin tanımlanması aşamasına dönmelidir.

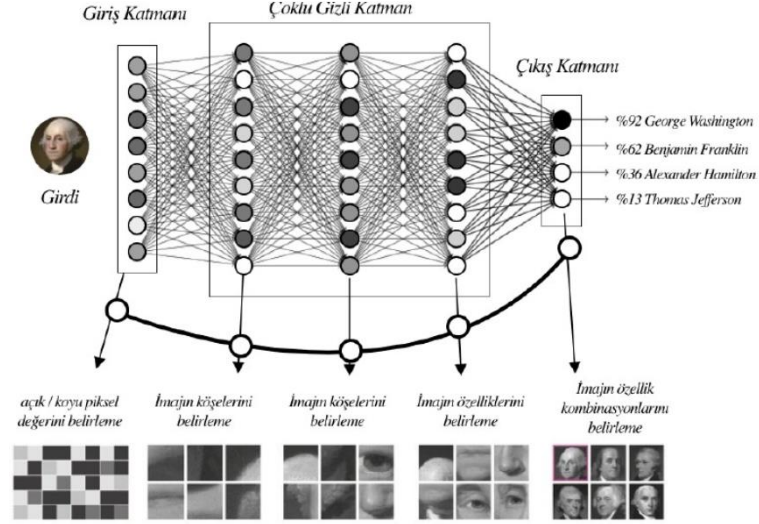
4.1.4.6 Canlıya Alma

Bu aşama seçilen modelin dağıtımını içermektedir. Modelin sonuçlarının sürekli takip edilmesi ve gerektiği durumlarda modeli devre dışı bırakma işlemleri bu aşamada yapılır. Düzenli bakım yapılması gerekir.

4.1.5 Derin Öğrenme Yöntemleri

Derin öğrenme; belirli katmanlardan yararlanarak ses dosyalarını metne dönüştürme, görüntü analizi, görüntü sınıflandırma, nesne bölütleme, videolarda nesne takibi gibi işlemler için kullanılan makine öğrenmesi yöntemlerindedir (Tan, Yüksel, Aydemir, & Ersoy, 2021). Derin öğrenme algoritması da makine öğrenmesi algoritmaları gibi veriye dayalı öğrenme gerçekleştirmektedir. Sinir ağı kurularak eğitim verileri modele girdi olarak verilir ve ağ eğitimi yapılır. Şekil 4.9'da derin öğrenme mimarisi verilmektedir. Derin yapıya sahip mimaride, özellikler ağın öğrenmesiyle oluşmaktadır. Derin öğrenmede modele girdi olarak verilen


verilerden yararlı olan ve sınıflandırılması yapılacak veriyi en iyi niteleyen özellikleri kendi kendine öğrenerek gerçekleştirir ve sebebiyle klasik yöntemlere göre daha başarılı sonuçlar ortaya koymaktadır (Kızrak & Bolat, 2018).



Şekil 4.9. Derin öğrenme mimarisi (Yapay zeka nedir?, 2020)


4.1.5.1 Yapay Sinir Ağları

Yapay Sinir Ağları, biyolojik sinir ağlarından esinlenerek oluşturulmuştur. İnsan beyninin özelliklerinden biri olan öğrenme yetisini taklit etmeyi amaçlamaktadır. Öğrenme sürecinin matematiksel modellenmesi yapılarak yapay sinir ağları geliştirilmiştir. Yeni bilgileri öğrenme, yeni bilgiler üretme ve türetme, öğrenilen bilgiler arasında ilişkiler kurmak ve önceki deneyimlere dayanarak hiç karşılaşılmayan durumlarda doğru kararlar verebilmeyi hedefleyen sistemlerdir. İnsan beyninin biyolojik yapılarını oluşturan nöronlar modellenerek bilgisayar sistemlerine aktarılmıştır. Nöronlar birbirine girdi gücünü veya önemini belirten sayısal değerlere yani ağırlıklara sahip bağlantılarla bağlıdır. YSA'nın matematiksel gösterimi Şekil 4.10'da gösterilmektedir. YSA, genellikle katmanlar halinde inşa edilir. Girdiye ait veriler katmanlar boyunca işlenerek çıktı değeri üretilmektedir. Ağırlıkların eğitim sürecinde güncellenmesiyle öğrenme gerçekleşir. Elde edilen çıktı değeriyle olması gereken çıktı değeri arasındaki farka hata değeri denmektedir. Bu hata değeri ağ boyunca ağırlıklara geri yayılım işlemiyle yayılır ve böylece ağırlıklar güncellenir. Biyolojik ve yapay sinir hücrelerinin modellenmesi Şekil 4.11'de gösterilmektedir.



Şekil 4. 10. Yapay sinir ağlarının matematiksel gösterimi (Kızırcak & Bolat, 2018)

YSA; çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik verilerinin olması ve problemin çözümü için özellikle bir matematiksel modelin ve algoritmanın bulunmaması durumlarında kullanılmaktadır (Altaş & Gülpınar, 2012). Literatürdeki çalışmalara bakıldığında YSA'nın başarıları görülmektedir.



Şekil 4. 11. Biyolojik sinir hücresi ve yapay sinir hücresinin modellemesi (Öztürk & Şahin, 2018)

4.1.5.1.1 Yapay Sinir Ağlarının Kullanım Alanları

Geçmişten günümüze yapay sinir ağları birçok alandaki uygulamalarda kullanılmaktadır. Bu uygulama alanlarına; üretim planlama, kan analizlerinin sınıflandırılması, beyin modellemesi çalışmaları, hastalık teşhisi, yüz tanıma, parmak izi tanıma, kredi kartı hilelerini saptama, zeki araçlar ve robotlar için en iyi rotayı belirleme, mekanik parçaların ömürlerinin tahmin edilmesi, ses tanıma, meteorolojik yorumlama, plaka tanıma, el yazısı tanıma, spam maillerin filtrelenmesi olarak örnekler verilebilir (Keskener & Keskener, 2017).


4.1.5.2 Derin Öğrenme Mimarileri

Derin öğrenme mimarileri kullanım amacına, analiz edilecek verinin türüne, katman sayısı, mimaride kullanılan katman türleri, katmanların aldığı parametreler gibi birçok faktöre göre birbirinden ayrılmaktadır. Bu bölümde görüntü işleme alanında en çok kullanılan derin öğrenme mimarilerinde ESA ve GAN açıklanmıştır.

4.1.5.2.1 ESA

Evrişimli sinir ağları yani ESA'lar çok katmanlı algılayıcıların bir türüdür. Hayvanların görme merkezinden esinlenerek geliştirilmiştir. Görüntü ve ses işleme, doğal dil işleme ve biyomedikal gibi alanlarda kullanılmaktadır. En iyi sonuçları görüntü işleme alanında vermiştir (Tüfekçi & Karpat, 2019). Çok katmanlı ileri beslemeli bir yapay sinir ağı olan ESA, özellikle görüntü analizlerinin yapılması için kullanılmaktadır (Doğan & Türkoğlu, 2019). ESA; nesne tanıma, sınıflandırma, özellik çıkarma, takip etme, doğal dil işlemede anlam çıkarma, tahmin gibi problemlerde kullanılmaktadır. Aynı zamanda Google DeepMind şirketinin AlphaGo yazılımında da kullanılmıştır (Kızrak & Bolat, 2018).

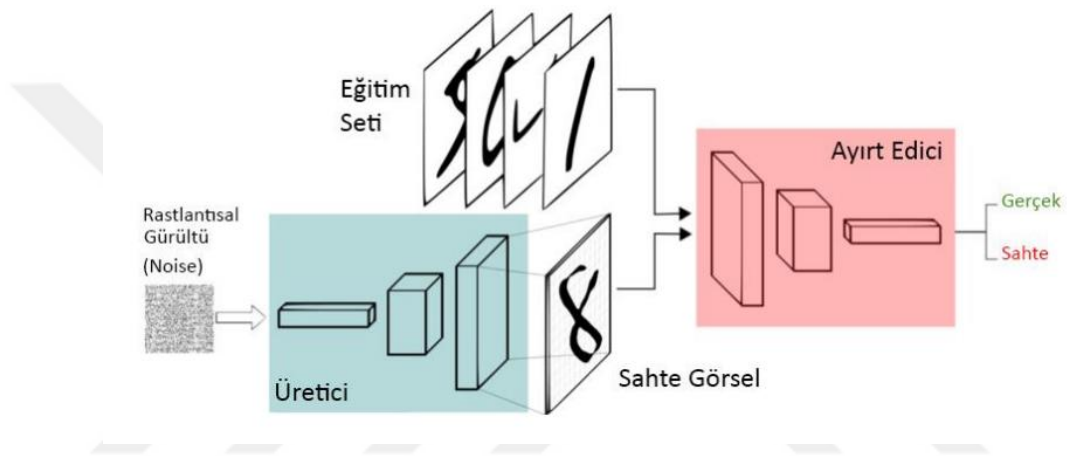
ESA mimarilerini programlayıp çalıştırıldığında programın kesintiye uğramaması için güçlü donanımlara ihtiyaç duyulmaktadır. Veri miktarlarındaki artış bu yöntemin popülerliğini artırmıştır. ESA bilinen klasik YSA'lardan farklı olarak özellik çıkarımı işlemini de kendi içerisinde gerçekleştirmektedir (Dağlı & Öztürk, 2021). Şekil 4.12'de ESA'nın genel mimarisi verilmiştir.



Şekil 4. 12. ESA'nın genel mimarisi (İnik & Ülker, 2017)

4.1.5.2.2 GAN

GAN olarak bilinen Çekişmeli Üretici Ağ modelleri, görüntü veri kümesinin artırılmasında, yüksek çözünürlüğe sahip görüntü elde etmede ve bir görüntüdeki dokunun başka bir görüntüye transferinde kullanılmaktadır (Eker & Duru, 2021). Modelin orijinal veri kümesinden yeni örnekler üretmek veya çıktı almak için kullanılabilmesi için girdi verilerindeki düzenlilikleri veya kalıpları otomatik olarak keşfetmeyi ve öğrenmeyi içermektedir (Sarker, 2021). GAN modellerinin genel mimarisinde biri üretici diğeri ayırıcı olmak üzere iki farklı derin ağ bulunmaktadır (Çelik & Talu, 2020). Şekil 4.13'te GAN şeması verilmektedir.



Şekil 4. 13. GAN çalışma prensibinin şeması (Çeliker, Efendioğlu, & Balaban, 2020)

4.1.5.3 Derin Öğrenme Mimarilerindeki Katmanlar

Derin öğrenme mimarilerini inşa ederken belli katmanlar kullanılır. Katmanlar belli parametrelerle ayarlanarak ya da varsayılan değerinde bırakılarak kullanılabilir. Bu katmanların sayısı arttıkça mimarinin derinliği de artmaktadır. Derin öğrenme mimarilerinde kullanılan katmanlar bu bölümde açıklanmıştır.

4.1.5.3.1 Giriş Katmanı

Bu katman ESA'nın ilk katmanını oluşturmaktadır. Bu katmanda veri ham olarak ağa verilmektedir. Tasarlanacak modelin başarımı için bu katmandaki verinin boyutu önem kazanmaktadır. Giriş görüntü boyutunun yüksek seçilmesi yüksek bellek ihtiyacını, eğitim süresinin uzamasını ve görüntü başına düşen test süresini uzatmak gibi problemlere yol açmaktadır. Fakat görüntü üzerindeki özellikler daha iyi çıkarılıp ağ başarısının artma ihtimali vardır. Giriş görüntü boyutunun düşük seçilmesi bellek ihtiyacını azaltır ve eğitim süresini

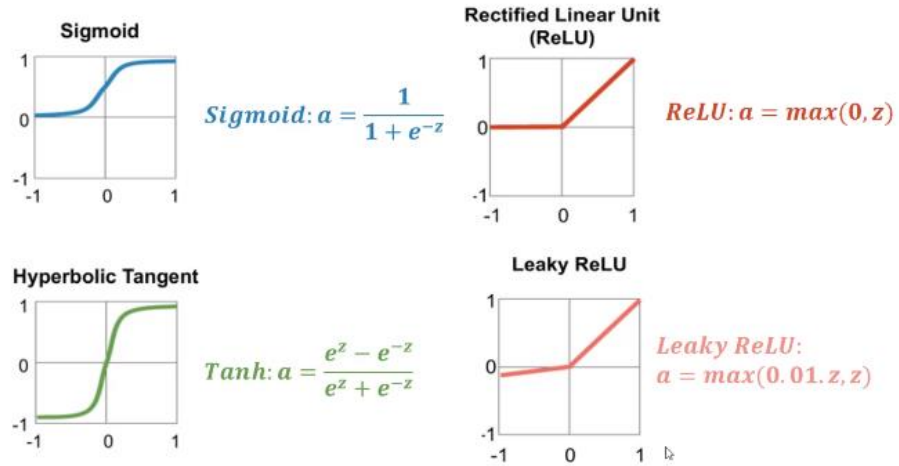
kısaltır. Fakat modelin performansı istenenenden daha düşük olabilir. Görüntü analizinde hem ağ derinliği hem donanımsal hesaplama maliyeti hem de ağ başarısı için uygun bir giriş görüntü boyutu seçilmelidir (İnik & Ülker, 2017).

4.1.5.3.2 Konvolüsyon Katmanı

Bu aşamada giriş verisi üzerinde daha küçük bir çekirdek matris seçilerek konvolüsyon işlemi uygulanmaktadır. Giriş matrisi üzerinde satır ve sütunlar boyunca gezdirilen bu çekirdek matris sonrası giriş verisinden n adet alt veri matrisi oluşturmaktadır. Bu katmanda çekirdek matrisinde kaydırma veya adım değeri de belirlenmektedir. Adım değeri arttıkça yakalanan özellikler azalmaktadır. Bu işlem ESA sınıflandırma başarısı açısından büyük önem arz etmektedir. Çekirdek matrise filtre de denilmektedir. Sınıflandırma işleminin başarısını artırmak için verinin artırımı, döndürülmesi gibi işlemler uygulanmaktadır (Santur, 2020).

4.1.5.3.3 Aktivasyon Katmanı

Aktivasyon katmanı, ağın verilerdeki karmaşık kalıpları öğrenmesine yardımcı olmak için yapay sinir ağlarına eklenen bir katmandır. Beynimizde bulunan nöron temelli bir modelle karşılaştırıldığında, aktivasyon işlevi sonunda bir sonraki nörona neyin gönderileceğine karar verir. Bir ESA'da da bir aktivasyon fonksiyonunun yaptığı tam olarak budur. Bir önceki hücreden gelen çıkış sinyalini alır ve onu bir sonraki hücreye girdi olarak alınabilecek bir forma dönüştürür. Aktivasyon fonksiyonları Şekil 4.14'te gösterilmektedir.



Şekil 4. 14. Aktivasyon fonksiyonları (Yıldırım E. , 2020)

4.1.5.3.4 Havuzlama Katmanı

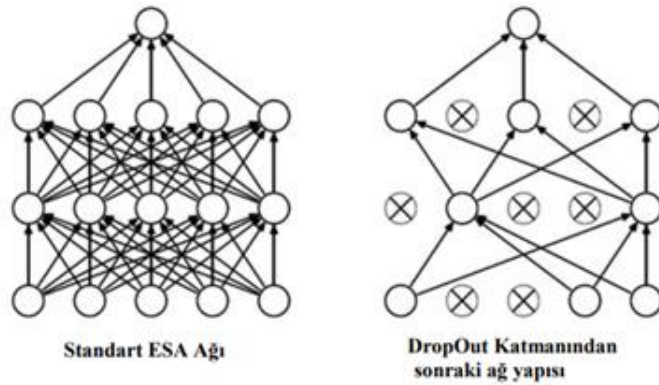
Bu katmanı, ağ içindeki parametreleri azaltır ve hesaplama yükünü azaltmak için kullanılır. Maksimum havuzlamada, filtre penceresinde kalan en büyük piksel değeri ve ortalama havuzlama işleminde filtre penceresinde kalan tüm piksel değerlerinin ortalaması çıktı matrisinde tek bir değer olarak tutulur. Havuzlama işleminin sonunda görüntünün en boy oranı azaltılmış olur. Bu süreçte piksel değerlerinde kayıplar olur, ancak bu kayıplar sonraki katmanlar için daha az hesaplama yükü oluşturur (Bozkurt & Yağanoğlu, 2021).

4.1.5.3.5 Düzleştirme Katmanı

Evrişim ve havuzlama katmanlarından sonra düzleştirme katmanı kullanılır. Evrişim ve havuzlama katmanları birçok kez kullanılabilir. Bu katmanlardan geçen veri düzleştirme katmanına gelir ve tam bağlantılı katmana girdi olabilmesi için $N \times 1$ 'lik bir matrise dönüştürülür.

4.1.5.3.6 Dropout Katmanı

ESA büyük verilerle eğitildiğinde ağın bazen ezberleme yaptığı görülür. Ağın ezberleme yapmasını önlemek için ezberleme katmanı kullanılmaktadır. Bu katmana bir ezberleme değeri verilir ve verilen değer oranına göre ağda bulunan düğümler kaldırılır. Şekil 4.15'te ESA üzerinde dropout katmanının uygulaması gösterilmektedir.



Şekil 4. 15. Bir ESA üzerinde dropout katmanının uygulaması (İnik & Ülker, 2017)

4.1.5.3.7 Tam Bağlantı Katmanı

Bu katman, önceki bölümlerde anlatılan ve ardı ardına tekrar eden öznelik çıkarım katmanlarından sonra gelmektedir. Kendinden önceki tüm katmanlarla bağlantılıdır (Dağlı &

Öztürk, 2021). Tam bağlantılı katman, genellikle ESA'nın sonunda bulunur ve sınıflandırma işlemlerinde kullanılır. Bu katman sınıf skorlarını optimize etmek için kullanılır. Bu katmandaki gizli katman sayısı derin öğrenmeye dayalı mimarilerde arasında farklılık gösterebilmektedir (Bozkurt & Yağanoğlu, 2021).

4.1.5.3.8 Sınıflandırma Katmanı

Bu katman tam bağlantılı katmandan sonra gelir. Çıkış katmanı olarak da adlandırılır. Derin öğrenme mimarilerinin bu katmanında sınıflandırma işlemi yapılmaktadır. Bu katmanın çıkış değeri, sınıflandırması yapılacak nesne sayısına eşittir. Bu katmanda farklı sınıflandırıcılar kullanılmaktadır. Çoğunlukla başarısından dolayı softmax aktivasyon fonksiyonu tercih edilir. İkili sınıflandırmalarda sigmoid seçildiğinde daha yüksek başarı elde edilmektedir. Analizde kaç farklı sınıf varsa ağa verilen her girdi verisine çıktısı olarak her sınıf için 0-1 aralığında bir çıkış değeri üretir. Her çıkış bir sınıfı temsil etmektedir. 1'e yakın sonucu üreten çıkış, ağın tahmin ettiği nesne olduğu anlaşılır (İnik & Ülker, 2017).

4.1.5.4 Hazır ESA Mimarileri

ESA, genellikle görüntü işleme alanında kullanılan bir derin öğrenme mimarisidir. Görüntülerdeki özellikleri yakalamada ve görüntüleri sınıflandırmada başarılıdır. Bu konuda başarısını kanıtlamış farklı mimarilerde ESA mimarileri bulunmaktadır. Bu çalışmada VGG16, ResNet50 ve DenseNet201 mimarileri kullanılmıştır. Bu bölümde bu mimariler açıklanmıştır.

4.1.5.4.1 VGGNet

VGGNet, Karen Simonyan ve Andrew Zisserman tarafından tasarlanan bir ESA modelidir (İnik & Turan, 2018). VGG, 2014 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda 2. olmuştur. VGG mimarisi 224x224x3 giriş görüntüsü kullanır. Genellikler evrimsel, havuzlama ve tam bağlantı olmak üzere 3 katmandan oluşmaktadır. Evrimsel katmanlar giderek derinleşen bir yapıya sahiptir. Bu derin yapıda 3x3'lük filtreler ve 2x2'lik havuzlama katmanları ile parametre sayısı azaltılır. Mimari 3 adet tam bağlantı katmanına sahiptir. Çıkış katmanı, 1000 sınıflı ve aktivasyon fonksiyonu softmax olan katmandır. Mimarinin büyük başarı sağladığı VGG-16, VGG-19 modellerinin yanında VGG-11, VGG-13 gibi farklı modellerle de çalışmalar yapılarak performansları gözlemlenip kıyaslanmaktadır (Donuk & Hanbay, 2021). Şekil 4.16'da VGG mimarisinin yapısı verilmiştir.

VGG Konfigürasyonları					
A	A-LRN	B	C	D	E
11 Ağırılık Katmanı	11 Ağırılık Katmanı	13 Ağırılık Katmanı	16 Ağırılık Katmanı	16 Ağırılık Katmanı	19 Ağırılık Katmanı
Girdi (224 x 224 RGB Resim)					
evriş3-64	evriş3-64 LRN	evriş3-64 evriş3-64	evriş3-64	evriş3-64	evriş3-64
Havuzlama					
evriş3-128	evriş3-128	evriş3-128 evriş3-128	evriş3-128	evriş3-128	evriş3-128
Havuzlama					
evriş3-256 evriş3-256	evriş3-256 evriş3-256	evriş3-256 evriş3-256	evriş3-256 evriş3-256 evriş1-256	evriş3-256 evriş3-256 evriş3-256	evriş3-256 evriş3-256 evriş3-256 evriş3-256
Havuzlama					
evriş3-512 evriş3-512	evriş3-512 evriş3-512	evriş3-512 evriş3-512	evriş3-512 evriş3-512 evriş1-512	evriş3-512 evriş3-512 evriş3-512	evriş3-512 evriş3-512 evriş3-512 evriş3-512
Havuzlama					
evriş3-512 evriş3-512	evriş3-512 evriş3-512	evriş3-512 evriş3-512	evriş3-512 evriş3-512 evriş1-512	evriş3-512 evriş3-512 evriş3-512	evriş3-512 evriş3-512 evriş3-512 evriş3-512
Havuzlama					
TB-4096					
TB-4096					
TB-1000					
softmax					

Şekil 4. 16. VGG ağ konfigürasyonu (Karakurt F. , 2018)

4.1.5.4.2 ResNet


Microsoft ResNet 2015 yılında gerçekleştirilen ImageNet yarışmasını kazanmıştır. Bu yarışmada %3,6 gibi bir hata oranı yakalamıştır. İnsanlar ortalama %5-%10 hata oranı ile görüntüyü sınıflandırırken %3,6'lık bir hata oranıyla insandan daha iyi görsel tanıma yapabildiğini göstermiştir. Daha önceki mimarilerden daha derin bir yapıya yani bu mimarinin katman sayısı diğer derin öğrenme mimarilerindeki katman sayılarından daha fazla katman sayısına sahiptir (Doğan & Türkoğlu, 2019). Şekil 4.17'de ResNet mimarisinin ağ konfigürasyonu verilmiştir.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2.x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3.x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4.x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5.x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Şekil 4. 17. ResNet ağ konfigürasyonu (He, Zhang, Ren, & Sun, 2016)

4.1.5.4.3 DenseNet

DenseNet, bilinen ve literatürdeki çalışmalarda başarısını ortaya koyan bir ESA mimarisidir. Tüm katmanları birbirine bağlıdır. Şekil 4.18’de DenseNet’te bulunan bir dense katmanın mimarisi verilmiştir. Şekil 4.19’da DenseNet ağ konfigürasyonu verilmektedir.



Şekil 4. 18. DenseNet’te bir dense katmanın temel mimarisi (Bozkurt, 2021)

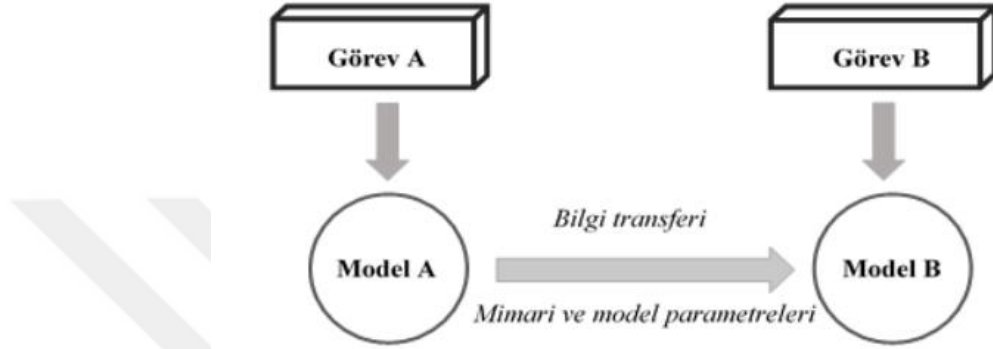
Layers	Output Size	DenseNet-121($k = 32$)	DenseNet-169($k = 32$)	DenseNet-201($k = 32$)	DenseNet-161($k = 48$)
Convolution	112×112	7×7 conv, stride 2			
Pooling	56×56	3×3 max pool, stride 2			
Dense Block (1)	56×56	1×1 conv 3×3 conv $\times 6$	1×1 conv 3×3 conv $\times 6$	1×1 conv 3×3 conv $\times 6$	1×1 conv 3×3 conv $\times 6$
Transition Layer (1)	56×56	1×1 conv			
	28×28	2×2 average pool, stride 2			
Dense Block (2)	28×28	1×1 conv 3×3 conv $\times 12$	1×1 conv 3×3 conv $\times 12$	1×1 conv 3×3 conv $\times 12$	1×1 conv 3×3 conv $\times 12$
Transition Layer (2)	28×28	1×1 conv			
	14×14	2×2 average pool, stride 2			
Dense Block (3)	14×14	1×1 conv 3×3 conv $\times 24$	1×1 conv 3×3 conv $\times 32$	1×1 conv 3×3 conv $\times 48$	1×1 conv 3×3 conv $\times 36$
Transition Layer (3)	14×14	1×1 conv			
	7×7	2×2 average pool, stride 2			
Dense Block (4)	7×7	1×1 conv 3×3 conv $\times 16$	1×1 conv 3×3 conv $\times 32$	1×1 conv 3×3 conv $\times 32$	1×1 conv 3×3 conv $\times 24$
Classification Layer	1×1	7×7 global average pool			
		1000D fully-connected, softmax			

Şekil 4. 19. DenseNet ağ konfigürasyonu (Huang, Liu, Maaten, & Weinberger, 2017)

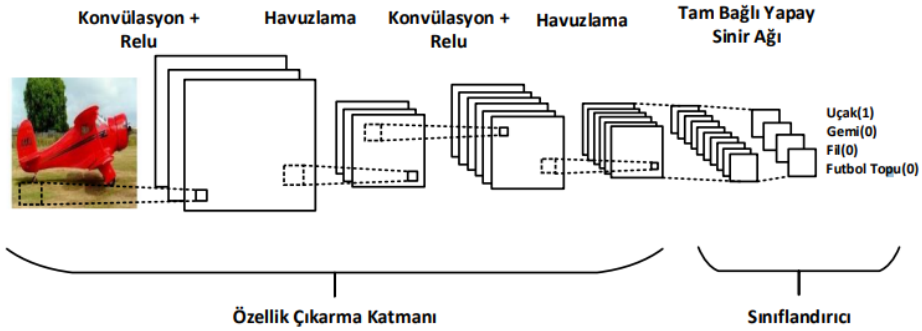
4.1.5.5 ESA ile Transfer Öğrenme

Transfer öğrenimi farklı görevler için elde edilen modellerin benzer diğer görevlerde yeniden kullanılması üzerinde kurgulanmış bir öğrenme modelidir. Şekil 4.20’de transfer öğrenmenin akış şeması verilmektedir. Transfer öğrenme ile çalışırken modelin yeniden eğitilmesine veya sıfırdan inşa edilmesine gerek yoktur. Sıfırdan bir ağı kurmaya ve eğitmeye göre çok daha hızlıdır. Önceden eğitilmiş bir model genellikle ImageNet gibi çok büyük ve fazlaca sınıflı veri setiyle eğitilerek eğitim sonrası elde edilen ağırlık değerleri yeni sınıflandırma veya özellik çıkarım işlemlerinde kullanılmaktadır. Transfer Öğrenme modellerini özellik çıkarımında kullanmak için modelin tam bağlantılı katmanı çıkarılır (Ağca & Takcı, 2022). Geri kalan katmanlarda eğitim durdurulur ve sınıflandırıcı kısmına mimariyi

tasarlayacak olan kişi gizli katmanı veya katmanları ve çıkış katmanını ekleyerek sadece en son eklenen katmanlarda eğitim yapılması sağlanır. Hibrid bir yapıda da sınıflandırma yapılabilir. Giriş katmanından tam bağlantılı katmana kadar ki kısım özellik çıkarımı için kullanılmaktadır. Transfer öğrenme metoduyla özellik çıkarımı yapıp gizli katman eklemek yerine RF ve KNN gibi geleneksel makine öğrenmesi algoritmalarıyla da sınıflandırma yapılabilir. Şekil 4.21’de ESA mimarisinde özellik çıkarım ve sınıflandırma bölümleri gösterilmektedir.



Şekil 4. 20. Transfer öğrenme akış şeması (Çelik & Kasım, 2021)




Şekil 4. 21. ESA ağ konfigürasyonu (Fırıldak & Talu, 2019)

5. DENEYSEL ÇALIŞMALAR

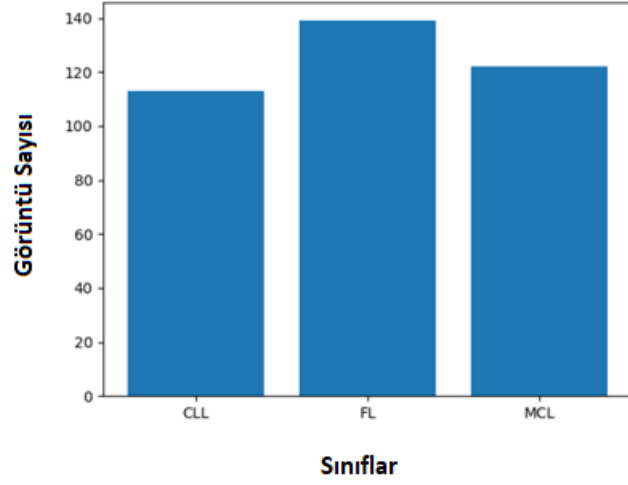
Bu bölümde çalışmada kullanılan veri seti, programlama dili, kütüphaneler, IDE ve deneysel çalışmaların sonuçlarını gösteren tablolara ve açıklamalarına yer verilmiştir.

5.1 Çalışmada Kullanılan Veri Seti

Çalışmada kullanılan veri seti Kaggle platformundan alınmıştır. Veri seti içerisinde farklı bölgelerden ve farklı patologlar tarafından hazırlanmış HE boyalı CLL, FL ve MCL lenfoma türlerine ait toplamda 374 tane biyopsi görüntü bulunmaktadır. CLL klasöründe 113, FL klasöründe 139 ve MCL klasöründe 122 tane görüntü bulunmaktadır. Şekil 5.1’de veri setinde bulunan orijinal görüntülerin bir kısmı verilmektedir. Veri setinin boyutu 1.6 GB’tır ve görüntüler TIFF formatındadır. Görüntülerin veri seti içerisindeki dağılımı Şekil 5.2’de gösterilmektedir.

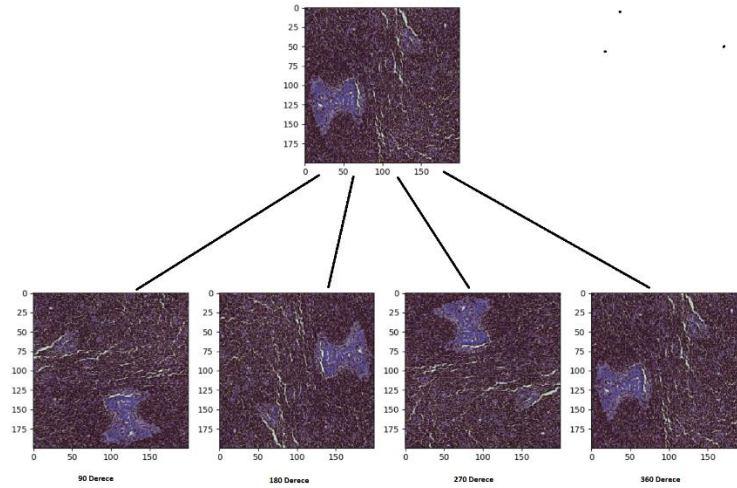


Şekil 5. 1. Veri setinde bulunan orijinal görüntülerin bir kısmı




Şekil 5. 2. Veri artırım öncesi veri setindeki sınıflara göre görüntülerin dağılımı

ESA mimarileri büyük veri setleriyle başarılı performans göstermektedir. Derin öğrenme modellerinin performansı yeni veri toplamak yerine mevcut verileri artırarak da geliştirilebilir. Veri seti içerisinde görüntü sayısını arttırmak için veri artırım metotlarından rotasyon seçilmiştir. Her bir görüntü ayrı ayrı 90,180, 270 ve 360 derecelerde döndürülerek veri setinde artırım yapılmıştır. Bir görüntüye rotasyon işlemi uygulandıktan sonraki elde edilen görüntüler Şekil 5.3'te gösterilmektedir. Bu sayede toplamda 1496 tane görüntü elde edilmiştir. Görüntülerin veri seti içerisindeki dağılımı Şekil 5.4'te gösterilmektedir.



Şekil 5. 3. Bir histopatolojik görüntünün belirtilen açılarda döndürülmüş halleri



Şekil 5. 4. Veri artırım sonrası veri setindeki sınıflara göre görüntülerin dağılımı

5.2 Python ve Kullanılan Kütüphaneler

Veri bilimi ve yapay zeka alanlarında en çok kullanılan programlama dili Python'dır. Veri analiziyle ilgili kapsamlı kütüphaneler sunması Python programlama dilini veri bilimi alanında popüler hale getirmiştir. Bu bölümde çalışmada kullanılan Python programlama dili ve kütüphaneler açıklanmıştır.

5.2.1 Python

Python programlama dili, öğrenmesi kolay, nesneye yönelik ve güçlü bir programlama dilidir. Guido van Rossum tarafından yaratılmış ve 1991 yılında piyasaya sürülmüştür (Python introduction, t.y.). Python programlama dili, yüksek seviyesi, etkileşimli doğası ve olgun ekosistemi nedeniyle bilimsel hesaplama için en popüler seçeneklerden biri olarak kendini kanıtlamıştır (Perez & Granger, 2007).

Diğer programlama dillerinin aksine satır sonuna noktalı virgöl koyulmaz. Satır sonunu belirtmek için bir alt satıra geçilir. Diğer programlama dillerinde döngülerin, fonksiyonların ve sınıfların kapsadığı kod parçalarını kümelemek için '{ }' kullanılır. Python'da kod parçalarını kümelemek için girintiler oluşturulur. Aynı kümede ki kod parçaları aynı hizada olmalıdır. Aynı hizada bulunan kodlar aynı statüde veya kümededir anlamına gelir. Python'da değişkenlerin tipi belirtilmez. Python programlama dili kullanarak birçok işlem yapılabilir. Masaüstü ve web formunda projeler geliştirilebilir, geliştirilen projelere veritabanı bağlantıları yapılabilir, görüntü işleme işlemleri, makine öğrenmesi ve derin öğrenme algoritmaları kullanarak uzman

sistemler oluşturulabilir, büyük veriler işlenebilir gibi daha birçok işlem Python'la gerçekleştirilebilir. Python, farklı platformlarda da çalışabilir. Yani platform bağımsızdır ve cross-platform özelliğine sahiptir. Diğer programlama dillerine göre daha az satır kod yazılarak aynı işlem yapılabilir.

5.2.2 Sklearn

Sklearn, makine öğrenmesi algoritmalarını kullanmak ve geliştirmek için kullanılan açık kaynak Python kütüphanesidir. Sınıflandırma, regresyon ve kümeleme için kullanılan pek çok makine öğrenmesi algoritmasını bünyesinde bulundurmaktadır. Bu kütüphane ESA mimarilerini desteklememektedir. Sadece geleneksel makine öğrenmesi algoritmaları kullanmak veya geleneksel makine öğrenmesi algoritmalarıyla birlikte derin öğrenme yöntemlerini kullanarak hibrid bir yapıda çalışmalar yapılacaksa Sklearn kütüphanesine ihtiyaç duyulmaktadır.

5.2.3 OpenCV

OpenCV, mantıksal ve aritmetik işlemler gibi temel görüntü işlemlerinden oluşur ve ayrıca nesne algılama ve nesne takibi gibi karmaşık işlemleri de içerir (Sugano & Miyamoto, 2010). Görüntü işlemeyle ilgili standart işlemler bulunmaktadır ve bu işlemlerin her birinin ayrı ayrı algoritmaları vardır. Kodlama yaparken programlama dilinin desteklediği hazır kütüphaneler kullanılarak bu işlemlerin algoritmalarını uzun uzun yazmaya gerek kalmadan görüntü işlemeyle ilgili kodlar yazılmaktadır. OpenCV'de bu hazır kütüphanelerden biridir. Python projelerine 'cv2' yazılarak eklenir.

OpenCV, 1999 yılında Intel tarafından geliştirilmiştir. BSD lisanslı bir ürün olan OpenCV, işletmelerin kodu kullanmasını ve değiştirmesine olanak sağlar. Bu kütüphane hem klasik hem de son teknoloji bilgisayarlı görme ve makine öğrenimi algoritmalarından oluşan kapsamlı bir kütüphanedir. İçerisinde 2500'den fazla algoritma bulunmaktadır. Bu algoritmalar, yüz tanıma ve algılama, nesneleri tanımlama, videolardaki nesnelere takip etme, gibi amaçlarda kullanılmaktadır. Görüntü tabanlı uygulamalarda sıklıkla kullanılmaktadır. Elde edilen görüntülerdeki kusurların giderilmesi, iyileştirilmesi ve analizini kolaylaştırmak için kullanılmaktadır (About, t.y.).

5.2.4 Numpy

NumPy, Python'da bilimsel hesaplama için temel pakettir. Çok boyutlu bir dizi nesnesi, çeşitli türetilmiş nesnelere (maskelenmiş diziler ve matrisler gibi) ve diziler üzerinde matematiksel, mantıksal, şekil işleme, sıralama, seçme, G/Ç dahil olmak üzere hızlı işlemler için çeşitli rutinler sağlayan bir Python kütüphanesidir (Numpy documentation, t.y.). Numpy, makine öğrenmesi alanında çalışmalar yapan kişiler için temel bir kütüphanedir. Makine öğrenmesi süreci adımlarında sıklıkla kullanılmaktadır. Özellikle veri ön işleme aşamasında kullanılmaktadır.

NumPy dizisi, öğelerin çok boyutlu, tek biçimli bir koleksiyonudur. Bir dizi, içerdiği öğelerin türü ve şekli ile karakterize edilir. Örneğin, bir matris, sayıları içeren, örneğin kayan nokta veya karmaşık sayılar içeren bir şekil dizisi ($M \times N$) olarak temsil edilebilir. Matrislerin aksine, NumPy dizileri herhangi bir boyuta sahip olabilir. Ayrıca, booleanlar veya tarihler gibi başka tür öğeler (veya hatta öğe kombinasyonları) içerebilirler. Başlık altında, bir NumPy dizisi, temsil edilen sayıların kolayca değiştirilebilmesi için bir veya daha fazla bilgisayar belleği bloğunu tanımlamanın gerçekten uygun bir yoludur (Colbert & Varoquaux, 2011).

5.2.5 Tensorflow

Tensorflow, açık kaynaklı bir Python kütüphanesidir. Bu kütüphaneyle ESA mimarileri inşa edilebilir veya hazır olan ESA mimarileri kullanılarak çalışmalar yapılır. Google tarafından geliştirilmiştir. Temelinde Python yazılım dili kullanılarak geliştirilen bu kütüphane; C++, Java, C# ve R gibi pek çok dili desteklemektedir.

5.2.6 Keras

Keras; derin öğrenme modellerini inşa etmek, tanımlamak ve eğitmek için kullanılan bir Python kütüphanesidir. Keras, Tensorflow ve Theano üzerinde çalışmaktadır. Keras kütüphanesinin temel amacı yapay sinir ağlarını hızlıca programlanabilirliğini sağlamaktır. Makine öğrenmesi ve derin öğrenme alanında çalışmalar yapan kişilerin modellerini eğitmelerini ve deneysel çalışmalar yapmalarına olanak sağlar.

5.2.7 Skimage

Skimage, bir görüntü işleme kütüphanesidir. Bu kütüphanede, görüntü üzerindeki özellik çıkarmayı sağlayan bazı yöntemler bulunmaktadır. Çalışmada GLCM metodunu kullanabilmek için bu kütüphane projeye dahil edilip kullanılmıştır.

5.2.8 Pandas


Pandas, veri analizleri yapmak için kullanılan açık kaynak kodlu bir Python kütüphanesidir. Pandas ilk olarak 2008 yılında piyasaya sürülmüştür. Pandas kütüphanesiyle veri temizleme, doldurma normalleştirme, birleştirme, ayırma, yükleme ve kaydetme gibi işlemler yapılır. Pandas'ta bulunan DataFrame sayesinde veriler tablo haline dönüştürülür ve işlemler yapılır. Pandas bünyesinde NumPy'daki metotlara benzer metotlar mevcuttur. Aralarındaki fark ise NumPy aynı veri tipleriyle çalışırken Pandas farklı veri tipleriyle de çalışmaya olanak sağlar. Veri bilimi alanında çalışmalar yapan kişilerin sıkça kullandığı bir kütüphanedir.

5.2.9 OS

Python'da dosyaları işlemek için OS kütüphanesi kullanılır. Komut istemcisinde komutlar yazmak yerine Python programlama dili aracılığıyla OS kütüphanesi kullanılarak dosyalar üzerinde işlemler yapılır. Yeni dosya oluşturma, geçerli dosyanın adını veya uzantısını değiştirme, geçerli çalışma dizinini alma/değiştirme, klasör oluşturma, dosya veya klasörleri silme, dosyaların veya klasörlerin dizinini değiştirme, klasörlerin adını değiştirme, dosyaların içeriğini okumak veya değiştirmek gibi dosya işlemleri bu kütüphaneye gerçekleştirilir.

5.3 Visual Studio 2019

IDE, yazılım geliştirmenin birçok yönünü destekleyen zengin özelliklere sahip bir programdır. Visual Studio IDE; kod düzenlemek, paket yüklemek, hata ayıklamak, derlemek ve ardından bir uygulamayı yayımlamak için kullanılabilir (Lee & Par, 2022). Python programlama dilini destekleyen birçok IDE bulunmaktadır. Bu IDE'lerden en popülerleri VS, VS Code, PyCharm ve Spyder'dır. Yazılımcının kullanım alışkanlıkları, paket yönetim sistemi, IDE'nin varsayılan ayarlarına tekrardan ayara gerek olup olmaması gibi kriterlere göre IDE seçimi yapılır. Bu çalışmada IDE olarak Visual Studio 2019 seçildi. Çalışma bu ortamda geliştirildi. Visual Studio 2019'un logosu Şekil 5.5'te gösterilmektedir.



Şekil 5. 5. Visual Studio 2019 logosu

5.4 Sınıflandırma Performans Metrikleri

Makine öğrenmesi ve derin öğrenme yöntemleriyle eğitim yaptıktan sonra modelin başarısını ölçmek için bazı metriklere bakılır. Bu metrikleri hesaplamak için eğitilmiş modele test için ayrılan veriler girdi olarak verilerek tahminleme işlemi yapılır. Tahminleme sonrası sınıflandırma sonuçlarını ölçmek için karışıklık matrisi (confusion matrix(CM)) incelenir. Bu matris girdi değerlerinin ne kadar doğru sınıflandırıldığı gösterir. Şekil 5.6'da ikili sınıflandırma için örnek CM gösterilmektedir.

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	TP	FN
	Negatif	FP	TN

Şekil 5. 6. İkili sınıflandırma için CM (Bilen, 2021)

CM'de; TP, FP, FN ve TN değerleri bulunmaktadır. TP, gerçekte pozitif olan bir değeri tahminde de pozitif bulunan değerlerin sayısıdır. FP, gerçekte negatif olup pozitif tahmin edilenlerin sayısıdır. FN, gerçekte pozitif olup negatif tahmin edilenlerin sayısıdır. TN, gerçekte negatif olup negatif tahmin edilenlerin sayısıdır. Bu değerler kullanılarak bazı ölçümler yapılmaktadır. Bu ölçümler; accuracy, precision, recall ve F-Score'dur. Accuracy, gerçekte pozitif olup pozitif tahmin edilenlerle gerçekte negatif olup negatif tahmin edilenlerin bütün

tahminlere oranını veren değerdir. Precision, pozitif tahmin edilenlerin kaç tanesinin gerçek pozitif sınıflandırıldığına oranını veren değerdir. Recall, gerçekte pozitif olup pozitif tahmin edilenlerin gerçek pozitiflere oranını veren değerdir. F1-Score, precision ve recall değerlerinin harmonik ortalamasını veren değerdir.

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{FP} + \text{TN} + \text{FN}) \quad (5.1)$$

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (5.2)$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (5.3)$$

$$\text{F1-Score} = 2 * \text{Precision} * \text{Recall} / (\text{Precision} + \text{Recall}) \quad (5.4)$$

5.5 Özellik Çıkarımı

Örüntü tanımanın temel basamaklarından birisi olan öznelik çıkarma örüntüyü diğer örüntülerden ayırt edebilecek yapısal ve istatistiksel özelliklerin belirlenmesidir (Şişeci & Cetişli, 2012). Çalışmada özellik çıkarımı için kullanılan GLCM ve transfer öğrenmenin çalışmada nasıl kullanıldığı bu bölümde açıklanmıştır.

5.5.1 GLCM

GLCM, gri seviye görüntülerde özellik çıkarımı için kullanılan bir yöntemdir. Görüntüde bulunan farklı piksel değerlerini alarak bu pikselleri çiftler halinde bulunma sayılarını belirten bir matris oluşur. Bu piksel çiftleri verilen açı değerlerinde görüntüyü tarayarak aynı piksel çiftlerini bulmaya çalışır. GLCM’de bu matris çıkarıldıktan sonra elde edilen matris üzerinden özellikler çıkarılır. Bu çalışmada, GLCM’e açı değeri olarak 0, 45, 90 ve 135 değerleri verilmiştir. Piksel çiftleri görüntüleri bu yönlerde taramıştır. Daha sonra her bir açı için ayrı ayrı matris çıkarıldığı görülmüştür. Bu matrislerdeki verilere göre korelasyon, homojenlik, kontrast, ASM, enerji, benzemezlik ve entropi özellikleri çıkarılmıştır.

5.5.2 Transfer Öğrenme

Transfer öğrenimi; bir görev için eğitilmiş bir modelin, benzer yapıdaki başka bir görevi gerçekleştirmek için kullanılmasıdır. Transfer öğrenme modellerinin özellik çıkarımı için kullanılmasında son katman çıkarılarak kullanılmaktadır (Ağca & Taccı, 2022). Geri kalan katmanlarda eğitim durdurulur ve sınıflandırıcı kısmına mimariyi tasarlayacak olan kişi gizli katmanı veya katmanları ve çıkış katmanını ekleyerek sadece en son eklenen katmanlarda

eđitim yapılması sađlanır. Hibrid bir yapıda da sınıflandırma yapılabilir. Giriş katmanından tam bađlantılı katmana kadar ki kısım özellik çıkarımı için kullanılmaktadır. Transfer öğrenme metoduyla özellik çıkarımı yapıp gizli katman eklemek yerine RF ve KNN gibi geleneksel makine öğrenmesi algoritmalarıyla da sınıflandırma yapılabilir.

Çalışmada ki ikinci yaklaşımda, VGG16 modelinin tam bađlı katmanı çıkarılıp kalan katmanların öğrenmesi durdurularak sadece özellik çıkarımı için kullanıldı. Bu sayede transfer öğrenme yapıldı. Özellik çıkarımı sonrası RF, KNN, NB ve DT algoritmalarıyla sınıflandırma yapılmıştır. Böylece hibrid bir yapı kurularak deneysel çalışma yapılmıştır. Çalışmada ki üçüncü ve son yaklaşımda; VGG16, DenseNet201 ve ResNet50 mimarilerinin tam bađlantılı katmanı çıkarılıp geri kalan katmanlarda öğrenme durdurulmuştur. Sınıflandırma işlemi için bu mimarilere genel olarak düzleştirme, dense, dropout ve çıkış katmanları eklenmiştir. Çıkış katmanına ikili sınıflandırma yapılırken 2 parametresi ve aktivasyon fonksiyonu olarak sigmoid ayarlanmıştır. Kayıp fonksiyonu olarak binary_crossentropy belirlendi. Üçlü sınıflandırmada çıkış değeri 3 ve aktivasyon fonksiyonu softmax olarak ayarlandı. Kayıp fonksiyonu olarak sparse_categorical_crossentropy ayarlandı. Bu katmana 1024 parametre değeri olarak verilmiştir. Şekil 5.7'de çalışmadaki son yaklaşımdaki VGG16 mimarisinin son hali verilmektedir. Şekil 5.8'de çalışmadaki son yaklaşımdaki DenseNet201 mimarisinin son katmanları ve ondan önceki özellik çıkarım katmanlarından bazılarını gösteren şema verilmektedir. Çalışmadaki son yaklaşımdaki ResNet50 mimarisinin son katmanları ve ondan önceki özellik çıkarım katmanlarından bazılarını gösteren şema Şekil 5.9'da verilmektedir.

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_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
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_pool (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
Flatten (Flatten)	(None, 25088)	0
dense (Dense)	(None, 1024)	25691136
dropout (Dropout)	(None, 1024)	0
dense_1 (Dense)	(None, 1)	1025
Total params: 40,406,849		
Trainable params: 25,692,161		
Non-trainable params: 14,714,688		

Şekil 5. 7. VGG16 mimarisinin son hali

conv5_block31_2_conv (Conv2D)	(None, 7, 7, 32)	36864	conv5_block31_1_relu[0][0]
conv5_block31_concat (Concatenation)	(None, 7, 7, 1888)	0	conv5_block30_concat[0][0] conv5_block31_2_conv[0][0]
conv5_block32_0_bn (Batch Normalization)	(None, 7, 7, 1888)	7552	conv5_block31_concat[0][0]
conv5_block32_0_relu (Activation)	(None, 7, 7, 1888)	0	conv5_block32_0_bn[0][0]
conv5_block32_1_conv (Conv2D)	(None, 7, 7, 128)	241664	conv5_block32_0_relu[0][0]
conv5_block32_1_bn (Batch Normalization)	(None, 7, 7, 128)	512	conv5_block32_1_conv[0][0]
conv5_block32_1_relu (Activation)	(None, 7, 7, 128)	0	conv5_block32_1_bn[0][0]
conv5_block32_2_conv (Conv2D)	(None, 7, 7, 32)	36864	conv5_block32_1_relu[0][0]
conv5_block32_concat (Concatenation)	(None, 7, 7, 1920)	0	conv5_block31_concat[0][0] conv5_block32_2_conv[0][0]
conv5_block32_bn (Batch Normalization)	(None, 7, 7, 1920)	7680	conv5_block32_concat[0][0]
conv5_block32_relu (Activation)	(None, 7, 7, 1920)	0	conv5_block32_bn[0][0]
conv5_avg_pool (Global Average Pooling2)	(None, 1920)	0	conv5_block32_relu[0][0]
conv5_dropout (Dropout)	(None, 1920)	0	conv5_avg_pool[0][0]
conv5_dense (Dense)	(None, 3)	5763	conv5_dropout[0][0]
Total params: 18,327,747			
Trainable params: 5,763			
Non-trainable params: 18,321,984			

Şekil 5. 8. DenseNet201 mimarisinin son hali

conv5_block1_2_bn (Batch Normalization)	(None, 7, 7, 512)	2048	conv5_block1_2_conv[0][0]
conv5_block1_2_relu (Activation)	(None, 7, 7, 512)	0	conv5_block1_2_bn[0][0]
conv5_block1_3_conv (Conv2D)	(None, 7, 7, 2048)	2099200	conv5_block1_2_relu[0][0]
conv5_block1_3_bn (Batch Normalization)	(None, 7, 7, 2048)	1050624	conv5_block1_3_conv[0][0]
conv5_block1_3_relu (Activation)	(None, 7, 7, 2048)	8192	conv5_block1_3_bn[0][0]
conv5_block1_3_conv (Conv2D)	(None, 7, 7, 2048)	8192	conv5_block1_3_relu[0][0]
conv5_block1_add (Add)	(None, 7, 7, 2048)	0	conv5_block1_3_conv[0][0] conv5_block1_3_conv[0][0]
conv5_block1_out (Activation)	(None, 7, 7, 2048)	0	conv5_block1_add[0][0]
conv5_block2_1_conv (Conv2D)	(None, 7, 7, 512)	1049888	conv5_block1_out[0][0]
conv5_block2_1_bn (Batch Normalization)	(None, 7, 7, 512)	2048	conv5_block2_1_conv[0][0]
conv5_block2_1_relu (Activation)	(None, 7, 7, 512)	0	conv5_block2_1_bn[0][0]
conv5_block2_2_conv (Conv2D)	(None, 7, 7, 512)	2359808	conv5_block2_1_relu[0][0]
conv5_block2_2_bn (Batch Normalization)	(None, 7, 7, 512)	2048	conv5_block2_2_conv[0][0]
conv5_block2_2_relu (Activation)	(None, 7, 7, 512)	0	conv5_block2_2_bn[0][0]
conv5_block2_3_conv (Conv2D)	(None, 7, 7, 2048)	1050624	conv5_block2_2_relu[0][0]
conv5_block2_3_bn (Batch Normalization)	(None, 7, 7, 2048)	8192	conv5_block2_3_conv[0][0]
conv5_block2_3_relu (Activation)	(None, 7, 7, 2048)	0	conv5_block2_3_bn[0][0]
conv5_block2_add (Add)	(None, 7, 7, 2048)	0	conv5_block2_3_relu[0][0] conv5_block2_3_relu[0][0]
conv5_block2_out (Activation)	(None, 7, 7, 2048)	0	conv5_block2_add[0][0]
conv5_block3_1_conv (Conv2D)	(None, 7, 7, 512)	1049888	conv5_block2_out[0][0]
conv5_block3_1_bn (Batch Normalization)	(None, 7, 7, 512)	2048	conv5_block3_1_conv[0][0]
conv5_block3_1_relu (Activation)	(None, 7, 7, 512)	0	conv5_block3_1_bn[0][0]
conv5_block3_2_conv (Conv2D)	(None, 7, 7, 512)	2359808	conv5_block3_1_relu[0][0]
conv5_block3_2_bn (Batch Normalization)	(None, 7, 7, 512)	2048	conv5_block3_2_conv[0][0]
conv5_block3_2_relu (Activation)	(None, 7, 7, 512)	0	conv5_block3_2_bn[0][0]
conv5_block3_3_conv (Conv2D)	(None, 7, 7, 2048)	1050624	conv5_block3_2_relu[0][0]
conv5_block3_3_bn (Batch Normalization)	(None, 7, 7, 2048)	8192	conv5_block3_3_conv[0][0]
conv5_block3_3_relu (Activation)	(None, 7, 7, 2048)	0	conv5_block3_3_bn[0][0]
conv5_block3_add (Add)	(None, 7, 7, 2048)	0	conv5_block3_3_relu[0][0] conv5_block3_3_relu[0][0]
conv5_block3_out (Activation)	(None, 7, 7, 2048)	0	conv5_block3_add[0][0]
flatten (Flatten)	(None, 100352)	0	conv5_block3_out[0][0]
dropout (Dropout)	(None, 100352)	0	flatten[0][0]
dense (dense)	(None, 3)	301059	dropout[0][0]
Total params: 23,880,771			
Trainable params: 80,659			
Non-trainable params: 23,800,112			

Şekil 5. 9. ResNet50 mimarisinin son hali

5.6 Özellik Seçimi

Özellik seçimi, analiz edilecek veri setindeki verileri en iyi temsil eden özelliklerin belirlenmesidir. Bu seçim işlemiyle boyut azaltımı da yapılmış olur. Bunun için literatürde birçok yöntem bulunmaktadır. Özellik seçimi yaparken verileri niteleyen genel özelliklerin seçilmesi daha sonraki aşamalarda verinin analizi için çok önemlidir. Genel özellikleri seçerken belli bir kayıp meydana gelmektedir. Bu kaybın genel yani verileri niteleyen önemli özelliklerden olmaması gerekir.

Çalışmada özellik seçimi yapılan kısımlarda PCA kullanılmıştır. Kodlama yaparken PCA'nın n_component parametresine değer vererek veriler içerisindeki en değerli özellikleri içeren bir boyutu azaltılmış öznelik vektörü elde edilir. PCA'nın bu parametresine 0,4 değeri verildiğinde demek istenen PCA yönteminin girdi olarak aldığı verilerin özneliklerinin %40'ının korunması istenildiği anlamına gelmektedir. Deneysel çalışmalarda PCA'nın n_component parametresine 0,4 ve 0,5 değerleri verilmiştir. Bide varsayılan değerde bırakılıp parametreye değer vermeden de deneysel çalışmalar yapıp etkileri incelendi.

5.7 Çalışmadaki Yaklaşımlar ve Sonuçları

Bu çalışmada 3 farklı yaklaşımla deneyler yapılmıştır. Her bir yaklaşım “Çalışmada İzlenecek Metodoloji” bölümünde açıklanmıştır. Bu bölümde verilecek çizelgelerde ikili ve üçlü sınıflandırmaya göre sınıflandırma sonuçları yer almaktadır. İlk yaklaşımda veri setindeki görüntüler gri seviyeye dönüştürülen görüntülerin GLCM'le özellikleri çıkarılır ve makine öğrenmesi algoritmalarıyla sınıflandırılması yapılır. PCA'nın etkilerini gözlemlemek için GLCM sonrası PCA uygulayarak da sınıflandırma yapılır ve sonuçlar incelenir. Bu işlemler veri artırımı sonrası da yapılmıştır. Gri seviyeye dönüşüm sonrası görüntülere görüntü işleme tekniklerinde biri olan histogram eşitleme işlemi yapılmış görüntülerdeki etkilerini incelemek için histogramı eşitlenmiş görüntülere de aynı işlemler ayrıca uygulanmıştır. Veri artırımı öncesi GLCM kullanarak özellik çıkarımı yapıldığındaki sınıflandırma sonuçları Çizelge 5.1'de gösterilmektedir. Veri artırımı öncesi histogramı eşitlenmiş görüntülerin GLCM ile özellikleri çıkarılıp sınıflandırma yapıldığındaki sonuçları Çizelge 5.2'de gösterilmektedir. Veri artırımı öncesi gri seviye görüntülere GLCM sonrası PCA uygulayıp sınıflandırma yapıldığındaki sonuçlar Çizelge 5.3'te gösterilmektedir. Veri artırımı öncesi gri seviyeye dönüşüm sonrası histogramı eşitlenmiş görüntülere GLCM ve PCA uygulaması sonrası sınıflandırma sonuçları Çizelge 5.4'te gösterilmektedir. Çalışmada makine öğrenmesi algoritmaları varsayılan

değerlerinde bırakılmıştır. KNN algoritmasında n_neighbors parametresi 5'tir ve metrics parametresi Minkowski'dir. Bu parametre varsayılan değerinde bırakılmıştır.

Çizelge 5.1. Veri arttırım öncesi GLCM kullanarak sınıflandırma sonuçları

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.74	[[22 4] [9 16]]	0.61	[[21 5] [15 10]]	0.78	[[21 5] [6 19]]	0.67	[[23 3] [14 11]]
FL ve MCL	0.70	[[22 5] [11 15]]	0.74	[[23 4] [10 16]]	0.66	[[22 5] [13 13]]	0.60	[[16 11] [10 16]]
MCL ve CLL	0.66	[[17 5] [11 14]]	0.53	[[15 7] [15 10]]	0.57	[[10 12] [8 17]]	0.62	[[17 5] [13 12]]
CLL, FL ve MCL	0.56	[[12 4 9] [2 19 7] [3 8 11]]	0.39	[[8 8 9] [7 16 5] [8 9 5]]	0.43	[[13 6 6] [8 17 3] [10 10 2]]	0.40	[[9 4 12] [7 14 7] [6 9 7]]

Çizelge 5.2. Veri arttırım öncesi histogramı eşitlenmiş görüntülere GLCM uygulanması sonrası sınıflandırma sonuçları

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.76	[[21 5] [7 18]]	0.73	[[22 4] [10 15]]	0.53	[[19 7] [17 8]]	0.72	[[23 3] [11 14]]
FL ve MCL	0.75	[[22 5] [8 18]]	0.58	[[20 7] [15 11]]	0.60	[[24 3] [18 8]]	0.60	[[19 8] [13 13]]
MCL ve CLL	0.57	[[16 6] [14 11]]	0.57	[[17 5] [15 10]]	0.62	[[8 14] [4 21]]	0.55	[[9 13] [8 17]]
CLL, FL ve MCL	0.53	[[9 6 10] [2 21 5] [4 8 10]]	0.36	[[8 8 9] [6 16 6] [11 8 3]]	0.39	[[8 10 7] [4 17 7] [7 11 4]]	0.53	[[11 6 8] [5 19 4] [5 7 10]]

Çizelge 5.3. Veri artırım öncesi GLCM ve PCA kullanarak sınıflandırma sonuçları

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.86	[[25 1] [6 19]]	0.61	[[21 5] [15 10]]	0.78	[[17 9] [2 23]]	0.75	[[21 5] [8 17]]
FL ve MCL	0.75	[[23 4] [9 17]]	0.74	[[23 4] [10 16]]	0.64	[[16 11] [8 18]]	0.58	[[20 7] [15 11]]
MCL ve CLL	0.72	[[17 5] [8 17]]	0.53	[[15 7] [15 10]]	0.57	[[13 9] [11 14]]	0.49	[[14 8] [16 9]]
CLL, FL ve MCL	0.55	[[11 4 10] [2 21 5] [6 7 9]]	0.39	[[8 8 9] [7 16 5] [8 9 5]]	0.56	[[17 3 5] [5 17 6] [9 5 8]]	0.47	[[11 3 11] [7 14 7] [8 4 10]]

Çizelge 5.4. Veri artırım öncesi histogramı eşitlenmiş görüntülere GLCM ve PCA uygulaması sonrası sınıflandırma sonuçları

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.80	[[24 2] [8 17]]	0.73	[[22 4] [10 15]]	0.69	[[18 8] [8 17]]	0.73	[[22 4] [10 15]]
FL ve MCL	0.81	[[25 2] [8 18]]	0.59	[[20 7] [15 11]]	0.72	[[18 9] [6 20]]	0.59	[[20 7] [15 11]]
MCL ve CLL	0.66	[[17 5] [11 14]]	0.57	[[17 5] [15 10]]	0.51	[[15 7] [16 9]]	0.66	[[16 6] [10 15]]
CLL, FL ve MCL	0.51	[[7 8 10] [2 23 3] [7 7 8]]	0.36	[[8 8 9] [6 16 6] [11 8 3]]	0.45	[[10 2 13] [3 14 11] [7 5 10]]	0.48	[[11 7 7] [11 14 3] [3 8 11]]

İlk yaklaşımın veri artırım sonrası gri seviye görüntülere GLCM sonrası sınıflandırma sonuçları Çizelge 5.5'te gösterilmektedir. Veri artırım sonrası gri seviyeye dönüşüm sonrası histogramı eşitlenmiş görüntülere GLCM uygulaması sonrası sınıflandırma sonuçları Çizelge 5.6'da verilmektedir. Veri artırım sonrası gri seviye görüntülere GLCM ve ardından PCA uygulaması sonrası sınıflandırma sonuçları Çizelge 5.7'de verilmektedir. Veri artırım sonrası histogramı eşitlenmiş gri seviye görüntülere GLCM ve ardından PCA uygulaması sonrası sınıflandırma sonuçları Çizelge 5.8'de verilmektedir.

Çizelge 5.5. Veri artırım sonrası GLCM uygulayıp sınıflandırma yapıldığındaki sonuçlar

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.87	[[98 13] [13 78]]	0.72	[[84 27] [30 61]]	0.71	[[72 39] [19 72]]	0.82	[[92 19] [17 74]]
FL ve MCL	0.89	[[101 13] [10 85]]	0.66	[[74 40] [30 65]]	0.64	[[67 47] [29 66]]	0.88	[[100 14] [10 85]]
MCL ve CLL	0.87	[[87 8] [15 78]]	0.61	[[56 39] [34 59]]	0.58	[[41 54] [25 68]]	0.81	[[80 15] [21 72]]
CLL, FL ve MCL	0.82	[[72 8 12] [6 97 7] [10 11 77]]	0.49	[[44 24 24] [30 63 17] [42 17 39]]	0.48	[[62 20 10] [34 70 6] [51 34 13]]	0.77	[[66 12 14] [8 91 11] [14 11 73]]

Çizelge 5.6. Veri artırım sonrası histogramı eşitlenmiş görüntülere GLCM uygulaması sonrası sınıflandırma sonuçları

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.86	[[91 15] [13 83]]	0.70	[[82 24] [36 60]]	0.57	[[87 19] [67 29]]	0.83	[[95 11] [24 72]]
FL ve MCL	0.88	[[109 14] [10 76]]	0.76	[[100 23] [27 59]]	0.60	[[100 23] [60 26]]	0.85	[[106 17] [15 71]]
MCL ve CLL	0.80	[[74 24] [14 76]]	0.62	[[66 32] [40 50]]	0.51	[[24 74] [19 71]]	0.74	[[75 23] [26 64]]
CLL, FL ve MCL	0.72	[[55 11 13] [15 86 5] [26 14 75]]	0.49	[[47 17 15] [26 70 10] [51 34 30]]	0.40	[[3 57 19] [6 83 17] [4 77 34]]	0.70	[[57 3 19] [18 73 15] [22 13 80]]

Çizelge 5.7. Veri artırım sonrası GLCM ve PCA uygulayıp sınıflandırma yapıldığındaki sonuçlar

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.89	[[101 11] [12 78]]	0.69	[[82 30] [33 57]]	0.68	[[64 48] [16 74]]	0.81	[[101 11] [28 62]]
FL ve MCL	0.88	[[93 9] [15 92]]	0.72	[[70 32] [26 81]]	0.64	[[50 52] [22 85]]	0.86	[[89 13] [16 91]]
MCL ve CLL	0.84	[[78 15] [14 81]]	0.62	[[63 30] [42 53]]	0.59	[[63 30] [46 49]]	0.76	[[71 22] [22 73]]
CLL, FL ve MCL	0.81	[[82 9 6] [5 89 10] [14 12 73]]	0.55	[[55 19 23] [23 66 15] [27 27 45]]	0.47	[[29 12 56] [23 45 36] [16 15 68]]	0.67	[[61 13 23] [10 80 14] [22 16 61]]

Çizelge 5.8. Veri artırım sonrası histogramı eşitlenmiş görüntüleri GLCM ve PCA uygulayıp sınıflandırma yapıldığındaki sonuçlar

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.89	[[99 7] [16 80]]	0.68	[[83 23] [42 54]]	0.61	[[55 51] [28 68]]	0.83	[[92 14] [21 75]]
FL ve MCL	0.84	[[90 12] [21 86]]	0.65	[[72 30] [42 65]]	0.64	[[55 47] [28 79]]	0.83	[[83 19] [16 91]]
MCL ve CLL	0.85	[[87 6] [23 72]]	0.57	[[64 29] [52 43]]	0.62	[[75 18] [53 42]]	0.76	[[73 20] [25 70]]
CLL, FL ve MCL	0.72	[[67 13 17] [14 84 6] [17 16 66]]	0.53	[[55 24 18] [32 61 11] [31 25 43]]	0.47	[[18 23 56] [14 44 46] [7 13 79]]	0.63	[[61 16 20] [15 74 15] [24 20 55]]

Çalışmadaki ikinci yaklaşım, RGB formatındaki görüntülerin VGG16 modeli kullanarak transfer öğrenme metoduyla özellik çıkarılması ve PCA ile özellik seçimi yapılması sonrası makine öğrenmesi algoritmalarıyla sınıflandırılmasıdır. Bu yaklaşım, veri artırım öncesi ve sonrasında da ayrı ayrı uygulanmıştır. PCA'ya 0.4 ve 0.5 değerleri verilerek PCA'nın varsayılan değeriyle sınıflandırmaya etkilerini gözlemlemek için deneysel çalışmalar yapılmıştır. Veri artırım öncesi VGG16 ile özellik çıkarıp PCA'ya parametre gönderilmediğindeki sınıflandırma sonuçları Çizelge 5.9'da gösterilmektedir. Veri artırım öncesi VGG16 ile özellik çıkarıp PCA'ya sırasıyla 0,4 ve 0,5 parametreleri gönderildiğindeki sınıflandırma sonuçları sırasıyla Çizelge 5.10 ve Çizelge 5.11'de gösterilmektedir. Tekrar tekrar bu yöntemle program çalıştırıldığında varsayılan değerle aynı doğruluk değerlerinin elde

edildiği görüldü. Veri artırım sonrası VGG16 ile özellik çıkarılıp ardından PCA uygulandığında ki sınıflandırma sonuçları Çizelge 5.12’de gösterilmektedir. Çalışmada ele alınan birinci ve ikinci yaklaşımın birlikte bulunduğu akış şeması Şekil 5.10’da verilmektedir. Şekil 5.10’da orijinal görüntü yazan kısım, orijinal görüntüleri ve döndürülme sonucu veri artırım yapılmış görüntüleri kapsamaktadır.

Çizelge 5.9. Veri artırım öncesi VGG16 ve PCA() uygulandıktan sonraki sınıflandırma sonuçları

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.74	[[23 3] [10 15]]	0.921	[[24 2] [2 23]]	0.60	[[14 12] [8 17]]	0.705	[[22 4] [11 14]]
FL ve MCL	0.73	[[26 1] [13 13]]	0.773	[[19 8] [4 22]]	0.75	[[18 9] [4 22]]	0.716	[[23 4] [11 15]]
MCL ve CLL	0.659	[[15 7] [9 16]]	0.7446	[[16 6] [6 19]]	0.76	[[18 4] [7 18]]	0.7446	[[13 9] [3 22]]
CLL, FL ve MCL	0.546	[[12 1 12] [2 20 6] [4 9 9]]	0.52	[[17 2 6] [8 18 2] [10 8 4]]	0.533	[[22 2 1] [9 15 4] [14 5 3]]	0.466	[[6 3 16] [3 18 7] [6 5 11]]

Çizelge 5.10. Veri artırım öncesi VGG16 ve PCA(0,5) uygulandıktan sonraki sınıflandırma sonuçları

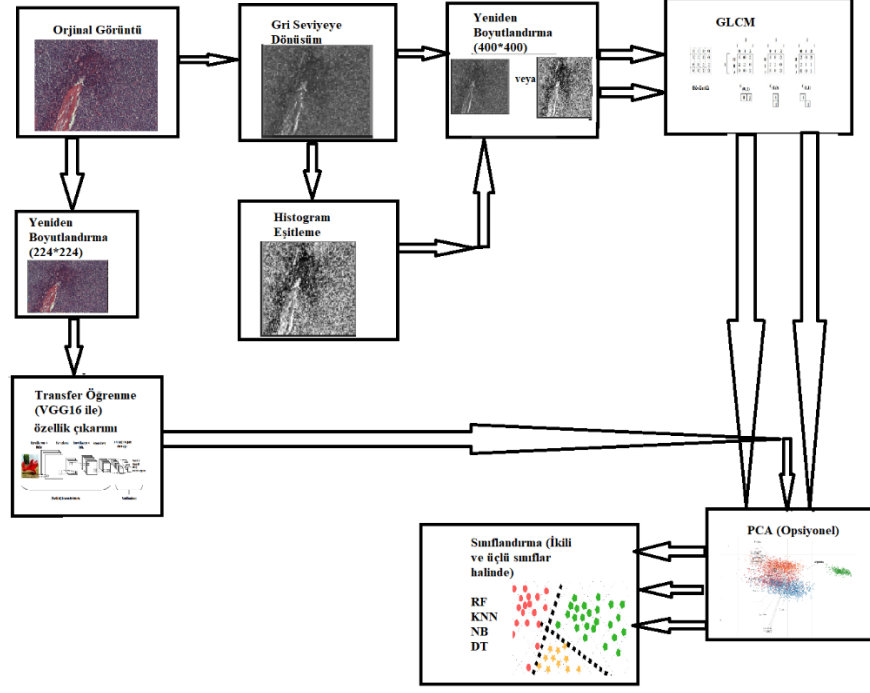
Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.78	[[24 2] [9 16]]	0.88	[[25 1] [5 20]]	0.66	[[12 14] [3 22]]	0.72	[[21 5] [9 16]]
FL ve MCL	0.77	[[23 4] [8 18]]	0.88	[[24 3] [3 23]]	0.62	[[8 19] [1 25]]	0.622	[[19 8] [12 14]]
MCL ve CLL	0.65	[[16 6] [10 15]]	0.78	[[17 5] [5 20]]	0.72	[[16 6] [7 18]]	0.744	[[16 6] [6 19]]
CLL, FL ve MCL	0.53	[[9 7 11] [2 14 8] [3 4 17]]	0.64	[[16 7 4] [6 16 2] [3 5 16]]	0.53	[[19 6 2] [9 13 2] [10 6 8]]	0.49	[[10 8 9] [5 12 7] [4 5 15]]

Çizelge 5.11. Veri artırım öncesi VGG16 ve PCA(0,4) uygulandıktan sonraki sınıflandırma sonuçları

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.82	[[25 1] [8 17]]	0.88	[[25 1] [5 20]]	0.76	[[20 6] [6 19]]	0.78	[[24 2] [9 16]]
FL ve MCL	0.81	[[24 3] [7 19]]	0.92	[[25 2] [2 24]]	0.679	[[10 17] [0 26]]	0.58	[[22 5] [17 9]]
MCL ve CLL	0.82	[[18 4] [4 21]]	0.82	[[18 4] [4 21]]	0.70	[[17 5] [9 16]]	0.80	[[19 3] [6 19]]
CLL, FL ve MCL	0.68	[[16 4 5] [0 23 5] [2 8 12]]	0.68	[[16 3 6] [1 23 4] [5 5 12]]	0.58	[[14 2 9] [2 15 11] [3 4 15]]	0.62	[[16 4 5] [2 21 5] [3 9 10]]


Çizelge 5.12. Veri artırım sonrası VGG16 ve PCA() uygulandıktan sonraki sınıflandırma sonuçları

Sınıflar	RF		KNN		NB		DT	
	Acc	CM	Acc	CM	Acc	CM	Acc	CM
FL ve CLL	0.83	[[104 8] [26 64]]	0.88	[[95 17] [7 83]]	0.52	[[16 96] [1 89]]	0.80	[[92 20] [21 69]]
FL ve MCL	0.66	[[98 9] [61 41]]	0.76	[[79 28] [22 80]]	0.65	[[43 64] [8 94]]	0.62	[[81 26] [53 49]]
MCL ve CLL	0.63	[[60 35] [35 58]]	0.68	[[48 47] [13 80]]	0.62	[[26 69] [2 91]]	0.61	[[57 38] [36 57]]
CLL, FL ve MCL	0.51	[[53 22 16] [12 71 23] [31 44 28]]	0.63	[[75 7 9] [28 72 6] [43 19 41]]	0.37	[[86 0 5] [88 1 17] [79 0 24]]	0.44	[[36 22 33] [14 54 38] [29 32 42]]



Şekil 5. 10. Çalışmadaki birinci ve ikinci yaklaşımın birlikte bulunduğu akış şeması

Çalışmadaki son yaklaşım VGG16, ResNet50 ve DenseNet201 modellerinin tam bağlantılı katmanlarını çıkarıp kalan katmanlarda öğrenmeyi engelleyip son kısma yeni katmanlar ekleyerek eklenen katmanlarda öğrenmeyi sağlayıp sınıflandırma yapılmaktadır. Şekil 5.11’de çalışmadaki son yaklaşımın ilgili görsellerinin eklenmiş akış şeması bulunmaktadır. Modellerin son kısımları eğitilerek sınıflandırma yapılmıştır. Bu yaklaşımda modeller 20 epoch değerinde çalıştırılmıştır. Batch_size değeri 32 olarak ayarlanmıştır. Bu modellere bütün görüntüler girdi olarak verilmeden önce 224x224 boyutlarında yeniden şekillendirildi. Veri artırım öncesi VGG16 uygulaması sonrası sınıflandırma sonuçları Çizelge 5.13’te verilmektedir. Veri artırım sonrası VGG16 uygulayarak sınıflandırma sonuçları Çizelge 5.14’te gösterilmektedir. Veri artırım öncesi DenseNet201 uygulaması sonrası sınıflandırma sonuçları Çizelge 5.15’te verilmektedir. Veri artırım sonrası DenseNet201 uygulayarak sınıflandırma sonuçları Çizelge 5.16’da gösterilmektedir. Veri artırım öncesi ResNet50 uygulaması sonrası sınıflandırma sonuçları Çizelge 5.17’de verilmektedir. Veri artırım sonrası ResNet50 uygulayarak sınıflandırma sonuçları Çizelge 5.18’de gösterilmektedir.



Şekil 5. 11. Çalışmadaki son yaklaşımın görselleri eklenmiş akış şeması

Çizelge 5.13. Veri artırım öncesi VGG16 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar

Sınıflar	Acc	CM	Sınıf	Precision	Recall	F1 Score	Kayıp Değeri
CLL ve FL	0.94	[[18 1] [2 30]]	CLL	0.90	0.95	0.92	0.28
			FL	0.97	0.94	0.95	
FL ve MCL	0.75	[[23 5] [8 17]]	FL	0.74	0.82	0.78	0.74
			MCL	0.77	0.68	0.72	
MCL ve CLL	0.64	[[15 4] [13 15]]	MCL	0.54	0.79	0.64	1.07
			CLL	0.79	0.54	0.64	
CLL, FL ve MCL	0.67	[[14 8 5] [2 21 5] [1 4 15]]	CLL	0.82	0.52	0.64	1.01
			FL	0.64	0.75	0.69	
			MCL	0.60	0.75	0.67	

Çizelge 5.14. Veri artırım sonrası VGG16 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar

Sınıflar	Acc	CM	Sınıf	Precision	Recall	F1 Score	Kayıp Değeri
FL ve CLL	0.87	[[73 11] [16 102]]	FLL	0.82	0.87	0.84	0.36
			CLL	0.90	0.86	0.88	
FL ve MCL	0.76	[[86 16] [33 74]]	FL	0.72	0.84	0.78	0.67
			MCL	0.82	0.69	0.75	
MCL ve CLL	0.76	[[65 28] [16 79]]	MCL	0.80	0.70	0.75	0.65
			CLL	0.74	0.83	0.78	
CLL, FL ve MCL	0.66	[[42 13 42] [1 83 20] [3 24 72]]	CLL	0.91	0.43	0.59	0.95
			FL	0.69	0.80	0.74	
			MCL	0.54	0.73	0.62	

Çizelge 5.15. Veri artırım öncesi DenseNet201 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar

Sınıflar	Acc	CM	Sınıf	Precision	Recall	F1 Score	Kayıp Değeri
FL ve CLL	0.80	[[12 7] [3 29]]	FLL	0.80	0.63	0.71	0.44
			CLL	0.81	0.91	0.85	
FL ve MCL	0.77	[[24 4] [8 17]]	FL	0.75	0.86	0.80	0.32
			MCL	0.81	0.68	0.74	
MCL ve CLL	0.70	[[15 4] [13 15]]	MCL	0.61	0.74	0.67	0.58
			CLL	0.79	0.68	0.73	
CLL, FL ve MCL	0.64	[[16 6 5] [0 22 6] [6 4 10]]	CLL	0.73	0.59	0.65	0.76
			FL	0.69	0.79	0.73	
			MCL	0.48	0.50	0.49	

Çizelge 5.16. Veri artırım sonrası DenseNet201 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar

Sınıflar	Acc	CM	Sınıf	Precision	Recall	F1 Score	Kayıp Değeri
FL ve CLL	0.94	[[74 10] [2 116]]	FL	0.97	0.88	0.93	0.23
			CLL	0.92	0.98	0.95	
FL ve MCL	0.84	[[82 20] [14 93]]	FL	0.85	0.80	0.83	0.41
			MCL	0.82	0.87	0.85	
MCL ve CLL	0.79	[[79 14] [26 69]]	MCL	0.75	0.85	0.80	0.46
			CLL	0.83	0.73	0.78	
CLL, FL ve MCL	0.77	[[77 6 14] [3 90 11] [17 19 63]]	CLL	0.79	0.79	0.79	0.58
			FL	0.78	0.87	0.82	
			MCL	0.72	0.64	0.67	

Çizelge 5.17. Veri artırım öncesi ResNet50 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar

Sınıflar	Acc	CM	Sınıf	Precision	Recall	F1 Score	Kayıp Değeri
CLL ve FL	0.82	[[13 6] [3 29]]	CLL	0.81	0.68	0.74	0.52
			FL	0.83	0.91	0.87	
FL ve MCL	0.70	[[23 5] [11 14]]	FL	0.68	0.82	0.74	0.60
			MCL	0.74	0.56	0.64	
MCL ve CLL	0.55	[[14 5] [16 12]]	MCL	0.47	0.74	0.57	0.75
			CLL	0.71	0.43	0.53	
CLL, FL ve MCL	0.44	[[1 6 20] [0 18 10] [0 6 14]]	CLL	1.00	0.04	0.007	1.48
			FL	0.60	0.64	0.62	
			MCL	0.32	0.70	0.44	

Çizelge 5.18. Veri artırım sonrası ResNet50 ile transfer öğrenme uygulayıp sınıflandırma yapıldığındaki sonuçlar

Sınıflar	Acc	CM	Sınıf	Precision	Recall	F1 Score	Kayıp Değeri
CLL ve FL	0.78	[[47 37] [8 110]]	CLL	0.85	0.56	0.68	0.60
			FL	0.75	0.93	0.83	
FL ve MCL	0.57	[[101 1] [88 19]]	FL	0.53	0.99	0.69	1.01
			MCL	0.95	0.18	0.30	
MCL ve CLL	0.56	[[90 3] [80 15]]	MCL	0.53	0.97	0.68	0.84
			CLL	0.83	0.16	0.27	
CLL, FL ve MCL	0.48	[[89 8 0] [48 56 0] [79 20 0]]	CLL	0.41	0.92	0.57	1.96
			FL	0.67	0.54	0.60	
			MCL	0.00	0.00	0.00	

Çalışmamızın literatürdeki benzer çalışmaların sonuçlarıyla karşılaştırıldığında başarılı sonuçlar elde edildiği görülür. Çizelge 5.19'da çalışmamızın literatürdeki benzer çalışmalarla kıyaslanması verilmiştir. Veri setlerindeki görüntü sayıları da dikkate alınıp doğruluk değerleri incelendiğinde ikili ve üçlü sınıflandırmalarda çalışmamızın iyi performans gösterdiği çıkarımı yapılabilir. Üçlü sınıflandırma yaparken literatürdeki diğer yöntemler baz alınarak yöntemler geliştirilerek daha iyi sonuçlar elde edilebilir.

Çizelge 5.19. Çalışmamızın literatürdeki benzer çalışmalarla kıyaslanması

Çalışmayı Yapanlar	Veri Seti İçerisindeki Sınıflar	Veri Setindeki Görüntü Sayısı	Kullanılan Yöntem	Acc	Sınıflar	Precision	Recall	F1-Score
Varol ve İşeri (Varol & İşeri, 2019)	CLL, FL ve MCL	135	Renk yoğunluğu, piksel yoğunluğu ve entropi değerlerine göre RF ile sınıflandırma	0.90	CLL	0.88	0.88	0.88
					FL	0.85	0.94	0.89
					MCL	0.82	0.74	0.78
Boussaid ve diğ. (Boussaid, Sertel, Lozanski, Shana'aah, & Gürcan, 2009)	CB olan ve olmayan (FL)	436	PCA ile özellik çıkarımı yapıp QDA ile sınıflandırma	0.83	CB olan	-	-	-
					CB olmayan	-	-	-
Orlov ve diğ. (Orlov, et al., 2010)	MCL ve CLL	171	CHARM sonrası WND ile sınıflandırma	0.86	MCL	-	-	-
					CLL	-	-	-
Ribeiro ve diğ. (Ribeiro, et al., 2018)	CLL, FL ve MCL	173	Renk normalizasyonu sonrası RF ile sınıflandırma	0.87	CLL	-	-	-
					FL	-	-	-
					MCL	-	-	-
Jiang ve diğ. (Jiang, Li, Li, & Zhou, 2018)	CLL, FL ve MCL	48620	Özellik çıkarımı için SAE, LPQ ve GLCM; sınıflandırma için ELM ve SVM	0.98	CLL	-	-	-
					FL	-	-	-
					MCL	-	-	-
Bizim çalışmamız	CLL ve FL	1008	Transfer öğrenme (DenseNet201)	0.94	FL	0.97	0.88	0.93
					CLL	0.92	0.98	0.95
Bizim çalışmamız	CLL, FL ve MCL	1496	GLCM uygulaması sonrası RF ile sınıflandırma	0.82	CLL	0.82	0.78	0.8
					FL	0.84	0.88	0.86
					MCL	0.8	0.76	0.78

6. SONUÇ VE ÖNERİLER

Bu çalışmada sınıflandırma, özellik çıkarım ve özellik seçim metodlarının sınıflandırmadaki etkileri karşılaştırılmıştır. Aynı zamanda bu metodların veri artırım öncesi ve sonrası performansları da incelenmiştir. Sonuçlar incelendiğinde veri artırım öncesi gri seviye görüntülerde ikili sınıflandırmada GLCM sonrası PCA uygulanan verilerin sınıflandırmasında RF algoritması FL ve CLL için % 86 ve üçlü sınıflandırmada NB algoritması %56 doğruluk değeriyle en başarılı sonuçlar elde edilmiştir. Veri artırım sonrası gri seviye görüntülerde ikili sınıflandırmada sadece GLCM uygulanan görüntülerde FL ve MCL, GLCM sonrası PCA uygulaması ve histogramı eşitlenmiş görüntülere GLCM ve PCA uygulaması sonrası FL ve CLL %89 doğruluk oranıyla RF algoritmasıyla sınıflandırıldığında en başarılı sonuçlar elde edilir. Üçlü sınıflandırmada ise sadece GLCM uygulanmış görüntüler RF algoritmasıyla sınıflandırıldığında %82 doğruluk oranıyla veri artırım sonrası gri seviye görüntülerde üçlü sınıflandırmada en iyi sonuçları vermiştir. Genel olarak gri seviye görüntülerin analizinde histogram eşitlenmiş görüntüler eşitlenmemiş görüntülere göre daha az başarılı olmuştur. GLCM uygulaması sonrası PCA uygulamasının sınıflandırmadaki etkilerinin hissedilir düzeyde olmadığı görüldü. FL ve CLL'nin sınıflandırılmasının diğer sınıflandırma sonuçlarıyla kıyaslandığında daha başarılı olduğu ve çoğunlukla bu başarıyı RF algoritmasıyla elde ettiği görülmüştür.

Veri artırım öncesi VGG16 modeliyle transfer öğrenme uygulayarak özellik çıkarımı yapıp PCA ile özellik seçimi sonrası ikili sınıflandırmada PCA'nın n_component parametresi 0,4 verildiğinde FL ve MCL, varsayılan değerde bırakıldığında ise FL ve CLL %92 doğrulukla KNN algoritması en iyi ikili sınıflandırmayı yapmıştır. Üçlü sınıflandırmada, PCA'nın n_component parametresi 0,4 verildiğinde KNN ve RF algoritmaları aynı performansları göstermiş olup doğruluk değerleri %68'dir. Veri artırım sonrası aynı yöntemde PCA n_component parametresine değer verilmeyerek ölçümler yapılmıştır. Varsayılan değerde kaldığında ve değer verildiğindeki sınıflandırma sonuçları incelendiğinde büyük bir fark görülmemiştir. Bu yüzden böyle yapılmıştır. Veri artırım sonrası ikili sınıflandırmada FL ve CLL'yi %88 ve üçlü sınıflandırmada %63 doğrulukla sınıflandıran KNN algoritması en iyi sonuçları vermiştir. Veri artırım öncesi ikili ve üçlü sınıflandırmalarda daha yüksek doğruluklar elde edildiği görülmüştür.

Veri artırım öncesi seçilen derin öğrenme mimarilerin tam bağlantılı katmanları çıkarılıp geri kalan katmanların öğrenmesi engellenip sınıflandırıcı katman eklenmiş modelde

ikili sınıflandırma sonuçları incelendiğinde çalışmada kullanılan bütün modellerin FL ve CLL'yi en iyi şekilde sınıflandırdığı görülmüştür. VGG16 ile %94, DenseNet201 ile %80 ve ResNet50 ile %82 doğruluk elde edilmiştir. Üçlü sınıflandırmada %67 doğruluk oranıyla VGG16 en başarılı olmuştur. DenseNet201 modelinde %64 doğruluk elde edilirken ResNet50 modelinde %44 doğruluk değeri elde edilmiştir. Veri artırımı sonrası ise ikili sınıflandırmada en iyi sonucu FL ve CLL'yi %94 doğrulukla sınıflandırarak DenseNet201 göstermiştir. VGG16 %87 ve ResNet50 %78 doğrulukla ikili sınıflandırmada en iyi sonuçlarını FL ve CLL'yi sınıflandırarak göstermişlerdir. Veri artırımı sonrası üçlü sınıflandırmada %77 doğrulukla DenseNet201 en iyi sonucu vermiştir.

Çalışmada ikili sınıflandırmalarda FL ve CLL sınıflandırma sonuçlarının en başarılı olduğu görülmektedir. Gri seviye görüntülerde RF algoritması ikili ve üçlü sınıflandırmalarda en iyi sonuçları göstermiştir. Çalışmada elde edilen yüksek doğruluk oranı veri artırımı sonrası DenseNet201 modeliyle FL ve CLL'nin sınıflandırmasında %94 doğrulukla elde edilmiştir. Çalışmada genel olarak FL ve CLL'nin sınıflandırılması yapılmıştır. En düşük doğruluk değerleri ikili sınıflandırmalarda MCL ve CLL'de görülmüştür. Bu da MCL ve CLL'nin özelliklerinin birbirine benzer olduğundan dolayı sınıflandırılmasının zor olduğunu ve dolayısıyla sınıflandırma metodlarının düşük doğrulukta sonuçlar vermesine sebep olmuştur. FL, diğer iki hastalıktan özellik olarak daha farklı olduğu için ikili sınıflandırmalarda FL ile sınıflandırma yapıldığında en iyi sonuçlar elde edilmiştir.

Bu çalışmanın ileriki dönemlerde farklı veri artırımı metotlarıyla, parametrelerle ve derin öğrenme mimarileriyle deneysel çalışmalarının yapılıp literatüre katkı sağlanacağı öngörülmektedir

KAYNAKLAR

- About. (t.y.). Retrieved from OpenCV: <https://opencv.org/about/>)
- About lymphoma and lymphoma subtypes. (t.y.). Retrieved from Lymphoma: <https://lymphoma.org/understanding-lymphoma/aboutlymphoma/>
- Acıbadem Web ve Yayın Kurulu. (2022). *Lenf kanseri*. Acıbadem: <https://www.acibadem.com.tr/ilgi-alani/lenf-kanseri-lenfoma/#tedavi-yontemleri> adresinden alındı
- Ağca, K., & Takcı, H. (2022). Hibrit bir model oluşturarak diyabetik retinopati sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, 227-236.
- Akademi 4.0 Ekibi. (2020, Mart 24). *İnsan öğrenmesi ve makine öğrenimi*. Akademi 4.0: <https://akademi40.org/insan-ogrenmesi-ve-makine-ogrenimi/> adresinden alındı
- Akar, Ö., & Güngör, O. (2021). Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*.
- Akay, N., Şimşek, G., Yalçın, S., İnal, M., Balcı, M., & Onaran, Z. (2018). Maksiller sinüsün mantle hücreli lenfoması: olgu sunumu. *Turkish Journal of Clinics and Laboratory*, 250-253.
- Akyiğit, H. E., & Taşçı, T. (2022). Sigortacılık sektöründe makine öğrenmesi ile müşteri kaybı analizi. *Tasarım Mimarlık ve Mühendislik Dergisi*, 66-79.
- Altaş, D., & Gülpınar, V. (2012). Karar ağaçları ve yapay sinir ağlarının sınıflandırma performanslarının karşılaştırılması: Avrupa Birliği örneği. *Trakya Üniversitesi Sosyal Bilimler Dergisi*, 1-22.
- Ansell, S. (2022). *Lymphoma*. Mayo Clinic: <https://www.mayoclinic.org/diseases-conditions/lymphoma/symptoms-causes/syc-20352638#:~:text=Lymphoma%20is%20a%20cancer%20of,other%20organs%20throughout%20the%20body.>) adresinden alındı
- Arts, L., Poll, L., Berg, S. V., Prins, J. B., Husson, O., Mols, F., . . . Oerlemans, S. (2017). Lymphoma InterVention (LIVE) - patient-reported outcome feedback and a web-based self-management intervention for patients with lymphoma: study protocol for a randomised controlled trial. *BioMed Central*.
- Ayık, Y. Z., Özdemir, A., & Yavuz, U. (2010). Lise türü ve lise mezuniyet başarısının, kazanılan fakülte ile ilişkisinin veri madenciliği tekniği ile analizi. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 441-454. Dergipark: <https://dergipark.org.tr/tr/download/article-file/32076> adresinden alındı
- Aylak, B. L., Oral, O., & Yazıcı, K. (2021). Yapay zeka ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımı. *El-Cezerî Fen ve Mühendislik Dergisi*, 74-93.
- Balaban, M. E., & Kartal, E. (2018). *Veri madenciliği ve makine öğrenmesi*. İstanbul: Çağlayan Yayınları.
- Battula, P., & Sharma, S. (2018). Automatic classification of Non Hodgkin's lymphoma using histological images: recent advances and directions. *2018 International Conference on Advances in Computing, Communication Control and Networking (ICACCCN)*.

- Berg, M., Holroyd, N., Walsh, C., West, H., Samuel, S. W., & Shipley, R. (2022). Challenges and opportunities of integrating imaging and mathematical modelling to interrogate biological processes. *The International Journal of Biochemistry & Cell Biology*.
- Bhattacharjee, S., Park, H. G., Kim, C. H., Prakash, D., Madusanka, N., So, J. H., . . . Choi, H. K. (2019). Quantitative analysis of benign and malignant tumors in histopathology: predicting Prostate cancer grading using SVM. *Applied Sciences*.
- Bilen, B. (2021, Şubat 4). *Karışıklık matrisi (Confusion matrix)*. Medium: <https://burhanbilen.medium.com/kar%C4%B1%C5%9F%C4%B1kl%C4%B1k-matrisi-confusion-matrix-990dfc718653> adresinden alındı
- Bingöl, M. C. (2021). DDPG algoritmasında bulunan Ornstein–Uhlenbeck gürültüsünün standart sapmasının araştırılması. *Gazi Üniversitesi Fen Bilimleri Dergisi*, 200-210.
- Boussaid, K. B., Sertel, O., Lozanski, G., Shana'aah, A., & Gürcan, M. (2009). Extraction of color features in the spectral domain to recognize centroblasts in histopathology. *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*.
- Bozkurt, F. (2021). Classification of blood cells from blood cell images using dense convolutional network. *Journal of Scientific Technology and Engineering Research*, 81-88.
- Bozkurt, F., & Yağanoğlu, M. (2021). Derin evrişimli sinir ağları kullanarak akciğer X-Ray görüntülerinden COVID19 tespiti. *Veri Bilimi Dergisi*.
- Budak, H. (2018). Özellik seçimi yöntemleri ve yeni bir yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*.
- Ceran, M. (2022). Geldim, gördüm, resmettim: ışıkla resmetme terimleri. L. Kılıç içinde, *Işıkla Resmetme Teknikleri*. İnkılâp Kitabev.
- Colbert, S. C., & Varoquaux, G. (2011). The NumPy array: a structure for efficient numerical computation. *IEEE Xplore*.
- Cooper, L. A., Carter, A. B., Farris, A. B., Wang, F., Kong, J., Gutman, D. A., . . . Saltz, J. H. (2012). Digital pathology: data-intensive Frontier in medical imaging. *Proceedings of the IEEE*.
- Çavuşoğlu, Ü., & Kaçar, S. (2019). Anormal trafik tespiti için veri madenciliği algoritmalarının performans analizi. *Academic Platform Journal of Engineering and Science*, 205-216.
- Çelik, G., & Talu, M. F. (2020). Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi. *BAUN Fen Bilimleri Enstitüsü Dergisi*, 181-192.
- Çelik, Ö., & Altunaydın, S. S. (2018). A research on machine learning methods and its applications. *Journal of Educational Technology & Online Learning*.
- Çelik, R., & Çiçekli, S. (2022). Bir bakış açısı olarak sine-göz: Dziga Vertov'un kameralı adam filmi. *Gümüşhane Üniversitesi Sosyal Bilimler Dergisi*, 37-47.
- Çelik, S., & Kasım, Ö. (2021). Beyin manyetik rezonans görüntülerindeki tümörlü dilimlerin özellik mühendisliği ile optimize edilen transfer öğrenmesiyle tespiti. *Natural & Applied Sciences Journal*.

- Çeliker, E., Efendioğlu, G., & Balaban, Ö. (2020). Cycle-GAN ile modern iç mekânların bilim kurgu ortamları olarak yeniden üretilmesi. *Journal of Computational Design*, 71-94.
- Dağlı, İ., & Öztürk, A. (2021). Görüntü sınıflandırmada derin öğrenme yöntemlerinin karşılaştırılması. *Konya Mühendislik Bilimleri Dergisi*.
- Demiralay, M., & Çamurcu, A. Y. (2005). Cure, agnes ve K-Means algoritmalarındaki kümeleme yeteneklerinin karşılaştırılması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 1-18.
- Demirhan, A., & Güler, İ. (2010). Özörgütlemeli harita ağları ve gri düzey eş oluşum matrisleri ile görüntü bölütleme. *Gazi Üni. Mühendislik ve Mimarlık Fakültesi Dergisi*.
- Discover the main benefits of machine learning*. (t.y.). Retrieved from Iberdrola: <https://www.iberdrola.com/innovation/machine-learning-automatic-learning>
- Doğan, F., & Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *DÜMF Mühendislik Dergisi*.
- Donuk, K., & Hanbay, D. (2021). Sınıflandırma algoritmalarına dayalı VGG-11 ile yüzde duygu tanıma. *Journal of Computer Science*, 359-365.
- Durmuş, Ş., & Bayazıt, U. (2017). Plant species estimation from field images. *2017 25th Signal Processing and Communications Applications Conference (SIU)*, (pp. 1-4).
- Edizer, E. (2006). *Sayısal görüntü işleme yöntemi ile tane boyut dağılımı analizi (Yüksek Lisans Tezi)*. Adana: Çukurova Üniversitesi Fen Bilimleri Enstitüsü.
- Eichenauer, D. A., & Engert, A. (2017). Nodular lymphocyte-predominant Hodgkin lymphoma: a unique disease deserving unique management. *Hematology American Society Hematology Education Program*, 324-328.
- Ekberg, S., Smedby, K. E., Lindblad, A. A., Jerkeman, M., Weibull, C. E., & Glimelius, I. (2022). Late effects in mantle cell lymphoma patients treated with or without autologous stem cell transplantation. *Blood Advances*.
- Eker, A. G., & Duru, N. (2021). Medikal görüntü işlemede derin öğrenme uygulamaları. *Acta Infologica*.
- Er, O., & Temurtas, F. (2005). Human face recognition. *Electronic Letters on Science and Engineering*, 1-12.
- Eyüpoğlu, C., & Yavuz, E. (2020). Kanser teşhisi için makine öğrenmesi tekniklerine dayalı yeni bir sınıflandırma metodu. *BŞEÜ Fen Bilimleri Dergisi*.
- Fırıldak, K., & Talu, M. F. (2019). Evrimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi. *Anatolian Journal of Computer Science*, 88-95.
- Gonzales, R. C., & Woods, R. E. (2014). *Sayısal görüntü işleme*. Ankara: Palme Yayınevi.
- Gökgöz, Z., Gemici, A. İ., & Aydoğdu, İ. (2015). Nodüler lenfosit baskın Hodgkin lenfoma tedavisi. *Celal Bayar Üniversitesi Sağlık Bilimleri Enstitüsü Dergisi*, 8-10.
- Görüntü işleme nedir?* (2020, Temmuz 28). Odak Arge Merkezi: <https://www.odakarge.com/goruntu-isleme-nedir.html> adresinden alındı
- Gülperçin, N. (2015). Böceklerin gözünden Dünya. *BAÜ Fen Bilimleri Dergisi*, 53-58.

- Gültekin, T., Koyuncu, C. F., Sokmensuer, C., & Demir, Ç. G. (2015). Two-tier tissue decomposition for histopathological image representation and classification. *IEEE Transactions on Medical Imaging*.
- Güneş, A. K., & Çınarsoy, M. (2021). Erken evre klasik Hodgkin lenfoma vakalarında tedavi. *Muğla Sıtkı Koçman Üniversitesi Tıp Dergisi*, 172-178.
- Güvenç, U., & Karagül, T. (2009). Görüntülerin kenar haritalarının çıkarımına yeni bir yaklaşım. *Bilişim Teknolojileri Dergisi*.
- Güvenç, U., Elmas, Ç., & Demirci, R. (2008). Renkli görüntülerin otomatik ayrıştırılması. *Politeknik Dergisi*, 9-12.
- Hakim, F., & Farooq, A. (2022). Conjunctival chronic lymphocytic leukemia presenting as bilateral chronic conjunctivitis. *American Journal of Ophthalmology Case Reports*.
- Hansen, S. V., Nyvold, C. G., & Hansen, M. (2022). Mantle cell lymphoma and the evidence of an immature lymphoid component. *Leukemia Research*.
- Hao, Y., Qiao, S., Zhang, L., Xu, T., Bai, Y., Hu, H., . . . Zhang, G. (2021). Breast cancer histopathological images recognition based on low dimensional three-channel features. *Frontiers in Oncology*.
- Harrizi, M., Ibourk, A., & Yahya, I. B. (2022). Non-Hodgkin's lymphoma in the jaw: a report of 3 cases. *Advances in Oral and Maxillofacial Surgery*.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (pp. 770-778).
- Huang, G., Liu, Z., Maaten, L. V., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (pp. 2261-2269).
- İnik, Ö., & Turan, B. (2018). Classification of different age groups of people by using deep learning. *Journal of New Results in Science*, 9-16.
- İnik, Ö., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 85-104.
- Jiang, H., Li, Z., Li, S., & Zhou, F. (2018). An effective multi-classification method for NHL pathological images. *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, (pp. 763-768).
- Karakurt, F. (2018). *Evrışimli sinir ağlarında hiper parametrelerin etkisinin incelenmesi (Yüksek Lisans Tezi)*. Ankara: Hacettepe Üniversitesi Fen Bilimleri Enstitüsü.
- Karakurt, M., & İşeri, İ. (2021). Patoloji görüntülerinin derin öğrenme yöntemleri ile sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, 192-206.
- Kaseb, H., & Babiker, H. M. (2022). Hodgkin lymphoma. StatPearls Publishing.
- Kavzaoğlu, T., & Çölkesen, İ. (2010). Karar ağacı ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği. *Harita Teknolojileri Elektronik Dergisi*, 36-45.
- Keskener, M. F., & Keskener, E. F. (2017). Geçmişten günümüze yapay sinir ağları ve tarihçesi. *Takvim-i Vekayi*, 8-18.

- Kızılkaya, Y. M., & Oğuzlar, A. (2018). Bazı denetimli öğrenme algoritmalarının R programlama dili ile kıyaslanması. *Karadeniz Uluslararası Bilimsel Dergi*, 90-98.
- Kızrak, M. A., & Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*.
- Koç, M. M. (2021). A glimpse to the modern opticianry techniques. *Kırklareli University Journal of Engineering and Science*, 166-186.
- Kormaz, D., Çelik, H. E., & Kapar, M. (2018). Sınıflandırma ve regresyon ağaçları ile rastgele orman algoritması kullanarak Botnet tespiti: Van Yüzüncü Yıl Üniversitesi örneği. *Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 297-307.
- Kumrular, R. K., & Polat, A. (2021). Klinik uygulamalarda ileri biyomedikal görüntüleme teknolojileri. *Avrupa Bilim ve Teknoloji Dergisi*.
- Kuruca, Y., Üstüner, M., & Şimşek, I. (2022). Dijital pazarlamada yapay zekâ kullanımı: Sohbet robotu. *Medya ve Kültürel Çalışmalar ve Medya Dergisi*.
- Lee, T. G., & Par, J. (2022, Ekim 5). *Visual Studio IDE'ye hoş geldiniz*. Retrieved from Microsoft: <https://docs.microsoft.com/tr-tr/visualstudio/get-started/visual-studio-ide?view=vs-2022>
- Lenf dolaşımı nedir?* (2020). Fikir Gen: <https://www.fikir.gen.tr/lenf-dolasimi-nedir-nasil-olur-odem-nedir/> adresinden alındı
- Lymphoma*. (t.y.). Retrieved from American Society of Hematology: <https://www.hematology.org/education/patients/blood-cancers/lymphoma>
- Meghpara, M. K., Rhee, R. Y., Almadani, M., Henaghan, J. K., Huang, Y. J., & Sebastian, A. (2022). Contained abdominal aortic rupture secondary to follicular lymphoma invasion. *Journal of Vascular Surgery Cases, Innovations and Techniques*, 271-274.
- Mehta, N., Alomari, R. S., & Chaudhary, V. (2009). Content based sub-image retrieval system for high resolution pathology images using salient interest points. *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*.
- Memorial Tıbbi Yayın Kurulu. (2022). *Lenf kanseri, lenfoma belirtileri ve tedavisi*. Memorial: <https://www.memorial.com.tr/hastaliklar/lenfoma-belirtileri-ve-tedavisi> adresinden alındı
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill Science.
- Mohty, R., Dulery, R., Bazarbachi, A. H., Savani, M., Hamed, R. A., Bazarbachi, A., & Mohty, M. (2021). Latest advances in the management of classical Hodgkin lymphoma: the era of novel therapies. *Blood Cancer Journal*.
- Momotow, J., Borchmann, S., Eichenauer, D. A., Engert, A., & Sasse, S. (2021). Hodgkin lymphoma—review on pathogenesis, diagnosis, current and future treatment approaches for adult patients. *Journal of Clinical Medicine*.
- Nacar, E. N., & Erdebilli, B. (2021). Makine öğrenmesi algoritmaları ile satış tahmini. *Endüstri Mühendisliği Dergisi*.
- National Eye Institute. (2022, Nisan 20). *How the eyes work*. Retrieved from National Eye Institute: <https://www.nei.nih.gov/learn-about-eye-health/healthy-vision/how-eyes->

- Saplıoğlu, K., & Acar, R. (2020). K-Means kümeleme algoritması kullanılarak oluşturulan yapay zekâ modelleri ile sediment taşınımının tespiti. *BEÜ Fen Bilimleri Dergisi*.
- Sarker, I. H. (2021). Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*.
- Sathyamoorthy, D. (2013). Çoklu ölçekli sayısal yükseklik modellerinden çıkarılan fizyografik detaylara ait yüzey doku özelliklerinin gri düzey eş-oluşum matrisi ile analizi. *Jeodezi ve Jeoinformasyon Dergisi*, 56-69.
- Savaş, S. (2020, Mayıs 19). *Veri madenciliği süreci*. Medium: <https://medium.com/veri-madencili%C4%9Fi/veri-madencili%C4%9Fi-s%C3%BCreci-11243e7966fc> adresinden alındı
- Selvi, O. (2019). Göğüs kanseri teşhisinde farklı makine öğrenmesi tekniklerinin performans karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*.
- Sever, M. (2018, Ekim 8). *Sayısal görüntü işlemede kullanılan renk modelleri*. Elektrik Port: <https://www.elektrikport.com/universite/sayisal-goruntu-islemede-kullanilan-renk-modelleri/21711#ad-image-0> adresinden alındı
- Sezgin, M. G., & Bektaş, H. (2021). Lenfoma hastalarıyla yaşayan aile üyelerinin bakım verme. *H.Ü. Sağlık Bilimleri Fakültesi Dergisi*.
- Shanbhag, S., & Ambinder, R. (2018, March). Hodgkin lymphoma: a review and update on recent progress. *CA Cancer J Clin*.
- Sharadhi, A. K., Gururaj, V., Shankar, S. P., Supriya, M. S., & Chogule, N. S. (2022). Face mask recogniser using image processing and computer vision approach. *Global Transitions Proceedings*, 67-73.
- Shyni, H. M., & Chitra, E. (2022). A comparative study of X-ray and CT images in COVID-19 detection using image processing and deep learning techniques. *Computer Methods and Programs in Biomedicine Update*.
- Soyhan, İ., Gürel, S., & Tekin, S. A. (2021). Yapay zeka tabanlı görüntü işleme tekniklerinin insansız hava araçları üzerinde uygulamaları. *Avrupa Bilim ve Teknoloji Dergisi*, 469-473.
- Sugano, H., & Miyamoto, R. (2010). Highly optimized implementation of OpenCV for the cell broadband engine. *Computer Vision and Image Understanding*, 1273-1281.
- Suknuntha, K., Subramanian, K., Racchumi, J., & Tam, W. (2022). Merkel cell carcinoma and follicular lymphoma: a highly unusual collision tumor. *Human Pathology Reports*.
- Şeker, Ş. E. (2018). CRISP-DM: endüstriler arası standart işleme – veri madenciliği için. *YBS Ansiklopedi*.
- Şirin, S. (2020). Ratgele orman algoritmaları ile otel özellikleri analizi. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 123-132.
- Şişeci, M., & Cetişli, B. (2012). Traverten plaka taşlarda sınıfların k-ortalamlar ve bulanık c-ortalamlar kümeleme yöntemleri ile belirlenmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*.
- Tan, F. G., Yüksel, A. S., Aydemir, E., & Ersoy, M. (2021). Derin öğrenme teknikleri ile nesne tespiti ve takibi üzerine bir inceleme. *Avrupa Bilim ve Teknoloji Dergisi*.

- Tüfekçi, M., & Karpat, F. (2019). Derin öğrenme mimarilerinden konvolüsyonel Sinir Ağları (CNN) üzerinde görüntü işleme sınıflandırma kabiliyetinin artırılmasına yönelik yapılan çalışmaların incelenmesi. *International Congress on HumanComputer Interaction, Optimization and Robotic Applications*, 28-31.
- Ünal, A. (tarih yok). Hodgkin lenfoma. Türk Hematoloji Derneği.
- Üstündağ, M. (2015, Haziran 25). *Görme olayı nasıl gerçekleşir?* Fen Okulu: https://www.fenokulu.net/yeni/Fen-Konulari/Konu/Gorme-Olayi-Nasil-Gerceklesir_1589.html adresinden alındı
- Varol, A. B., & İşeri, İ. (2019). Lenf kanserine ilişkin patolojik görüntülerin makine öğrenimi yöntemleri ile sınıflandırılması. *Avrupa Bilim ve Teknoloji Makalesi*.
- Veranyurt, Ü., Deveci, A. F., Esen, M. F., & Veranyurt, O. (2020). Makine öğrenmesi teknikleriyle hastalık sınıflandırması: Random Forest, K-Nearest Neighbour ve Adaboost algoritmalarıyla uygulaması. *Uluslararası Sağlık Yönetimi ve Stratejileri Araştırma Dergisi*.
- Veta, M., Pluim, J. P., Diest, P. J., & Viergever, M. A. (2014). Breast cancer histopathology image analysis: a review. *IEEE Transactions on Biomedical Engineering*.
- Vuong, T. T., Song, B., Kim, K., Cho, Y. M., & Kwak, J. T. (2022). Multi-scale binary pattern encoding network for cancer classification in pathology images. *IEEE Journal of Biomedical and Health Informatics*.
- Wang, Y., Peng, T., Duan, J., Zhu, C., Liu, J., Ye, J., & Jin, M. (2020). Pathological image classification based on hard example guided CNN. *IEEE Access*.
- Watson, S., & Ratini, M. (2022, March 4). *What is lymphoma?* Retrieved from WebMD: <https://www.webmd.com/cancer/lymphoma/lymphoma-cancer>
- Wright, A. I., Dunn, C. M., Hale, M., Hutchins, G. G., & Treanor, D. E. (2021). The effect of quality control on accuracy of digital pathology image analysis. *IEEE Journal of Biomedical and Health Informatics*.
- Yakalı, G. (2017). Significance of ophthalmic optics in opticianry education at Turkey. *Usak University Journal of Science and Natural Sciences*, 7-14.
- Yalçın, E. C., & Şen, A. (2012). Süreç iyileştirme çalışmalarında veri madenciliği yaklaşımının kullanılması üzerine bir çalışma. *Muğla Sıtkı Koçman Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*.
- Yalman, Y., & Ertürk, İ. (2013). A new color image quality measure based on YUV transformation and PSNR for human vision system. *Turkish Journal of Electrical Engineering & Computer Sciences*, 603-612.
- Yaman, K., Sarucan, A., Atak, M., & Aktürk, N. (2001). Dinamik çizelgeleme için görüntü işleme ve arıtma modelleri yardımıyla veri hazırlama. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19-40.
- Yamashita, R., Long, J., Banda, S., Shen, J., & Rubin, D. L. (2021). Learning domain-agnostic visual representation for computational pathology using medically-irrelevant style transfer augmentation. *IEEE Transactions on Medical Imaging*.

- Yang, C. K., Lee, C. Y., Wang, H. S., Huang, S. C., Liang, P. I., Chen, J. S., . . . Chen, T. D. (2021). Glomerular disease classification and lesion identification by machine learning. *Biomedical Journal*.
- Yapay zeka nedir? (2020, Haziran 30). Soyleki: <https://soyleki.com/yapay-zeka-nedir-nasil-calisir-insan-gibi-dusunen-makine/> adresinden alındı
- Yıldırım, B., & Demirarslan, D. (2019). Gözün görme işlevi ve sanal iç mimari ürün. *Mimarlık ve Yaşam Dergisi*, 155-165.
- Yıldırım, E. (2020, Mayıs 2). *Yapay sinir ağı (artificial neural network) nedir?* Veri Bilimi: <https://www.veribilimiokulu.com/yapay-sinir-agiartificial-neural-network-nedir/> adresinden alındı
- Yıldız, M. Ş., Arkan, O., Erenoğlu, A. K., & Kekezoğlu, B. (2021). K-Means kümeleme yöntemi ile konutlarda kullanılan elektrikli cihazların güç tüketimi ve harmonik bileşenlerinden karakter analizi. *Fırat Üniversitesi Müh. Bil. Dergisi*, 1-9.
- Zhang, S., Chen, C., Chen, C., Chen, F., Li, M., Yang, B., . . . Lv, X. (2021). Research on application of classification model based on stack generalization in staging of cervical tissue pathological images. *IEEE Access*.
- Zhang, X., Liu, W., Dünder, M., Badve, S., & Zhang, S. (2015). Towards large-scale histopathological image analysis: hashing-based image retrieval. *IEEE Transactions on Medical Imaging*, 496-506.
- Zhang, Y., Xing, Z., Mi, L., Li, Z., Zhu, J., Wei, T., & Wu, W. (2022). Novel agents for relapsed and refractory classical Hodgkin lymphoma: a review. *Frontiers in Oncology*.
- Zorman, M., Kokol, P., Lenic, M., Rosa, J. L., Sigut, J. F., & Alayon, S. (2007). Symbol-based machine learning approach for supervised segmentation of follicular lymphoma images. *Twentieth IEEE International Symposium on Computer-Based Medical Systems (CBMS'07)*.