



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DERİN ÖĞRENME YAKLAŞIMI İLE MALARIA (SITMA) HASTALIĞI
GÖRÜNTÜLERİNİN SINIFLANDIRILMASI**

MOHANAD MOHAMMED QANBAR

YÜKSEK LİSANS TEZİ

Bilişim Teknolojileri Mühendisliği Anabilim Dalı

Aralık-2019
KONYA
Her Hakkı Saklı

TEZ KABUL VE ONAYI

Mohanad Mohammed QANBAR tarafından hazırlanan “Derin Öğrenme Yaklaşımı ile Malaria (Sıtma) Hastalığı Görüntülerinin Sınıflandırılması” adlı tez çalışması 30/12/2019 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilişim Teknolojileri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Doç. Dr. Mesut GÜNDÜZ

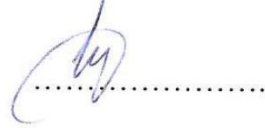
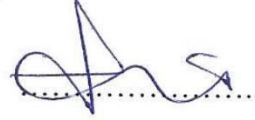
Danışman

Prof. Dr. Şakir TAŞDEMİR

Üye

Doç. Dr. Humar KAHRAMANLI ÖRNEK

İmza



Yukarıdaki sonucu onaylarım.

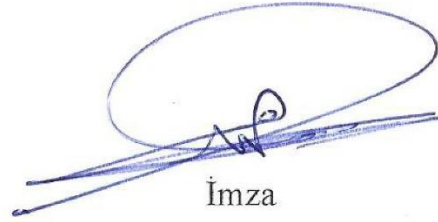
Prof. Dr. Mustafa YILMAZ
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



İmza

Mohaned Mohammed QANBAR

Tarih: 30/12/2019

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YAKLAŞIMI İLE MALARIA (SITMA) HASTALIĞI GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Mohanad Mohammed QANBAR

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilişim Teknolojileri Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Şakir TAŞDEMİR

2019, 83 Sayfa

Jüri

Prof. Dr. Şakir TAŞDEMİR

Doç. Dr. Mesut GÜNDÜZ

Doç. Dr. Humar KAHRAMANLI ÖRNEK

Günümüzde bilişim temelli uygulamalar, teknolojiadaki gelişmelerle beraber değişik disiplinlerde artmaktadır. Bu alanlardan birisi de tıptır. Yapay zeka ve makine öğrenmesi gibi teknikler tıbbi görüntülerin analizi ve sınıflandırılması için en yaygın kullanılan yöntemlerdir. Bu teknikleri kullanarak bir model oluşturmak için, öncelikle analiz edilecek özellik vektörlerinin belirlenmesi gerekmektedir. Ancak bu analiz süreçleri uzmanlık isteyen ve uzun zaman alan uygulamalardır. Bu noktada günümüzde oldukça popüler durumda olan derin öğrenme metodları kullanılarak hastalık teşhis ve tespiti çok hızlı ve kolay bir şekilde yapılabilmektedir. Uzun yıllar devam eden çalışmalar sayesinde çok sayıda derin öğrenme algoritmaları geliştirilmiştir. Bu çalışmada, kan hücrelerine ait görüntüler derin öğrenme yaklaşımı ile parazitli ve parazitsiz olarak sınıflandırılmıştır. Böylece malarya (sıtma) hastalığını tespit eden CNN tabanlı RAN modeli ile bilgisayar destekli (karar destek sistemi) bir uygulama geliştirilmiştir. Tez çalışmasında, 27,558 adet Malarya (sıtma) hastalığına ait parazitli ve parazitsiz kan örneklerini içeren smear görüntüleri veri seti kullanılmıştır. Çalışma, CNN algoritmalarından olan ve sıtma hastalık teşhisi için kullanıldığı taramalarda görülmeyen RAN modeli ile geliştirilmiştir. Ayrıca AN, VGG16, ResNet50, InceptionV3, AlexNet ve SVM modelleri ile de sonuçlar alınmıştır. RAN ve diğer modeller ile elde edilen sınıflama başarıları analiz edilmiştir. Sonuçlar istatistiksel olarak kıyaslanmış ve performans karşılaştırılması yapılmıştır. Çalışma sonucunda, RAN modeli kullanılarak oluşturulan derin öğrenme yaklaşımında %95.79 görüntü sınıflandırma doğruluğuna ulaşıldığı ve yüksek başarı oranını elde ettiği görülmektedir. Sonuç olarak, kan hücrelerine ait görüntülerin sınıflandırılması için, otomatik olarak, hızlı ve doğru bir şekilde çalışan derin öğrenme yaklaşımı geliştirilmiş ve karşılaştırmalı ve başarılı şekilde uygulanarak sonuçlar alınmıştır.

Anahtar Kelimeler: Artık Dikkat Ağı, Derin Öğrenme, Destek Vektör Makinesi, Evrimsel Sinir Ağı, Sıtma.

ABSTRACT

MS THESIS

CLASSIFICATION OF MALARIA DISEASE IMAGES USING DEEP LEARNING APPROACH

Mohaned Mohammed QANBAR

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SELÇUK UNIVERSITY
THE DEGREE OF MASTER OF INFORMATION TECHNOLOGY
ENGINEERING**

Advisor: Prof. Dr. Şakir TAŞDEMİR

2019, 83 Pages

Jury

Prof. Dr. Şakir TAŞDEMİR

Doç. Dr. Mesut GÜNDÜZ

Doç. Dr. Humar KAHRAMANLI ÖRNEK

Today, information-based applications are increasing in different disciplines together with the developments in technology. One of these areas is medicine. Techniques such as artificial intelligence and machine learning are the most commonly used methods for the analysis and classification of medical images. To create a model using these techniques, first of all, feature vectors to be analyzed must be determined. However, these analysis processes are requiring expertise and long-time applications. At this point, the diagnosis and detection of the disease can be done very quickly and easily by using deep learning methods which are very popular today. Numerous deep learning algorithms have been developed through many years of studies. In this study, smear cell images were classified as infected and uninfected with a deep learning approach. Thus, a computer-aided application (decision support system) was developed with the CNN based RAN model that detects malaria disease. In the thesis, smear images dataset containing infected and uninfected blood samples of 27,558 malaria diseases were used. The study was developed with the RAN model, which is one of the CNN algorithms and is not seen in the literature for the diagnosis of malaria disease. Also, AN, VGG16, ResNet50, Inception V3, AlexNet and SVM models were used and results obtained. Classification successes obtained with RAN and other models were analyzed. The results were compared statistically and performance was compared. As a result of the study, it is seen that 95.79% image classification accuracy is achieved and success rate is achieved in the deep learning approach using RAN model. As a result, in order to classify the images of blood cells, a deep learning approach which works automatically, quickly and accurately has been developed. Comparative and successful implementation was achieved.

Keywords: Residual Attention Network, Deep Learning, Support Vector Machine, Convolutional Neural Network, Malaria.

ÖNSÖZ

Bu tez çalışmasında, beni yönlendirip, bana her türlü desteği veren danışmanım Prof. Dr. Şakir TAŞDEMİR'e, Arş. Gör. Kübra UYAR'a, Eşime ve eğitim hayatım boyunca benden her türlü maddi manevi desteklerini esirgemeyen aileme sonsuz saygı ve teşekkürlerimi sunarım.

Mohanad Mohammed Qanbar
KONYA-2019



İÇİNDEKİLER

ÖZET	v
ABSTRACT	vi
ÖNSÖZ	vii
İÇİNDEKİLER	viii
ŞEKİLLER LİSTESİ	x
ÇİZELGELER LİSTESİ	xiii
SİMGELER VE KISALTMALAR	xiv
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	5
3. MATERYAL VE YÖNTEM	15
3.1. Sıtma Hastalığı Hakkında Genel Bilgiler.....	16
3.1.1. Hastalığın tarihçesi	18
3.1.2. Hastalığın patolojisi	19
3.1.3. Hastalığın semptomları	19
3.1.4. Hastalığının tanısı	20
3.1.4.1. Doğrudan tanı yöntemleri	20
3.1.4.2. Dolaylı tanı yöntemleri	21
3.2. Derin Öğrenme	21
3.2.1. Derin öğrenme yöntemleri	24
3.2.1.1. Evrişimsel sinir ağı yöntemi (convolutional neural networks).....	24
3.2.1.1.1. Evrişimsel sinir ağı mimarisinin bileşenleri	27
3.2.1.1.2. Evrişimsel sinir ağı modelleri	34
3.2.1.2. Tekrarlayan sinir ağları (recurrent neural network-RNN).....	41
3.2.1.3. Uzun kısa süreli bellek (long short-term memory unit).....	42
3.2.1.4. Otomatik ve Yığınlı otomatik kodlayıcılar (auto-encoders, stacked auto-encoders).....	43
3.2.1.5. Sınırlı Boltzmann Makineleri (RBM) ve Derin İnanç Ağları (DBN).....	44
3.2.1.6. Varyasyonel otomatik kodlayıcılar ve üretken ters ağlar	45
3.3. Destek Vektör Makinesi Yöntemi (Support Vector Machine).....	45
3.4. Derin Öğrenme Amacıyla Kullanılan Kütüphaneler ve Hata Matrisi	47
3.4.1. Derin öğrenme kütüphaneleri	47
3.4.2. Hata matrisi (confusion matrix)	48
4. UYGULAMA SONUÇLARI	51
4.1. Uygulama Modüllerinin İncelenmesi	51
4.2. Sıtma Görüntülerinin CNN Tekniği ile Analizi	51
4.2.1. RAN Modeli.....	51

4.2.2. AN Modeli	55
4.2.3. VGG16 Modeli	58
4.2.4. RestNet50 Modeli	61
4.2.5. InceptionV3 Modeli	63
4.2.6. AlexNet Modeli.....	66
4.2.7. Alexnet Modeli İle Gerçekleştirilen Matlab Uygulaması.....	68
4.3. Sıtma Görüntülerinin SVM Tekniđi ile Analizi	71
4.4. CNN ve SVM Yöntemlerinin Birlikte Kullanılması	72
5. TARTIŞMA VE ÖNERİLER.....	74
5.1 Tartışma.....	74
5.2 Öneriler.....	77
KAYNAKLAR	79
ÖZGEÇMİŞ	83

ŞEKİLLER LİSTESİ

Şekil 2.1. Tıbbi görüntülerin elde edilmesi (Vijayalakshmi, 2019)	12
Şekil 3.1. Sıtma paraziti taşıyan kan örnekleri (Arunava, 2019, Tensorflow, 2019, Jaeger, 2019).....	15
Şekil 3.2. Sıtma paraziti taşımayan kan örnekleri (Arunava, 2019, Tensorflow, 2019, Jaeger, 2019).....	16
Şekil 3.3. Eritrositler içerisinde görülen trofozoitler(Dobaño ve ark., 2019).....	21
Şekil 3.4. Veri işleme tekniklerinin karşılaştırılması (Goyal ve ark., 2018)	22
Şekil 3.5. Örnek bir nöron modeli (Goyal ve ark., 2018).....	23
Şekil 3.6. Örnek bir sinir ağı modeli (Zhang ve ark., 2019).....	24
Şekil 3.7. Convolutional Neural Networks (CNN) katman yapısı (Peng ve ark., 2017)	24
Şekil 3.8. O ve X harflerini temsil eden resim görüntüsü (Beysolow II, 2017)	25
Şekil 3.9. “X” harfinin özellik haritası	26
Şekil 3.10. “O” harfinin özellik haritası	26
Şekil 3.11. CNN ile özellik haritasının çıkarılması (Raschka ve Mirjalili, 2017).....	27
Şekil 3.12. Evrişimssel matris katmanında hesaplama işlemi (Vasilev ve ark., 2019) ..	28
Şekil 3.13. Maksimum havuzlama örneği (Vasilev ve ark., 2019)	29
Şekil 3.14. Ortalama havuzlama örneği (Vasilev ve ark., 2019).....	29
Şekil 3.15. CNN mimarisinde dropout katmanı kullanımı (Zhang ve ark., 2019)	30
Şekil 3.16. Tam bağlı katman ile elde edilen matris yapısı	30
Şekil 3.17. ReLU aktivasyon fonksiyonu grafiği (Zhang ve ark., 2019)	31
Şekil 3.18. Sigmoid aktivasyon fonksiyonu grafiği (Zhang ve ark., 2019).....	32
Şekil 3.19. Tanh aktivasyon fonksiyonu grafiği (Zhang ve ark., 2019).....	32
Şekil 3.20. Resim içerisinde doğru nesneye odaklanma örnekleri (Xu ve ark., 2015)....	34
Şekil 3.21. Dikkat ağı modeli kullanılarak oluşturulan örnek görüntü (Wang ve ark., 2017a)	36
Şekil 3.22. Dikkat ağı modelinde kullanılan soft mask katmanı (Wang ve ark., 2017a)	37
Şekil 3.23. VGG16 modelinde kullanılan soft mask katmanı(Simonyan ve Zisserman, 2014)	38
Şekil 3.24. ResNet50 modeli (Alom ve ark., 2018)	39

Şekil 3.25. InceptionV3 modeli (Alom ve ark., 2018).....	40
Şekil 3.26. AlexNet modeli (Alom ve ark., 2018).....	41
Şekil 3.27. RNN'nin temel işlevi (Raschka ve Mirjalili, 2017)	41
Şekil 3.28. Katmanlı RNN mimarisi (Raschka ve Mirjalili, 2017)	42
Şekil 3.29. LSTM hücre yapısı (Alom ve ark., 2018)	42
Şekil 3.30. LSTM katman mimarisi (Vasilev ve ark., 2019).....	43
Şekil 3.31. SVM yöntemi ile sınıflandırma yapılması (Yu ve ark., 2013).....	46
Şekil 4.1. RAN modeli kullanan uygulamanın eğitim (tarining) sonucuna ait ekran görüntüsü.....	53
Şekil 4.2. RAN modeli kullanan uygulamanın eğitim (tarining) sonucuna ait ekran görüntüsü	53
Şekil 4.3. RAN modeli kullanan uygulamanın test (tahmin) sonucuna ait ekran görüntüsü	53
Şekil 4.4. RAN modeli kullanan uygulamanın örnek resim üzerindeki test sonucuna ait görüntü.....	54
Şekil 4.5. Resim sınıflandırma için geliştirilen AN modeli.	56
Şekil 4.6. AN modeli kullanan uygulamanın eğitim (tarining) sonucuna ait ekran görüntüsü	57
Şekil 4.7. AN modeli kullanan uygulamanın test (tahmin) sonucuna ait ekran görüntüsü	57
Şekil 4.8. VGG16 mimarisi ile oluşturulan CNN modeli.....	59
Şekil 4.9. VGG16 Modeli kayıp ve doğruluk oranı grafiği.....	60
Şekil 4.10. VGG16 Modelinin testi sonucunda oluşan hata matrisi.....	60
Şekil 4.11. ResNet50 mimarisi ile oluşturulan CNN model.....	61
Şekil 4.12. ResNet50 Modeli kayıp ve doğruluk oranı grafiği.....	62
Şekil 4.13. ResNet50 Modelinin testi sonucunda oluşan hata matrisi.....	63
Şekil 4.14. InceptionV3 mimarisi ile oluşturulan CNN modeli	64
Şekil 4.15. InceptionV3 Modeli kayıp ve doğruluk oranı grafiği	65
Şekil 4.16. InceptionV3 Modelinin testi sonucunda oluşan hata matrisi	65
Şekil 4.17. AlexNet Modeli kayıp ve doğruluk oranı grafiği.....	67
Şekil 4.18. AlexNet modelinin testi sonucunda oluşan hata matrisi	67
Şekil 4.19. AlexNet mimarisi ile oluşturulan CNN modeli (Anwar, 2019).....	68

Şekil 4.20. AlexNet kullanan uygulamanın eğitim sonucuna ait ekran görüntüsü.....	69
Şekil 4.21. AlexNet mimarisinin hata matrisi	70
Şekil 4.22. SVM yöntemi ile elde edilen hata matrisi	72
Şekil 4.23. CNN ve SVM yöntemlerinin birleştirilmesi ile oluşturulan katman mimarisi (Vijayalakshmi, 2019)	73



ÇİZELGELER LİSTESİ

Çizelge 2.1. Literatürde yer alan benzer çalışmaların sonuçları.....	13
Çizelge 3.1. X harfini temsil eden matris bilgisi.....	27
Çizelge 3.2. Örnek bir dikkat ağı model mimarisi	37
Çizelge 3.3. Scikit-learn SVM çekirdek fonksiyonları.....	46
Çizelge 3.4. Hata matrisi ile yapılan test hesaplamalar	48
Çizelge 4.1. RAN modeli eğitim sonuç verileri	53
Çizelge 4.2. RAN modeli test sonuç verileri	54
Çizelge 4.3. RAN modeli tek resim test sonuç verileri	55
Çizelge 4.4. RAN modeli eğitim sonuç verileri	55
Çizelge 4.5. AN modeli eğitim sonuç verileri	57
Çizelge 4.6. AN modeli test sonuç verileri.....	58
Çizelge 4.7. VGG16 modeli eğitim sonuç verileri	59
Çizelge 4.8. VGG16 modeli test sonuç verileri.....	60
Çizelge 4.9. ResNet50 modeli eğitim sonuç verileri	62
Çizelge 4.10. ResNet50 modeli test sonuç verileri.....	63
Çizelge 4.11. InceptionV3 modeli eğitim sonuç verileri.....	64
Çizelge 4.12. InceptionV3 modeli test sonuç verileri	65
Çizelge 4.13. AlexNet modeli eğitim sonuç verileri	66
Çizelge 4.14. AlexNet modeli test sonuç verileri.....	68
Çizelge 4.15. AlexNet modeli eğitim sonuç verileri(matlab dilinde).....	69
Çizelge 4.16. AlexNet modeli test sonuç verileri(matlab dilinde)	70
Çizelge 5.1. Uygulamada kullanılan modellerin eğitim sonuçları	75
Çizelge 5.2. Uygulamada kullanılan modellerin test sonuçları	76

SİMGELER VE KISALTMALAR

1B	: One Dimensional (Tek Boyutlu)
2B	: Two Dimensional (İki Boyutlu)
3B	: Three Dimensional (Üç Boyutlu)
ANN	: Artificial Neural Network (Yapay Sinir Ağı)
CADx	: Computer Aided Diagnosis (Bilgisayar Destekli Tanı)
CNN	: Convolutional Neural Network (Evrşimsel Sinir Ağı)
DBN	: Deep Belief Network (Derin İnanç Ağları)
DSÖ	: Dünya Sağlık Örgütü (World Health Organization - WHO)
DL	: Deep Learning (Derin Öğrenme)
FR-CNN	: Faster Region Convolution Neural Network (Hızlı Bölge Tabanlı Evrşimsel Sinir Ağı)
HSV	: Hue, Saturation, Value (Ton, Doygunluk, Değere Göre Renklendirme)
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
ML	: Machine Learning (Makine Öğrenmesi)
NLM	: The National Library of Medicine (Ulusal Tıp Kütüphanesi)
QBC	: Quantitative buffy coat (Kantitatif Buffy Coat Yöntemi)
RAN	: Residual Attention Networks (Artık Dikkat Ağları)
AN	: Attention Networks (Dikkat Ağları)
RBC	: Red Blood Cell (Kırmızı Kan Hücresi)
RBM	: Restricted Boltzmann Machines (Sınırlı Boltzmann Makineleri)
RGB	: Red, Green, Blue (Kırmızı, Yeşil ve Mavi'ye Göre Renklendirme)
RNN	: Recurrent neural networks (Tekrarlayan Sinir Ağları)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
SVC	: Support Vector Classification (Destek Vektör Sınıflandırma)
VAE	: Variational Autoencoder (Varyasyonel Otomatik Kodlayıcı)
ABD	: Amerika Birleşik Devletleri
VGG16	: The Visual Geometry Group (Görsel Geometri Grubu)
ResNetV2	: Residual Network (Artık Ağ)
Tanh	: Tanh Fonksiyonu (Hiperbolik Tangent)
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
GPU	: Grafik İşleme Ünitesi (Graphics Processing Unit)
GAN	: Üretken ters ağlar (Generative adversarial networks)

1. GİRİŞ

Teknolojideki hızlı deęişimler, insan hayatında önemli etkiler meydana getirmiştir. Bu gelişmeler ile teknolojinin ve bilgisayar sistemlerinin insan hayatındaki vazgeçilmezlięi artarak devam etmektedir. Bilgisayarlar donanımları-yazılımları ve destekledięi cihazlar, hayatın neredeyse bütününde insanlıęa hizmet etmekte, yardımcı olmaktadır. İş yerlerinde, evlerde, okullarda kısacası hayatın her alanında bu teknolojiden faydalanma durumunu görmek mümkündür. Bu alanların biri de saęlık sektörü ve tıptır. Bu tür sistemler, hastalıkların teşhisi, sınıflandırılması ve tedavi aşamasında yaygın olarak kullanılmaktadır.

Hastalık sayısının fazla oluşu, teşhis ve tedavilerde oldukça fazla veriye ihtiyaç duyulması, bu verilen toplanması ve işlenmesi aşamasındaki maliyet artışı, süre gibi sebepler, tıp biliminde bilgisayar sistemlerinin kullanılmasını gereklilik haline getirmiştir. Tıp bilim insanları için birçok hastalığın tedavisinde erken teşhisin çok büyük önemi vardır. Buna yönelik araştırmalar da öncelikli konumdadır. Buna paralel olarak tıp ile ilgili çalışan bilişimciler, veri analizi ve görüntü işleme konularında karşılaşılan güçlükleri aşabilmek için, yapay zeka, makine öğrenmesi ve derin öğrenme yöntemlerini kullanabilmek amacıyla deęişik algoritmalar ve yazılım kütüphaneleri geliştirmeye çalışmaktadırlar. Bu şekilde tıp bilim insanlarının daha doęru ve hızlı karar verebilmeleri amacıyla bilgisayar sistemleri karar-destek amacıyla kullanılabilir. Yapay zeka, makine öğrenmesi ve derin öğrenme yöntemlerinin bir dięer katkısı da, hastada görülen semptomlar sırasında gözden kaçabilecek ayrıntıların fark ederek, tedavi sürecine olumlu katkı sağlanmasıdır (Şeker ve ark., 2017).

Malarya (Sıtma) hastalığı, sivrisinekler yoluyla taşınan, insanları ve hayvanları etkileyen bir hastalık türüdür. Sıtmanın tipik semptomları arasında, ateş, yorgunluk, kusma ve baş ağrısı vardır. Bu belirtiler genel olarak, sıtma hastalığı taşıyan bir sivrisineğin ısırmasından yaklaşık 10-15 gün sonra ortaya çıkmakta ve eęer hastalığın tedavisi düzgün yapılmazsa enfeksiyon tekrarlayabilmektedir. Ağır sıtma vakalarında, nöbetlere ve ölümlere varan ciddi sonuçlar ortaya çıkabilmektedir. Enfeksiyondan yeni kurtulanlarda ise yeterli dezenfeksiyon olmazsa, daha hafif semptomlar görülebilmektedir (Saygı, 1998; Altıntaş, 2002).

2016 yılında, dünya genelinde 216 milyon sıtma vakası yaşanmış ve bunun sonucunda binlerce insan hayatını kaybetmiştir. Bu hastalığa baęlı olarak, saęlık harcamalarında artış, çalışma gücünün azalması ve bulaşıcı olmasından dolayı turizm ve

ticaret sektörü üzerinde olumsuz etkiler yaşanabilmektedir. Türkiye’de görülen sıtma türünün, hafif seyrelmesi ve doğrudan hastalığa bağlı ölümler görülmemesi, hastalığın önemsenmemesine neden olmaktadır. Oysa Türkiye’de görülen sıtma hastalığı doğrudan ölümlere neden olmamakla birlikte, düşük veya ölü doğumun yanısıra doğum esnasında anne ölümlerine de yol açabilmektedir (Okursoy, 2010).

Sıtma hastalığına yakalanan kişilerin şikayetleri ve hastalığın belirtileri insana sıkıntı vermektedir. Bunlar; yüksek ateş, üşüme, titreme ve terleme şeklindedir. Bu belirtilere kusma ve ishal eşlik edebilmektedir. Parazitin kuluçka süresinin sonunda ise ölüme varabilen ateşli nöbetler, halsizlik, iştahsızlık, baş, kas ve eklem ağrıları gibi belirtiler görülebilmektedir (Saygı, 1998; Altıntaş, 2002). Geleneksel yöntemlerle hastalığın teşhisinde zaman kaybedilmesi ve uzman personel tarafından tetkik ve muayene yapılması gerekliliği de hastalıkla mücadele de etken unsurlar olmaktadır. Yukarıda ifade edilen nedenlerle, hastalığın erken teşhisi, semptomlarının bir ana önce kontrol altına alınması ve tedaviye başlanması açısından, modern ve gelişmiş yöntemlerin geliştirilmesi son derece önemli olmaktadır. Bu kapsamda yapılan çalışma ile gelişmiş teknolojik olanaklardan faydalanılarak, bilgisayar destekli yazılımlar ile sıtma hastalığının teşhisine katkı sağlanması amaçlanmıştır.

Bu kadar önemli etkileri olan bir hastalık için, Derin Öğrenme (Deep Learning) yöntemlerinin kullanılması, doktorlara hastalığın sınıflandırılmasında (teşhisinde) yardımcı olmak ve hastaya ait işlemleri hızlandırmak açısından büyük önem arz etmektedir. Günümüzde, derin öğrenme algoritmaları tıp alanında yaygın olarak kullanılmaktadır. Zira yapay zeka sistemlerinin doğruluk payı yüksek orandaki öngörülerini etkili olmaktadır. Ayrıca geliştirilen yöntemlerin mobil cihazlarda kullanılabilir kadar etkin ve verimli olması sayesinde, hastalığın hızlı ve kolay bir şekilde tespit ve teşhis edilmesi sağlanmaktadır. Böylece tıbbi maliyetler de düşürülebilmektedir. Sağlık ve tıp alanında tanı programları, tedavi protokolü geliştirme, ilaç geliştirme, kişiselleştirilmiş tıp, hasta izleme ve bakımı gibi olumlu etkilerinden dolayı uygulanmaktadır.

Bu bağlamda, tez çalışmasındaki beklentilerden biri, sıtma hastalığının teşhisi için insan gücünü ve tıbbi maliyetleri düşürebileceği şeklindedir. Evrişimsel Sinir Ağlarının (CNN) büyük bir veri seti ile çalıştırılması, daha doğru, hızlı ve düşük maliyetli bir tanı gerçekleştirilecek ve doktora yardımcı olabilecektir.

Makine öğrenmesi ve görüntü işleme tekniklerinden farklı olarak, derin öğrenme mimarileri, analiz süreçlerini ham verilerde gerçekleştirmektedir. Geliştirilen yapay

öğrenme algoritmaları ile işlemlerin daha hızlı ve daha doğru olması sağlanabilecektir. Bu durum hem hasta konforu hem de ülke ekonomisine katkı sağlanabilecektir. Bu tür olumlu sonuçlar, çalışmanın önemini ortaya koymaktadır. Bu kapsamda geliştirilen bilgisayar destekli yazılımlar ile sıtma hastalığının teşhisi ve buna yönelik tedavi süreçlerinde doktorun yaptığı işlemlere destek olunabilecek ve hızlı bir karar verme süreci oluşturulabilecektir.

Yapılan literatür taramasında, malaria (sıtma) hastalığı için bilgisayar temelli farklı çalışmalar yapıldığı görülebilmektedir. Görüntü işleme, makine öğrenmesi ve derin öğrenme algoritmaları bunlardan bazılarıdır. Son yıllarda derin öğrenme yaklaşımlarındaki çalışmalar, diğer tıbbi uygulamalarda olduğu gibi malaria hastalığının teşhisi için de uygulanabilir bir yöntem olarak kullanılabilirliğini göstermektedir. Yapılan literatür araştırmaları bu hususu destekler niteliktedir.

Bu çalışmada, kan hücrelerine ait görüntülerin incelenmesi sonucunda sıtma paraziti bulaşmış-bulaşmamış olanların hızlı ve doğru bir şekilde sınıflandırılması için derin öğrenme yaklaşımı ile geliştirilmiş bilgisayar destekli bir yazılımının tasarlanması amaçlanmıştır. Bu amaçla (Arunava, 2019) ve (Tensorflow, 2019) 'dan temin edilen parazitli ve parazitsiz (infected-uninfected) smear kan örneklerine ait (veri seti) görüntüler kullanılmış, ayrıca ABD Ulusal Tıp Kütüphanesi'nin internet sitesinden (Jaeger, 2019) faydalanılarak (görüntülerin nasıl, ne şekilde ve kimlerden alındığı vb.) derin öğrenme yöntemlerinden Evrişimsel Sinir Ağı (Convolutional Neural Networks-CNN) ile analiz edilmiştir. Bu şekilde, incelenen görüntülere parazit bulaşıp bulaşmadığının, diğer bir ifadeyle kan örneklerinin hastalıklı veya hastalıklı olmayan görüntülere ait olduğunun belirlenmesi kolaylıkla yapılabilmektedir.

Bu kapsamda, sıtma hastalığına ait görüntülerin sınıflandırılması için Python programlama dili ve diğer kütüphaneler kullanılmıştır. Tıbbi resimlerin sınıflandırılması için kullanılacak bir bilgisayar uygulaması geliştirilmesi amacıyla, makine öğrenme ve derin öğrenme algoritmalarını içeren TensorFlow, Keras ve Scikit-learn gibi kütüphanelerden faydalanılmıştır.

Literatür incelendiğinde, bu alanda farklı uygulama ve araştırmaların yapıldığı görülmektedir. Ancak bu çalışmalar arasında, CNN algoritmasından biri olan RAN modelinin (sıtma hastalığına ait) bu veri setinde kullanılmadığı tespit edilmiştir. RAN modeli sağladığı avantajlar ile derin öğrenme alanında öne çıkan bir yöntem durumundadır. Yapılan çalışmada, RAN modeli veri setine uygulanarak sonuçlar alınmıştır. Ayrıca diğer CNN yöntemleri (AN, VGG16, ResNet50, InceptionV3,

AlexNet) ve SVM ile sonuçlar alınmış ve istatistiksel kıyaslamalar yapılmıştır. Tez, bu yönü ile literatürdeki diğer çalışmalardan farklı olmakta ve performans karşılaştırmaları yapıldığında bilime önemli katkılar sağlayabilmektedir.

Bu amaçla yapılan çalışma beş bölümden oluşmaktadır. Birinci bölümde yapılan tez çalışması ile ilgili genel bir giriş yapılmıştır. İkinci bölümde konu ile ilgili literatürde yer alan çalışmalar incelenmiştir, üçüncü bölümde sıtma hastalığı hakkında genel bilgiler verildikten sonra, derin öğrenme kavramı ele alınmıştır. Dördüncü bölümde sıtma hastalığına ait kan örneklerini içeren görüntülerinin incelenmesi için hazırlanan bilgisayar uygulamasının bölümleri ve çalışması incelenmiştir. Çalışmanın beşinci ve son bölümünde ise elde edilen bulgular değerlendirilerek, önerilerde bulunulmuştur.



2. KAYNAK ARAŞTIRMASI

Literatür taramasında, Sıtma hastalığının teşhisi ve sınıflandırması vb. için Derin Öğrenme algoritmaları ve kütüphaneleri kullanılarak, yapılan değişik çalışmalar ve sonuçları ayrıntılı incelenmiştir.

Quinn ve ark. (2016) yaptıkları araştırmada mikroskopi ve bilgisayarlı görme yöntemlerini kullanan teşhis için, birkaç pratik soruna uygulamışlar ve başarılı sonuçlar elde etmişlerdir. Bununla birlikte, kullanılan bilgisayarla görme yöntemlerinin duyarlılığı ve özgüllüğü sınırlamalara tabidir. Çalışmada, derin öğrenmenin nesne tanıma görevleri için insan performansını aşan bazı durumlarda bilgisayar alanında devrim niteliğinde olduğu anlatılmıştır. Makalenin, derin evrimsel sinir ağlarının üç farklı mikroskopi görevindeki performansını değerlendirmek, kalın kan lekelerinde sıtma tanısı, balgam örneklerinde tüberküloz ve dışkı örneklerinde intestinal parazit yumurtalarını tespit etmek amaçlarını taşıdığı ifade edilmiştir. Her durumda doğruluğun çok yüksek olduğu ve geleneksel tıbbi görüntüleme tekniklerinden çok daha iyi sonuçlar verdiği öne sürülmüştür. Örnek olarak, Gana'da yapılan ulusal bir çalışmada 100,000 nüfus için 1,72 mikroskop bulunması, ancak 100,000 nüfus için yalnızca 0.85 eğitimli laboratuvar bulunması gösterilmektedir. Sonuç olarak, teşhisler sıklıkla tek başına klinik belirti ve semptomlar temelinde yapılır, bu hataya açıktır ve daha yüksek mortalite, ilaç direnci ve gereksiz ilaç satın almanın ekonomik yüküne yol açar, denilmiştir. Çalışma ile CNN ile yapılan hastalık tanımlama çalışmaları sonucunda %96'lık bir doğruluk elde edilmiştir.

Bibin ve ark. (2017) yılında yaptıkları çalışmada, Derin İnanç Ağı (Deep Blief Network (DBN) kullanarak insan periferik kan yayma görüntülerinde malaria parazitlerinin varlığını tanımlamak için yeni bir yöntem önermişlerdir. Bu çalışmada, parazit veya parazit olmayan bir sınıfa 4100 periferik kan smear görüntüsünü sınıflandırmak için DBN'ye dayanan eğitimli bir model sunulmaktadır. Önerilen DBN, ön eğitim için kontrast sapma yöntemini kullanarak sınırlı Boltzmann makinelerini istifleme yoluyla önceden eğitilmiştir. DBN'yi eğitmek için görüntülerden beslenmekte ve DBN'nin görünür değişkenlerini başlatmaktadır. Bu çalışmada bir özellik vektörü olarak birleştirilmiş renk ve doku özelliği kullanılmıştır. Son olarak, DBN, sınıf etiketlerinin olasılığını hesaplayan bir geri yayılım algoritması kullanılarak ayırt edici olarak ayarlanmamıştır. Bu çalışmada kullanılan DBN mimarisinin optimum boyutu, görünür katmanın 484 düğüme sahip olduğu ve çıkış katının, her katmanda 600 gizli

düğüm içeren dört gizli katmanı olan iki düğüme sahip olduğu 484-600-600-600-600-2'dir. Önerilen yöntem, %89.66'lık bir F-skoru, %97.60'lık bir duyarlılık ve %95.92'lik Hassasiyet, F-ölçütü ile diğer modern yöntemlerden önemli ölçüde daha iyi bir performans göstermiştir. Bu makale, insan periferik kan smear görüntülerinde malaria parazit tespiti için DBN'nin ilk uygulamalarından birini içermektedir.

Dong ve ark. (2017) yılında yayınladıkları makalede, malaria enfeksiyonu olan hücreleri derin öğrenme (deep learning) kullanarak otomatik olarak tanımlanmasını sağlamışlardır. Kullanılan veri kümesini derlemek için, ince kan lekelerinin tüm slayt görüntüleri malaria ile enfekte olan kırmızı kan hücrelerinin ve enfekte olmayan hücrelerin dört patolojik grubu tarafından etiketlenmiştir. İyi bilinen evrimsel sinir ağları türleri: "LeNet", "AlexNet" ve "GoogLeNet", olarak üçe ayrılmıştır. Çalışmada yapılan simülasyon sonuçlarının gösterdiği verilere göre, tüm bu derin evrimsel sinir ağlarının başarıları %95 başarı ile sınıflandırma yapmaktadır. Hassasiyeti daha yüksek destek vektörünün kullandığı yöntemde elde edilebilir yaklaşık değer %92'dir.

Mehanian ve ark. (2017) yılında Optik Mikroskop kullanıldığından bahsedip, alternatif olarak geliştirdikleri yöntemi anlatmışlardır. Yeni bir takım bilgisayarlı görüntü işleme teknikleri gelişmiş teknolojinin temelini oluşturmaktadır. Çalışmada zengin, küresel bir eğitim seti özetlenmiştir. Algoritmayı ayrıntılı olarak tarif ederek; hasta düzeyinde tartışarak otomatik değerlendirmesi için performans ölçümleri tanı yöntemleri ve P. falciparum için sonuçlar sağlanmaktadır. Bu ölçümleri yaparken birçok hastadan ve laboratuvarlardan örnekler alınarak, görüntü işleme ve ön işleme (bu aşamada; sıtma hastalığının parazitli kan örnekleri renkleri vasıtasıyla ayrılmıştır) yoluyla örnekler ayrıştırılmış, ardından CNN metodu kullanılmıştır. Veri toplama işleminin ardından, tanıma ve sınıflandırma işlemleri yapılarak istatistik verileri ortaya çıkarılmıştır. Bu çalışmada tanıma işleminin sonucu %90 olarak çıkmıştır.

Dong ve ark. (2017) çalışmalarında, birçok biyomedikal uygulamada, görüntülerin kaydedilerek sıkıştırılmış görüntü şeklinde iletildiği anlatılmış ve tipik desen sınıflandırıcılarının orijinal görüntüler kullanılarak eğitilebildiğini ifade etmişlerdir. çalışmada resimlerin ne kadar kayıpsız şekilde açıldığına dair çok az ön çalışma yapılmış olduğu anlatılarak, bunun sınıflandırma performansını etkileyeceği açıklanmıştır. Bir vaka çalışmasında sıtma ile enfekte olmuş hücrelerin otomatik sınıflandırılmasında, kullanılan derin konvolüsyona, girdi olarak dekompresyon hücre görüntüleri verilmiştir. Çeşitli kayıplı görüntü sıkıştırma yöntemleri ve değişken sıkıştırma oranları sınıflandırma doğruluğunu ortaya çıkarmada yardımcı olacaktır.

Özellikle dört yöntem belirlenmiştir, sıkıştırma yöntemleri: *Bitplane azaltma yoluyla kayıplı sıkıştırma*, *JPEG* ve *JPEG 2000* ve *seyrek otomatik kodlayıcılar*. Dekompresyonlu görüntüler eğitim ve test için LeNet-5'e verilmiştir. Simülasyon sonuçlar benzer sıkıştırma oranları için bit düzleminin redüksiyon yöntemi en düşük sınıflandırma doğruluğuna sahipken, JPEG ve JPEG 2000 yöntemleri iyi doğrulukları koruyabilmiştir. Özellikle, JPEG 2000 sıkıştırılmış görüntüler 30 ila 1 sıkıştırmadan sonra bile yaklaşık %95 hassasiyet elde edilmiştir. Ayrıca yaygın olarak kullanılan sınıflandırma sonuçlarını da çalışmada sunulmuştur. MNIST veri kümesi, el yazısı basamakların bulunduğu hakkında sıkıştırılmış görüntüler kullanarak sınıflandırmak çok daha kolayken, sadece tek bir bit düzlemi kullanılarak %90 doğruluk elde edilebilir.

Hung ve Carpenter (2017) çalışmalarında, Derin öğrenmeye dayalı modeller, nesne tespitinde büyük başarı elde etmişlerdir, ancak sanat modellerinin durumu biyolojik görüntü verilerine henüz yaygın olarak uygulanmamıştır. İlk kez, daha önce doğal görüntülerde hücreleri tanımlamak ve sıtma ile enfekte olmuş kanın aydınlık mikroskopi görüntülerinde aşamalarını tanımak için kullanılan bir nesne algılama modeli uygulandığı belirtilmiştir. Sıtma parazitleri gibi birçok mikro organizma hala uzman tarafından el ile muayene ve sayım şeklinde yapılmaktadır. Bu tür nesne algılama görevi, hücre şekli, yoğunluğu ve rengindeki değişiklikler ve bazı hücre sınıflarının belirsizliği gibi faktörler nedeniyle zor olduğu belirtilmiştir. Ek olarak, eğitim için yararlı olan açıklamalı veriler yetersizdir ve sınıf dağılımı, enfekte olmamış kırmızı kan hücrelerinin baskınlığı nedeniyle doğası gereği oldukça dengesizdir. ImageNet'te önceden eğitilmiş, ancak verilerimizle hassas şekilde ayarlanmış ve son yıllarda verilerimize göre ayarlanmış en iyi nesne tespit modellerinden biri olan Hızlı Bölge Tabanlı Evrimsel Sinir Ağı'nı (FR-CNN) kullanmışlardır. Hücre segmentasyonu, birkaç tek hücreli özelliğin çıkarılması ve rastgele ormanları kullanarak sınıflandırmadan oluşan geleneksel bir yaklaşım olarak tanımlanmıştır. İlk çalışmayı yapmak için, yaklaşık 100,000 ayrı hücreden oluşan 1300 görüş alanı veri setini toplanıp, etiketlenmiştir. Daha hızlı R-CNN'nin temel çizgimizi geride bıraktığını ve sonuçları insan performansı bağlamında ortaya koyduğunu göstermeye çalışmışlardır.

Razzak ve Naz (2017)'de hazırladığı, "Microscopic Blood Smear Segmentation and Classification using Deep Contour Aware CNN and Extreme Machine Learning" isimli makalede, Genomik teknolojilerinde son gelişmeler ve hastalıkların erken teşhisi için yeni teknikler geliştirildiği belirtilmiştir. Manuel tasarımın dezavantajlarının üstesinden gelmek için potansiyel teknolojiler incelenmiştir. Bu makalede,

segmentasyon yaklaşımına dayalı sınıflandırma için, Evrişimsel Sinir Ağı (CNN) ve makine öğrenimi kullanılmıştır. Makaledeki değerlendirmeye göre; bölümlendirme ve sınıflandırmaya dayalı sistem performansı veri setine bağlı olmaktadır. Çalışmada 64,000 kan hücresini içeren veri setine üzerinden deneme yapılmıştır. Veri setinin %80'i eğitim için ve %20'si test için ayrılmıştır. Segmentasyon sonuçları manuel segmentasyona göre karşılaştırılmış ve %98.16 lık bir başarı elde edilmiştir.

Poostchi ve ark. (2018b) çalışmalarında, Redüksiyon teşhisinin özellikle malaria teşhisinde yetersiz kaldığını belirtmektedirler. Teşhisi iyileştirmek için, mikroskopik kan slaytlarındaki parazitemiyi ölçmek için görüntü analiz yazılımı ve makine öğrenme yöntemleri kullanılmıştır. Bu makale, bu tekniklere genel bir bakış verir ve mikroskopik malaria teşhisi için görüntü analizindeki ve makine öğrenimindeki güncel gelişmeleri tartışır. Burada asıl nokta, enfekte olmuş hücrelerde, bu özelliklerin, görünür sitoplazma ve diğer benzersiz parazit özelliklerine sahip halka yapılarının tipik görünümünü yakalayabilmesidir. Genel olarak, kullanılan özelliklerin çoğu, diğer, genellikle tıbbi olmayan uygulama alanlarında zaten uygulanmış, denenmiş ve güvenilir özelliklerdir. Çoğu çalışma standart RGB renk alanında kalsa da, bu çalışmada ise, genellikle mavi veya mordan kahverengimsi tonlara kadar değişen tipik boyama renklerini çıkarmak için daha uygun olan farklı bir renk alanı kullanmak için yeterli bir neden olduğu düşünülmüştür. HSV renk sistemi birçok ürün tarafından tercih edilir ve diğer bazı makaleler de lekelenmeyle ilgili renk bilgilerini gri skalaya çıkarmak için yeşil RGB kanalını kullanır. Kalın lekeler için daha az sayıda yayın olması nedeniyle, literatürde daha az sayıda özellik denenmiştir. Derin öğrenme, yaygın makine öğrenme tekniği olduğundan, çeşitli çalışmalarda hücre sınıflandırması, hücre evrelemesi, hücre bölünmesi ve otomatik malaria tanısında diğer alt problemler için görünmesini beklenebilir.

Rajaraman ve ark. (2018) çalışmalarında, mikroskoplarla, hastalıkları teşhis etmek ve parazitemiyi hesaplamak için genellikle kalın ve ince kan lekelerini incelemişlerdir. Yapay zeka teknikleri kullanılarak smearlerin mikroskopik görüntülerine uygulanan, makine öğrenmesi (ML) tekniklerini kullanan, bilgisayar destekli tanı (CADx) yöntemlerine dayalı, bilgisayarlı tanı (CADx) yöntemleri, morfolojik, dokusal ve konumsal varyasyonların analizinde uzmanlık istemektedir. Buna karşılık, derin öğrenme sınıfı (DL) modelleri olan Evrişimsel Sinir Ağları (CNN), uçtan uca özellik çıkarma ve sınıflandırma ile son derece ölçeklenebilir ve üstün sonuçlar vaat etmektedir. DL tekniklerini kullanarak otomatik malaria taraması bu

nedenle etkili bir teşhis yardımcısı olarak kullanılabilir. Bu makalede, önceden eğitilmiş CNN bazlı DL modellerinin gelişmiş hastalık taramasına yardımcı olmak için parazitlenmiş ve enfekte olmamış hücrelerin sınıflandırılmasına yönelik özellik çıkarıcıları olarak performansını değerlendiririz. Temel verilerden özellik çıkarımı için en uygun model katmanlarını deneysel olarak belirlenmiştir. Bu çalışmada sınıflandırılma işleminin sonucu %93 olarak çıkmıştır.

Poostchi ve ark. (2018a) çalışmalarında, kırmızı kan hücrelerini (RBC) tespit etmek ve segmentlere ayırmak ve Wright-Giemsa lekeli ince kan lekelerinde enfekte hücreleri tanımlamak için otomatik bir sistem geliştirmişlerdir. Spesifik olarak, görüntü analizi ve makine öğrenme teknikleri kullanılarak, her bir smeardeki parazitemiyi belirlemek için ince kan lekelerinin dijital görüntülerini işlenir. RBC'leri, özellikle üst üste binen hücreleri bölümlere ayırmak için bir hücre ekstraksiyon yöntemi kullanılmıştır. RGB renk ve doku özelliklerinin bir birleşiminin diğer özellikleri geride bıraktığını gösterilmiştir. İnsan ve fareden alınan mikroskobik kan bulaşan görüntülerdeki yöntemlerini değerlendirerek ve diğer teknikleri geride bıraktığını göstermişlerdir. İnsan hücreleri için, gerçek ve otomatik parazit sayımı arasındaki %1.18'lik mutlak bir hata ölçülmüştür. Fare hücreleri için, otomatik sayımlarımız uzman ve akış sitometrisi sayımları ile iyi koreledir. Çalışma yapılırken özellikle, görüntü analizi ve makine öğrenme teknikleri ile her birinde paraziti belirlemek için ince kan lekelerinin dijital görüntüleri işlenmiştir. RGB ile renk ve doku özelliklerinin diğer özelliklerden daha iyi performans gösterdiği tespit edilmiştir. Bu çalışmada, görüntü işleme tekniği ve Support Vector Machine (SVM) / Artificial Neural Network (ANN) algoritmalarıyla doğru bir şekilde tespit etmede (F1 Skoru) puanının %90'ına ulaşmaktadır.

Azif ve ark. (2018) çalışmalarında, her bir araştırmada farklı özelliklere sahip görüntülerin kullanılması, hangi yöntemin en iyi kullanılacağına belirlenmesinin zorlukları üzerinde bir etkiye sahip olduğundan bahsedilmiş, bu araştırma alanında önerilen yöntemin büyük oranda kullanılan görüntünün özelliklerine bağlı göstermekte olduğu söylenmiştir. Belirli bir görüntü özelliğinde optimal görüntü işleme sekansının yöntem veya şemasının araştırılması, daha ileri araştırmalar için hala derinlemesine incelenebilir. Üstelik kalın kan bulaşmasında yayının çoğunluğu, malaria parazitini, boyama işleminin bir sonucu olarak ortaya çıkabilecek artefaktlarla ayırmamaktadır. Her çalışmada tıbbi imge hakkındaki sınırlı veri, araştırmacıları daha fazla araştırma yapma konusunda kısıtlayan bir faktördür. Malaria teşhisi konusundaki birçok çalışma

derin öğrenme kullanmaya başlamıştır, fakat kullanılan görüntü hala ince kan lekelerinden alınmıştır. İlgili çalışmada sırasıyla; Görüntü işlemede yapılması gereken ilk aşama ön işleme aşamasıdır. Bu aşamada görüntü kalitesinin iyileştirilmesi ve görüntü boyutu değişiklikleri yapılır. Ardından Bu aşamada ana odak, nesnelere (beyaz kan hücreleri ve plazmodyum) ile arka plan arasındaki ayırmadır. Son olarak özellikler çıkarılarak, sınıflandırma yapılır. Bunlardan haricen, Plazmada düşük yoğunluklu kan bulaşmasında, her görüntüde (%8) düşük yanlış pozitif algılama ile yüksek algılama hassasiyeti (%97) sağlanabildiği belirlenmiştir.

Das ve ark. (2013) çalışmalarında, Malariyanın, hematolojik alanda milyonlarca ölüme neden olan korkunç bir hastalık olduğundan, bununla birlikte hızlı tanınım, malaria tedavisi ve ölüm oranını azaltmak için öneminden bahsedilmiştir. Bu nedenle hızlı teşhis ve uygun ilaçlama, çağın yoğun ihtiyacı olduğu anlatılarak; sıtma analizi kan filmlerinin mikroskopik incelemesine dayanmakta olduğu anlatılarak çalışmanın yönü belirlenmiştir. Bu çalışmada, görüntü işleme teknikleri, Giemsa lekeli ince kan bulaşmasının mikroskopik görüntülerinden malaria tespiti için kullanılmıştır. Kan smear görüntüleri iki yonteme dayanarak analiz edilmiştir: İlk olarak, önceden işlenmiş görüntülerden SIFT özelliklerini ayıklayarak ve tanıma için sınıflandırıcıya yönlendirilmiştir. Çıkarılan SIFT özelliklerinin tanınması için karşılaştırmalı bir SVM (Destek Vektör Makinesi) ve ANN (Yapay Sinir Ağı) analizi yapılmaktadır. İkinci yöntemde ise, CNN tabanlı bir ağ üzerinde herhangi bir ön işleme tabii tutulmadan görüntünün doğrudan yönlendirilmesini içermektedir. SIFT bazlı özellik çıkarma yöntemi, SVM ile %94 ve CNN bazlı özellik çıkarma yöntemi ile %96 oranında doğruluğa ulaşılmıştır.

Aladago (2018) çalışmasında, sıtmanın dünyadaki en ölümcül hastalıklardan biri olduğundan, hastalığın eski olsa da bu hastalık için yeni ilaçların ve tedavi yöntemlerinin arayışının devam etmekte olduğundan bahsetmiştir. İlaç üretimindeki ana zorluklardan biri olarak, sıtma parazitlerine ait kesin ölçülerin ve kan bulaşma görüntülerinin sayılmasında ortaya çıkmaktadır. Bu tür ayrıntılı teşhisler için genellikle manuel mikroskopi yöntemi kullanılmaktadır. Bu araştırmada ise, evrişimli sinir ağı yönteminin kullanılması incelenmiştir. Çalışmada, çok az veri bulunan durularda bile, Plasmodium parazitlerinin farklı büyüme döngüsü aşamalarını tanımlamak için çeşitli ağlar kullanılmıştır. Veri büyütme ve transfer öğrenme teknikleri ile resimleri ayırt etmek için semantik bir segmentasyon modeli oluşturulmuştur. Trofozoitler, gametositler ve normal kırmızı kan hücreleri arasından %85.86 doğrulukla, Giemsa

lekeli ince kan hücreleri tespit edilmiştir. Çalışma sonucunda, Evrişimsel Sinir Ağları (CNN) kullanılarak, Giemsa lekeli ince kan buluşımına ilişkin yoğun öngürlerde bulunulabildiği kanısına varılmıştır.

Sorgedragger (2018) makalesinde, yakalanan düşük kaliteli kan smear görüntülerinde, otomatik olarak, düşük maliyetli bir akıllı telefon mikroskobu sistemi kullanılarak, malaria teşhisinin yapılmasına odaklanılmıştır. Buradaki asıl amaç, kan parazitemisini değerlendirmek için sağlıklı ve enfekte eritrositler ile yerelleştirmek ve sınıflandırmaktır. Due akıllı telefon mikroskobunun kalitesine göre, geleneksel yüksek teknolojiye kıyasla ışık mikroskopları, geleneksel algoritmaların bu görüntüleri işlemede başarısız oldukları tespit edilmiştir. Eeritrositleri lokalize etmek için, bir piksel sınıfı olarak evrişimli bir sinir ağının kullanılması önerilmiştir. Daha sonra, evrişimsel bir sinir ağını bir nesne olarak kullanarak bunları uygun şekilde sınıflandırılmıştır. Birinci sınıf böyle bir sistem, insan müdahalesi olmadan, dahili sıtma teşhisini sağlayabilir veya insan uzmanlarının iş yükünü azaltmasına ve teşhis doğruluğunu arttırmasına yardımcı olabileceği belirtilmiştir. Algoritma, eritrositleri % 97.31 oranında başarılı bir şekilde lokalize edilmiş ve %92.21 hassasiyet sonuçları ortaya çıkarılmıştır.

Pan ve ark. (2018) çalışmalarında, sıtmanın otomatik tanısı için makine öğrenme teknolojileri kullanımını incelemiştirlerdir. Sıtma ile enfekte olmuş hücrenin doğru sınıflandırılmasına yönelik çalışmalardan bazıları sunulmuştur. İlk olarak, kırmızı kan hücrelerinin (wholeslide) segmentasyonu için kullanılan görüntü işleme yöntemleri açıklanmıştır. Görüntüler derin sinir ağını eğitmek için kullanılmıştır. Ayrıca, derin evrişimsel sinir ağlarının eğitimi ile ilgili uyum sorunu ışığında veri setinin boyutunu önemli ölçüde artırmak için kullanılan veri büyütme yöntemleri anlatılmıştır. Daha sonra, derin evrişimsel sinir ağlarının elde ettiği sınıflandırma doğruluğu, veri kümelerinin çeşitli kombinasyonları ile eğitimi onaylama ve test etme yoluyla karşılaştırılmıştır. Bu veri kümeleri, orijinal veri kümesini ve doğrudan enterpolasyon kullanılarak elde edilerek önemli ölçüde artırılmış veri kümelerini içermektedir. Çalışma sonucunda %95.5 oranında bir sınıflandırma başarısı elde edilmiştir.

Vijayalakshmi (2019) çalışmasında, transfer öğrenme yaklaşımı kullanılarak enfekte olmuş falciparum malaria parazitinin tanımlanması için ağ modeli tanıtılmıştır. Bu önerilen transfer öğrenme yaklaşımı, mevcut Görsel Geometri Grubu (VGG) ağı ve Destek Vektör Makinesi (SVM) birleştirilerek sağlanabilir. Burada, önceden eğitilmiş VGG, uzman öğrenme modeli ve SVM'nin alana özgü öğrenme modeli olarak rolünü kolaylaştırmaktadır. Önceden eğitilmiş VGG katmanlarının ilk 'k' katmanları korunur

ve (n-k) katmanları SVM ile değiştirilir. Önerilen VGG-SVM modelini değerlendirmek için, enfekte olmuş ve enfekte olmamış malaria hastalarının kan smear görüntüleri alınarak ve modern Evrişimsel Sinir Ağı (CNN) modelleriyle karşılaştırılarak bir malaria dijital görüntüsü oluşturulmuştur. Malaria dijital görüntüleri, VGG19-SVM'nin performansını analiz etmek için kullanılmış ve enfekte edilmiş falciparum sıtma parazitinin tanımlanmasında %93.1 sınıflandırma doğruluğu elde edilmiştir. VGG19 ve SVM'nin birleştirilmesi, doğruluk, hassasiyet, özgüllük, ve F-Score gibi tüm performans göstergelerinde mevcut CNN modellerine göre üstünlük göstermiştir. Elde edilen sonuç, özellikle malaria teşhisi olmak üzere tıbbi görüntü analizi alanındaki "transfer öğrenmesi" potansiyelini göstermesi bakımından önemlidir.

Sıtma hastalığı taşıyan kan örneklerine ait veri setini içeren görüntülerin elde edilmesi için, bir dijital kamera ve ışık mikroskobu kullanılmaktadır. Bu işlem, kan örneklerinin dijitalleştirilmesi işlemi olarak ifade edilmektedir. Mikroskobik görünümü yakalamak için mikroskop göz merceğine 25 fps (kare/sn) görüntü yakalama hızına sahip bir dijital kamera yerleştirilmiştir. Yakalanan videoyu ayırmak ve resimler haline getirmek için ise bir video işleme yazılımı kullanılmıştır. Bu dijital mikroskobik görüntülerden üst üste gelmeyen düzgün görünümüleri ayrılır. Elde edilen bu mikroskobik görüntüler daha ileri eğitim ve analizlerde kullanılmak üzere bir sunucu tabanlı bilgisayar sisteminde depolanır Şekil 2.1'de görülmektedir (Vijayalakshmi, 2019).



Şekil 2.1. Tıbbi görüntülerin elde edilmesi (Vijayalakshmi, 2019)

(Akilotu ve ark., 2019) çalışmalarında, sıtma virüsünün bulunduğu kırmızı kan hücreleriyle sağlıklı hücrelerin yer aldığı toplam 27,558 görüntü üzerinde derin öğrenme yöntemleri kullanılmıştır. Bu amaçla, evrişimsel sinir ağlarından AlexNet ve VGGNet modelleri ile sınıflandırma katmanında destek vektör makinaları (SVM)

yönteminin sınıflandırma özelliği birlikte kullanılmıştır. Sonuçta ise AlexNet ile %93.88, VGG19 ile %95.08 ve VGG16 ile %96.02 doğruluk oranı elde edilmiştir.

Konu ile ilgili literatürde yer alan diğer çalışmalar ve elde edilen sonuçlar Çizelge 2.1.'de gösterilmiştir.

Çizelge 2.1. Literatürde yer alan benzer çalışmaların sonuçları

Yazarlar	Veri Seti	Kullanılan Yöntemler	Performans Sonuçları
Vijayalakshmi V., 2019	Mamic image database	VGGNet ve DVM	Doğruluk: %93.1
Rajaraman vd., 2018	Lister Hill National Center for Biomedical Communications (LHNCBC)	ESA	Doğruluk: %98.13
Dong vd., 2017	PEIR-VM dataset	LeNet, GoogLeNet, AlexNet	Doğruluk: %95
Bibin vd., 2015	Malaria dataset	DBN	F-skoru: %89.66 Hassasiyet: %97.6 Özgünlük: %95.92
Liang vd., 2016	Lister Hill National Center for Biomedical Communications (LHNCBC)	16 katmanlı yeni ESA modeli	Doğruluk: %97.37
Hung vd. 2017	100,000 individual cells	Faster R-CNN ve AlexNet	Doğruluk: %98
Var vd., 2015	1428 units of P. Vivax, 1425 pieces of P. ovale, 1446 pp. Falciparum, 1450 pieces of P. malariae and 1440 healthy sample	VGG ve Transfer Öğrenme	Max. Özgünlük: %86
Jeager, 2019	Lister Hill National Center for Biomedical Communications (LHNCBC) [8]	AlexNet, VGGNet, DVM ve Transfer Öğrenme	Doğruluk: %96.02

Literatür incelemesi sonucunda, tıbbi görüntülerin yapay zeka, makine öğrenmesi ve derin öğrenme gibi gelişmiş yöntemlerle incelenmesi hususunda birçok çalışma yapıldığı belirlenmiştir. Bu sayede bilgisayar biliminin tıp alanına oldukça büyük katkıların olduğu değerlendirilmektedir. Özellikle kan örneklerinin etkin ve hızlı bir şekilde incelenmesi ve hastalıkların tespit ve teşhisinde kolaylık sağlanması bu alanda yapılan çalışmaların önemini artırmaktadır.

Bu literatür taramasında, sıtma hastalığı ile ilgili CNN, makine öğrenmesi ve görüntü işleme üzerinde ne tür araştırmalar yapıldığı tespit edilmeye çalışılmıştır. Literatürde, CNN algoritmasından biri olan RAN modelinin sıtma hastalığına ait veri setinde kullanılmadığı görülmüştür. RAN modeli sağladığı avantajlar ile derin öğrenme alanında öne çıkan bir yöntem durumundadır. Sonuç olarak kullanılan algoritmalar ortaya çıkarılmış CNN'in RAN modelinin kullanılmadığı literatürden anlaşılmış ve çalışmamızda bu model tercih edilmiştir. Ayrıca, ulusal kaynaklı RAN modeli temelli çalışma ve araştırmalardaki eksiğin kapatılmasına da katkı sağlayacağı değerlendirilmektedir.

3. MATERYAL VE YÖNTEM


Bu çalışmada, sağlıklı ve hasta bireylerden alınan kan örneklerine ait (sıtma hastalığı) görüntülerinin sınıflandırılması amaçlanmıştır. Bu görüntüler derin öğrenme ağının eğitilmesi ve test edilmesi işlemlerinde kullanılmıştır. Yapılan çalışmada “ileri yönlü beslemeli” (feedforward) derin öğrenme ağ mimarisi ve dikkat mekanizması (attention mechanism) tabanlı bir Evrişimsel Sinir Ağı modeli olan “Artık Dikkat Ağı” (Residual Attention Network-RAN) (Wang ve ark., 2017a) yöntemi, görüntülerdeki özelliklerin saptanması ve görüntülerin sınıflandırılması için kullanılmıştır. Bu algoritmanın tercih edilme sebebi, önceki çalışmalarda sıtma hastalığı için kullanılmamış olmasıdır. Ayrıca diğer CNN yöntemleri (AN, VGG16, ResNet50, InceptionV3, AlexNet) ve SVM ile sonuçlar alınmış, analizler yapılmış ve istatistiksel performans karşılaştırılması yapılmıştır. Böylece, hangi yöntem ve modelin daha etkili sonuçlar verdiği tespit edilmiştir.

Çalışmada, sıtma hastalığına ait görüntülerin incelenmesi ve sınıflandırması için Python yazılımı ve diğer kütüphaneler (TensorFlow, Keras ve Scikit-learn) ile MATLAB kullanılmıştır.


Tez çalışmasında kullanılacak veri setinin büyüklüğünden dolayı, işlem yapılacak bilgisayarın CPU, GPU, RAM vb. donanım özelliklerinin güçlü olması gerekmektedir. Tezde, Intel Core i7-6700HQ işlemcili, 4 GB NVIDIA GeForce GTX 970M ekran kartlı ve 16 GB RAM’lı bir bilgisayar kullanılmıştır.

Tez çalışmasında kullanılan 27,558 adet sıtma hastalığına ait parazitli ve parazitsiz (infected-uninfected) kan örneklerini içeren smear görüntüleri (Arunava, 2019) ve (Tensorflow, 2019)’dan alınmış, ayrıca ABD Ulusal Tıp Kütüphanesi’nin internet sitesinden (Jaeger, 2019) görüntülerin hangi şartlarda, ne şekilde, nasıl ve kaç hastadan alındığı gibi bilgiler temin edilmiştir.

Veri (sıtma hastalığı) setinde yer alan ve sıtma paraziti taşıyan örnek görüntüler Şekil 3.1’de, sıtma paraziti taşımayan örnek görüntüler ise Şekil 3.2’de yer almaktadır.



Şekil 3.1. Sıtma paraziti taşıyan kan örnekleri (Arunava, 2019, Tensorflow, 2019, Jaeger, 2019)



Şekil 3.2. Sıtma paraziti taşımayan kan örnekleri (Arunava, 2019, Tensorflow, 2019, Jaeger, 2019)

Bu örnek sıtma görüntülerinden, 20,658 adet görüntü, derin öğrenme uygulamalarının eğitiminde (train) ve 6,900 adet görüntü de derin öğrenme uygulamalarının test işleminde kullanılmak üzere bölümlere ayrılmıştır.

Tez çalışmasında kullanılacak smear görüntüleri, yarısı parazitli ve yarısı da parazitsiz olarak iki ayrı sınıfa ayrılmış ve çalışmada kolaylık sağlaması açısından 32X32 boyutlarında görüntüler şeklinde modellerde incelenmiştir.

3.1. Sıtma Hastalığı Hakkında Genel Bilgiler

Günümüz dünyasında, iki milyar nüfus sıtma riski altında olup, bu nüfustan her yıl yaklaşık 200 milyon kişi sıtma hastalığına yakalanma ihtimali ile karşı karşıyadır. Bu hastalardan, her yıl iki milyona yakını ise ölümlerle sonuçlanmaktadır. Ölen bu insanların, bir milyonunu beş yaş altı çocuklar oluşturmaktadır. Bu sayılardan da anlaşılacağı üzere, sıtma hastalığı dünyada görülen tüm hastalıklar arasında ölüm nedenleri içinde ilk sıralarda yer almaktadır (Akdur, 2001).

Sıtma, Anofel cinsi dişi sivrisineklerin ısırmasıyla insana bulaşan ve *Plasmodium* türlerinin parazit olarak görüldüğü bir hastalıktır. Plasmodium türüne göre değişen aralıklarla gelen titreme ve ateş nöbetleri ile başlayıp, terleme ile sonlanan ileri nöbetlerle devam etmektedir. Ekonder anemi, splenomegali ve hepatomegali ile karakterize olan ve iç organlarda bir pigmentin birikmesi ile ortaya çıkan sıtma, Paludisma, Remittant, Paludismus ve Marsh Miasma olarak da bilinen bir enfeksiyon hastalığıdır (Unat ve ark., 1995).

Sıtma parazitleri esas olarak karaciğer hücrelerini ve alyuvarlarına yerleşmektedir. İnsan kanı ile beslenen sivrisinekler tarafından ya da paraziti taşıyan hasta insandan sağlam insanlara taşınır ve onları da hastalandırır. Sıtma parazitinin, vivax, malariae, falsiparum ve ovale olmak üzere dört ayrı türü vardır. Bunlardan vivax, üç günde bir nöbet veren bir türdür. Bu türde ölüm oranı en azdır. Türkiye’de yaygın olarak görülen tür bu sıtma türüdür. Malriae dört günde bir gelen nöbetlerle seyreltmekte, Falsiparum’da ise nöbetler belirgin olmamaktadır. Falsiparum türü en

ölümcül sıtma türüdür. Bu tür daha çok Afrika, Uzakdoğu ve Güney Amerika gibi tropik bölgelerde yaygındır. Ovale türü sıtma ise yalnızca Batı Afrika'da görülmektedir (Akdur, 2001).

Sıtma etkeni olan *Plasmodium* parazitlerini, yalnız *Anopheles* türü sivrisineklerin insanlara bulaştırdığı bilinmektedir. Bu sivrisinekler *Plasmodium*'lara geliştirici ve üretici bir biyolojik taşıyıcılık diğer bir ifadeyle vektörlük yaparlar. Anofelin tükürük bezlerinde biriken parazitler daha sonra ısırma sırasında insanın kanına geçerler (Merdivenci, 1984).

Ancak her *Anopheles* türü sıtma etkenlerini bulaştırmazlar. Anofelin insanı ısırma eğilimi, kan emme alışkanlığı, yaşam süresi, *Plasmodium*'ların anofelde yerleşme olasılığı, anofelin etkinliği ve süresi gibi etmenlerin de hastalığın yayılmasında etkisi vardır. Bundan dolayı her bölgede çok sayıda anofel türü bulunsa bile ancak birkaç türü *Plasmodium*'lara vektörlük yaparlar (Merdivenci, 1984).

Türkiye'deki sıtma vektörleri *Anopheles sacharovi*, *Anopheles superpictus* ve daha az rol oynayan *Anopheles maculipennis*'tir. 1977'de sıtma olgularının artmasının nedenlerinin basında *Anopheles sacharovi*'lerin D.D.T. türü tarım ilaçlarına direnç kazanması sonucu hızla üreyerek sıtmayı yeniden yaymaya başlamış olmalarıdır (Okursoy, 2010).

Sıtma hastalığı çoğu Afrika kıtasında bulunan dünya genelindeki 91 ülkede görülebilen yaygın bir enfeksiyon hastalığıdır. Dünya Sağlık Örgütü (DSÖ) 2016 yılında %90'ı Afrika ülkelerinde olmak üzere 216 milyon sıtma vakasının olduğunu ve bunlardan 445 bininin de hastalık sebebiyle hayatını kaybettiğini açıklamıştır. Ülkemiz tarihine de en önemli hastalıklardan birisi olarak geçen sıtma hastalığıyla mücadele Osmanlı İmparatorluğu döneminde başlanmış ve Cumhuriyet Döneminde de artarak devam etmiştir. Uygulanan başarılı mücadele programları sonucunda ise Türkiye'de 2000 yılında 11,378 olan sıtma vakası, 2005 yılında 2,036'ya düşmüştür. Bu doğrultuda sıtma hastalığı ile etkin olarak mücadele edilmesine yönelik 2005 yılından itibaren Sıtma Eliminasyon Programı başlatılmış ve bu alanda büyük başarı sağlanmıştır. Ancak Türkiye'de sıtma etkenini taşıyabilen Anofel türü sivrisineklerin bulunması, son dönemlerde savaşlar sebebiyle yaşanan göçler, ülkenin sıtmanın yayılabileceği subtropikal bölgede yer alması, iklim değişiklikleri dolayısıyla hava sıcaklıklarında yaşanan artışlar ve sıtmanın endemik olduğu ülkeler ile yapılan karşılıklı seyahatlerin artması gibi faktörler nedeniyle sıtma hastalığının bulaşma riski halen devam etmektedir

(Sağlık Bakanlığı, 2019). Bu nedenle de sıtma hastalığının yeniden yaygınlaşmaması amacıyla gereken tedbirler titizlikle devam ettirilmelidir.

3.1.1. Hastalığın tarihçesi

Sıtma hastalığı, tarihte bilinen en eski ve en çok ölüme neden olan hastalıklardan biridir. Bu yüzden tarihte adından sıkça söz edilmektedir. Jeolojik yapılarda görülen sivrisinek fosilleri ve eski kavimlere ait duvar yazılarında sıtma hastalığının çağlar ötesi varlığı gözlenmiştir. Sıtma hastalığı, dünya tarihine diğer enfeksiyonlara oranla daha fazla damgasını vurmuş bir hastalıktır. Savaşların sonuçlarına, nüfusların değişmesine ve dünyadaki farklı ülkelerin büyümelerine veya küçülmelerine büyük etki etmiştir (Lynne ve Bruckner, 1997).

Sıtma insanlık tarihinin ilk yazılı kayıtlarında yer alan hastalıklardan biridir. Hintli ve Mısırlı doktorlar, yaklaşık 3500 yıl kadar önce sıtmanın belirtilerini tanımlamışlardır. Mısırlılılar sivrisineklerin hastalıkla olan ilişkisini ilk kez ortaya koyan kişiler olmuşlardır (Blanc ve ark., 1992).

Tarihte sıtmanın Mezopotamya, Eti ve Grek uygarlıklarını zayıflatan en önemli etmen olduğu kabul edilmektedir. Giovanni Maria Lancisi, 1707'de sivrisineklerin sokarak, kötü etkenleri kanımıza enjekte ederek sıtmayı bulaştırdığını belirlemiştir. Jacquier ise, 1743'te sıtma için "malaria" (kötü hava) adını kullanmış ve ateşli hastalıkların bataklıklardan yükselen kötü havanın solunması ile oluştuğunu ileri sürmüştür (Özcel, 1999).

1880 yılında Laveran adında bir Fransız doktor, ilk defa ışık mikroskobu kullanarak sıtmalı hastaların kan örneklerindeki parazitleri saptamıştır (Fleischer, 2004). Francis Delafield, 1872'de sıtmada en sabit bulgunun kanda kara veya kırmızı ufak boya parçacıklarının bulunması olduğunu belirlemiştir. Dimitri Romanowsky 1891 yılında, eozin Y ve metilen mavisini karıştırarak infekte eritrositlerde parazitin sitoplazmasının mavi ve kromatin yapısının kırmızı renkte boyandığını gözlemlemiştir. Daha sonra Marchiafava ve Agelo Celi, bahse konu parazite *Plasmodium* adını vermişlerdir (Özcel, 1999).

Dünyanın büyük bir kısmında görülmekte olan sıtma hastalığı, insanlık tarihi boyunca birçok medeniyetin sona ermesine neden olmuştur. Sıtma hastalığı ülkemiz coğrafyasında da eski medeniyetlerden günümüze kadar her zaman önemli bir hastalık olarak görülmüştür. Yoğun mücadele programlarına rağmen; 1929-44, 1976-86 ve

1993-98 yılları arasında ülkemizde üç büyük sıtma salgını gözlenmiştir (Saygı, 1998; Akdur, 2001; Altıntaş, 2002).

3.1.2. Hastalığın patolojisi

Sıtmada patojenik etkilerin enfekte olan veya olmayan eritrositlerin hemoliziyle ilişkili olarak parazitten salınan metabolitler ve bu antijenik materyallere konağın immünolojik yanıtına ve sıtma pigmentinin oluşumuna doğrudan bağlı olduğu varsayılmalıdır. Ayrıca, *P. falciparum* sıtmasında sitoaderens olayı ile lokal olarak doku perforasyonunun bozulması söz konusudur. Enfekte eritrositlerin parçalanmasıyla sıtmada nöbetler görülmeye başlanmaktadır. Bu sırada hücre yıkımında artma, dalakta ve karaciğerde büyüme görülmektedir. Hemozoin pigmenti, vücutta demiri azalttığı için anemiye de neden olur (Markell ve ark., 1999).

Sıtma, organları değişik biçimde etkilemektedir. *P.falciparum* enfeksiyonunun başlangıcına konjestiyona bağlı olarak büyüyen, mikro sirkülasyon alanları parazitli eritrositlerle dolu olan ve ağırlığı 1000 grama kadar çıkabilen dalakta büyüme ve trabeküller de sertleşme olmaktadır. Hemozin cisimcikleri ile dolan hücreler dalağa siyahımsı görünüm vermekte ve makrofajlar içinde fagosite edilmiş parazitler görülmektedir (Aktuglu, 1992).

Hastalık uzadıkça karaciğer de büyümekte ve rengi de koyulaşmaktadır. Kupffer hücreleri parazit yıkım ürünleri ve hemozin cisimcikleri ile doludur. Bu pigment, kemik iliği, lenf bezi, derialtı dokusu ve akciğer gibi organlardaki fagositer hücrelerin içinde de saptanabilmektedir. Hastalık sırasında böbrekler de normalden büyüktür (Aktuglu, 1992; Ledingham ve Warrel, 2000).

3.1.3. Hastalığın semptomları

Hastalığa yakalanan kişilerin yakınmaları, sıtmanın türüne göre farklılıklar gösterir. Tüm türlerde ortak olan belirtiler; yüksek ateş, üşüme - titreme ve bol terdir. Bu belirtilere kusma ve ishal eşlik edebilir. Parazitin karaciğer hücrelerinde üremesi sırasında, genellikle, hiçbir belirti yoktur. Kuluçka süresinin sonunda ve parazitin karaciğerden kana döküldüğü sırada, iki ile dört gün kadar süren, bir prodromal dönem geçirilir. Bu dönemde, tipik sıtma belirti ve nöbetleri yoktur. Ateş düzensiz aralıklarla

yükselir düşer veya devamlıdır. Hastada halsizlik, kırıklık, iştahsızlık, baş, kas ve eklem ağrıları gibi belirtiler görülür (Saygı, 1998; Altıntaş, 2002).

Prodramal dönemin sonunda ve parazitin alyuvarlara yerleşmesi tamamlandıktan sonra, düzenli olarak yineleyen nöbetler dönemi başlar. Parazit türüne göre, üç ya da dört günde bir tekrarlayan klasik sıtma nöbetleri, dört evreden oluşur (Akdur, 2001).

1) *Üşüme - Titreme Evresi*: Hasta üşür ve titrer, dişleri birbirine vurur. Bu evrede, cilt soluk, parmaklar ve dudaklar morarmıştır. Nabız zayıflar, tansiyon düşer. Baş ağrısı, mide bulantısı yaygın görülen belirtilerdendir. Nöbetin bu evresi yarım saat ile iki saat arası sürer.

2) *Yüksek Ateş Evresi*: Hastanın üşümesi titremesi kaybolur ve ateş 40-41 dereceye yükselir. Buna bağlı olarak; hastanın yüzü kırmızı, solunumu sık, nabızı hızlı ve tansiyonu yüksektir. Nöbetin bu evresi, iki ile yedi saat arasında sürer.

3) *Terleme Evresi*: Yüksek ateş evresi sonunda, hastanın önce başından başlayıp sonra tüm vücudunu kaplayan yoğun bir terleme görülür. Zamanla ateş düşer ve buna bağlı belirtiler kaybolur. Hasta rahatlar ve çoğunlukla uykuya dalar. Bu evre, iki ile dört saat arasında sürer. Evre sonunda ateş tamamen normale döner.

4) *Sıtma nöbetleri*: *P.vivax*, *P.ovale* ve *P.falciparum*'da her 48 saatte bir görülür. *P.malariae*'da ise 72 saatte bir görülmektedir. Hastaların fiziki muayenesinde, yüksek ateş, güçsüzlük, aşırı terleme, hafif sarılık, hepatomegali, splenomegali gibi bulguları saptanabilmektedir (Özcel, 2007).


3.1.4. Hastalığın tanısı

Sıtma hastalığının teşhisinde pek çok teşhis yöntemi olmasının yanında, genel olarak yöntemler doğrudan ve dolaylı teşhis yöntemleri olarak sınıflandırılmaktadır.

3.1.4.1. Doğrudan tanı yöntemleri

Önemli klinik semptomlardan ölüme kadar uzanan etkileri olan sıtmanın tanısında kullanılan en iyi, en ucuz ve en hızlı yöntem direk mikroskopidir. Mikroskopide eritrositler içerisindeki parazitlerin görülmesiyle tanı konulur. Tanıda en yaygın olarak kullanılan yöntemler kalın damla ve ince yayma preparatların hazırlanmasıdır. Preparatlar hazırlanırken Wright, Giemsa veya Wright-Giemsa boyama yöntemleri kullanılmaktadır. Hazırlanan preparatlarda *Plasmodium*'ların trofozoit,

sizont ve gametosit şekilleri görülerek tanı konulabilir. Bu tanı yönteminde kullanılan örnek bir resim Şekil 3.3'te görülmektedir (Saygı, 1998; Altıntaş, 2002).



Şekil 3.3. Eritrositler içerisinde görülen trofozoitler(Dobaño ve ark., 2019)

3.1.4.2. Dolaylı tanı yöntemleri


Bu yöntemde IFAT, IHA, Immunopresipitasyon ve ELISA gibi testler yapılmakta ve eritrositik evredeki enfeksiyonlara karşı oluşan antikorlar tespit edilmektedir. Ayrıca moleküler biyoloji tanı yöntemleri, polimeraz zincir reaksiyonu (PCR), Kantitatif Buffy Coat Yöntemi (QBC), Hızlı Tanı Testleri ile de hastalara sıtma teşhisi konulabilmektedir (Kocaçiftçi, 2008).

Hızlı tanı amacıyla kullanılan test çeşitleri ise; OptiMAL testi, ICT Malaria testi, MAKROmed Rapid Malaria testi ve ParaSight-F testidir (Taşkın, 2010).

3.2. Derin Öğrenme

Donanımdaki gelişmeler ve büyük verilerin ortaya çıkmasıyla birlikte gelişmiş bilgisayar teknolojileri giderek daha popüler hale gelmiştir. Kaynakları daha verimli kullanmak isteyen şirketler son zamanlarda yapay zeka ve makine öğrenmesi gibi konulara ağırlık vermişlerdir. İstatistik, matematik ve bilgisayar bilimlerinin biraraya gelmesiyle ortaya çıkan yapay zeka ve makine öğrenmesi teknolojileri ile, kendi davranışlarını geliştiren algoritmalar oluşturmaya yönelik incelemeler yapılmaktadır. Önceleri sadece bu alanda yapay zeka sistemlerinin geliştirilmesine çalışılmaktaydı. Ancak zamanla makine öğrenme ve derin öğrenme algoritmaları geliştirilmeye odaklanılmıştır. Makine öğrenme yöntemlerinin eksikliklerini gidermek üzere derin

öğrenme yöntemleri ortaya çıkmıştır. Bu anlamda derin öğrenme heyecan verici bilim alanlarından biri olarak hızla gelişim göstermektedir. Derin öğrenme gelişen teknoloji ile birlikte özellikle kendi kendini süren arabalar, sosyal medya platformlarında görüntü tanıma ve metnin bir dilden diğerine çevrilmesi gibi sistemlerde kullanılmaktadır. Derin öğrenme, geleneksel makine öğrenme algoritmalarının sıklıkla yapamayacağı yüksek ve düşük veri özetlerini açıklayan ve öğrenen algoritmalar oluşturmak için kullanılan bir alt alandır. Derin öğrenme alanında geliştirilen bilgisayar algoritmaları, insan beynindeki nöronlar ve bunların uyarıcıları arasındaki ilişkideki benzerliklere sahiptir. Bu algoritma kümeleri “denetimli” ve “denetimsiz” öğrenmede kullanılabilir. Derin öğrenme algoritmalarının çoğunluğu yapay sinir ağları kavramına dayanmaktadır. Bu tür algoritmaların eğitimi günümüz dünyasında çokça kullanılmaktadır. Ek verilerle, derin öğrenme modellerinin performansı artmaya devam etmektedir. Bu yöntemlerin performans karşılaştırması Şekil 3.4’te gösterilmiştir (Goyal ve ark., 2018).




Şekil 3.4. Veri işleme tekniklerinin karşılaştırılması (Goyal ve ark., 2018)

Derin öğrenme terimi, yapay sinir ağı mimarisinin derinliğini ve yapay sinir ağı aracılığıyla öğrenmeyi ifade eder. Derin sinir ağları, görüntü verileri, metin verileri, ses veya video verileri gibi yapılardan özellik öğrenme yeteneğine sahiptir. Yapay bir sinir ağı ve derin öğrenme modellerinde benzer yapılar vardır. Ancak herhangi bir derin sinir ağını sıradan bir yapay sinir ağından ayıran şey, derin sinir ağı katmanlarının yapay sinir ağı katmanlarından daha çok olması ve daha güvenilir ve doğru sonuçlar alınmasıdır. Böylece hatalar küçülür ve daha etkili sonuçlar elde edilir (Goyal ve ark., 2018).

Evrişimli sinir ağları (Convolutional Neural Networks - CNN), nesnelerin tanınması sırasında insan beyнинin görsel korteksinin nasıl çalıştığından ilham alan bir model ailesidir. CNN’lerin gelişimi, Yann LeCun ve meslektaşlarının el yazısı rakamları içeren görüntüleri sınıflandırmak için “Bir Geri Yayılım Ağı ile El Yazısı

Rakam Tanıma” adlı yeni bir sinir ağı mimarisi önerdiği 1990’lı yıllarda ortaya atılmıştır. CNN’ler resim sınıflandırmasında gösterdiği üstün performans nedeniyle çok dikkat çekmiştir. Makine öğrenmesi ve bilgisayarlı görüntü işleme uygulamalarında da büyük gelişmelere yol açmıştır (Raschka ve Mirjalili, 2017).

Derin öğrenmede kullanılan sinir ağı sistemi, basitçe çoklu gizli katmanlara sahip ileri beslemeli bir sinir ağıdır. Ağda birçok katman olduğundan, ağın “derin” olduğu ifade edilir. Bir sinir ağının ardındaki temel prensip, ilk kez 1950’lerde Frank Rosenblatt tarafından geliştirilen yapay nöron ya da algılayıcı öğeler topluluğudur. Bunlar, x_1, x_2, \dots, x_N , şeklindeki girişleri algılar ve eğer aktivasyon değerinden büyükse bir çıkış üretirler. Nöronun, aktivasyon değeri aşıldığında diğer bir ifadeyle bir fonksiyonu olarak davrandığında “aktive olduğu” kabul edilir. Aktive olan nöron, sinyali bağlı diğer nöronlara iletir. Böylece diğer nöronlar da aktive olacak ve kademeli bir etki ortaya çıkacaktır. Derin öğrenmede kullanılan temsili bir nöron gösterimi Şekil 3.5’te yer almaktadır (Goyal ve ark., 2018).




Şekil 3.5. Örnek bir nöron modeli (Goyal ve ark., 2018)

Hesaplamlarda tüm girdiler aynı değere sahip olmadığından, modelin bazı girdilere daha fazla önem vermesini sağlamak üzere girdilerin her birine bir ağırlık (weight) değeri eklenmektedir. Sonuç değeri ise, Eğer ağırlık toplamı aktivasyon değerinden büyükse “1”, aksi durumda ise “0” olmaktadır. Buna ait matematiksel model Denklem 3.1’de gösterilmiştir:

$$\text{Çıkış (output)} = \sum_j W_n X_n + \text{Bias} \quad (3.1)$$

Denklem ile diğer nöronlardan gelen x_i bilgileri ağırlıklandırılır ve toplama işlemine tabi tutulur. Bu bilgiler daha sonra çıkış birimine gönderilir. Şekil 3.6’da, basit bir sinir ağı diyagram modeli gösterilmektedir. Bu modelde girdiler ve çıktılar arasındaki

bağlantıyı gösteren basit bir doğrusal regresyon temsil edilmektedir. Ancak modelde ağırlıklar (*weights*) veya önyargılar (*bias*) yer almamaktadır (Zhang ve ark., 2019).




Şekil 3.6. Örnek bir sinir ağı modeli (Zhang ve ark., 2019)

Şekil 3.6'daki modelde girişler x_1, x_2, \dots, x_d şeklindedir. Bazen giriş sayısı özellik sayısı olarak da adlandırılır. Modelde sadece tek bir nöron olduğu için, model; tek bir nörondan oluşan sinir ağı olarak düşünülebilir. Modeldeki tüm girişler bir çıkışa bağlı olduğundan, bu katman tam bağlı bir katmanın örneği olarak kabul edilebilir.

3.2.1. Derin öğrenme yöntemleri

3.2.1.1 Evrişimsel sinir ağı yöntemi (convolutional neural networks)

Evrişimsel Sinir Ağları (convolutional neural networks - CNN) bilgisayarla görme ve görüntü işlemede en sık kullanılan derin öğrenme modellerindedir. Hayvansal görsel korteksinin yapısı taklit edilerek tasarlanmıştır. Genel olarak, CNN'ler üç boyutta düzenlenmiş nöronlara sahiptir. Bu boyutlar, genişlik, yükseklik ve derinliktir. CNN mimarisinde belirli bir katmandaki nöronlar sadece önceki katmanın küçük bir bölgesine bağlanır. CNN mimarisinin katman (layer) temelli çalışma yapısı Şekil 3.7'de gösterilmiştir (Beysolow II, 2017).



Şekil 3.7. Convolutional Neural Networks (CNN) katman yapısı (Peng ve ark., 2017)

Evrişimli sinir ağıları (CNN), bir veri seti çıktısının hesaplanmasında kullanılan çoklu katmanlara sahiptir. Modelin gelişimi, araştırmacılar Hubel ve Wiesel'in hayvan görsel korteksini modellediği 1950'li yıllara dayanmaktadır. 1968 yılında yayınladıkları bir makalede, üzerinde çalıştıkları maymun ve kedilerin beyinlerinde bulunan hem basit hem de karmaşık hücreleri tanımlayan bulgularını tartışmışlardır. CNN mimarisinden görüntü tanıma ve sınıflandırmanın dışında, doğal dil işleme ve pekiştirici öğrenme alanları gibi diğer önemli uygulamalarda da yararlanılmaktadır.

CNN yöntemindeki her katmanın girdileri, önceki katmanın bir alt nöron kümesidir. Bu işlem, öğrenilen alt küme nöronlarının mümkün olan en iyi yanıtı üretmesini sağlamaktadır. CNN mimarisinde kullanılan en önemli veri seti özellik olarak adlandırılmaktadır. Diğer bir ifadeyle özellikler, görüntünün farklı bölümlerine ait bilgileri içermektedir. Özellikler, CNN'deki katman filtresinin görüntüye ait bölümünü analiz ettiği ve karşılaştırdığı veri setleridir. Böylece analiz edilen görüntünün ne kadarının incelenmekte olan özelliğe benzer olduğu belirlenebilmektedir. Yeterli eğitim verisine sahip olduğunda ise bu özelliklerin bir sınıfı diğerinden ayırt etmeye yardımcı olacak kadar belirgin olduğu tespit edilmiştir. Örneğin, aşağıdaki X ve O harflerini temsil eden Şekil 3.8'deki resim incelendiğinde, herbir harfe ait resim veri setinin, kendine has bir özellik haritasının bulunduğu görülmektedir.



Şekil 3.8. O ve X harflerini temsil eden resim görüntüsü (Beysolow II, 2017)

Şekil 3.11'deki, X ve O harflerini farklı kategorilere ayırmak diğer bir ifadeyle sınıflandırmak için, bunların ayırt edici faktörlerinin belirlenmesi gerekmektedir. Buna göre; O'nun merkezini boş olması ve X'in merkezinde iki kesişen çizginin bulunması ayırt edici bir özelliktir. Bu ayırt edici özellikler görselleştirildiğinde Şekil 3.9 ve Şekil 3.10'daki özellik haritaları elde edilmektedir.



Şekil 3.9. “X” harfinin özellik haritası



Şekil 3.10. “O” harfinin özellik haritası

Bu özellik verileri genellikle siyah ve beyaz için sırasıyla 1 ve 0 olan bir 2 boyutlu (2B) matris olarak temsil edilmektedir (Çizelge 3.1).


Çizelge 3.1. X harfini temsil eden matris bilgisi

1	1	0	0	0	0	1	1
1	1	1	0	0	1	1	1
0	1	1	1	1	1	1	0
0	0	1	1	1	1	0	0
0	0	1	1	1	1	0	0
0	1	1	1	1	1	1	0
1	1	1	0	0	1	1	1
1	1	0	0	0	0	1	1

Evrişimli sinir ağları, görüntü tanıma ve el yazısı tanıma için iyi uyarlanmıştır. Yapıları, görüntünün bir penceresini veya bölümünü örneklemeye, özelliklerini saptamaya ve sonra bir gösterim oluşturmak için özellikleri kullanmaya dayanır. Bu ifadede açıkça görüldüğü gibi, bu birkaç katman kullanımına yol açmaktadır, dolayısıyla bu modeller ilk derin öğrenme modelleridir.

Resimlerdeki belirgin özellikleri başarılı bir şekilde çıkarmak, makine öğrenmesi algoritmalarının performansını artırmaktadır. Yapay sinir ağları, ham verilerden belirli bir görev için en faydalı özellikleri otomatik olarak öğrenebilir. Bu nedenle, sinir ağını bir özellik çıkarma motoru olarak kabul etmek yaygındır. Örneğin, resim bilgisi içeren

görüntülerde, resmin içinde yer alan nesnenin kenarları ve renkleri gibi düşük düzey özellikleri, üst düzey özellikler oluşturmak için önceki katmanlardan çıkarılarak bir araya getirilir. Şekil 3.11’de, CNN yöntemiyle resmin özellik bilgilerinin çıkarılması amacıyla piksel bilgilerinin analizi gösterilmektedir (Raschka ve Mirjalili, 2017).



Şekil 3.11. CNN ile özellik haritasının çıkarılması (Raschka ve Mirjalili, 2017)

Temelde bu piksel verisine ilişkin, yakındaki piksellerin birbirinden uzakta olan piksellere nazaran daha kuvvetli ilişki içinde olduğu düşünülmektedir. Bu teknik CNN yönteminde genellikle çok iyi performans gösterir. Elde edilen özellik verileri sinir ağında ağırlık (weights) bilgisi olarak kullanılmaktadır (Raschka ve Mirjalili, 2017).


3.2.1.1.1. Evrimsel sinir ağı mimarisinin bileşenleri

CNN mimarisi arka arkaya gelen birçok katmandan oluşan bir sistemler bütünüdür. Tipik olarak, CNN’ler, sonunda bir veya daha fazla tamamen bağlanmış (Fully Connected Layer - FC) katman yer almaktadır. Tamamen bağlanmış katmanlar, esasen her giriş biriminin her bir ağırlık birimine bağlı olduğu çok katmanlı bir algılayıcıdır. Genelde havuzlama katmanları olarak bilinen alt örnekleme katmanlarının ise öğrenilebilen parametreleri yoktur. Bu katmanlar sadece modeldeki veri sayılarının azaltılması amacıyla kullanılmaktadır. Örneğin, havuz katmanlarında ağırlık (*weights*) veya yanlılık (*bias*) yoktur. Bununla birlikte, birbirine bağlı katmanlar ağırlık ve yanlılık değerlerine sahiptir (Raschka ve Mirjalili, 2017). CNN mimarisinde kullanılan temel katmanlar ve özellikleri aşağıda açıklanmıştır.

Evrşim katmanı (convolutional layer)

Bu katman, CNN modelindeki temel hesaplamaların gerçekleştiği yerdir. Bu nedenle, giriş olarak kullanılan bir görüntü verisinin içinden geçtiği ilk katmandır. Bu katmanda resmin her bir bölümünü tarayan filtreler bulunmaktadır. Her filtre, yükseklik ve genişlik olarak belirlenen matris yapısında resim kesitinin analizini yapmaktadır. Her bir evrşim katmanının sonucunda, resme ait temel özellikler belirlenir ve veri setinin boyutu küçültülerek bir sonraki katmana aktarılır.

Bu katmandaki giriş verileri vektör girişi ya da “sinyal” olarak adlandırılır. Hesaplama kullanılan matris yapısı ise filtre veya “çekirdek (*kernel*)” olarak adlandırılır (Raschka ve Mirjalili, 2017).



Şekil 3.12. Evrşimsssel matris katmanında hesaplama işlemi (Vasilev ve ark., 2019)

Şekil 3.12’de, evrşim katmanında matris yapısı kullanılarak yapılan hesaplama görülmektedir. Burada 4x4’lük matris giriş ve 2x2’lük matris ise filtre olarak kullanılmıştır. Katman çıkışında ise, 3x3’lük bir evrşimsel matris sonucu elde edilmiştir. Evrşimsel matris filtresi ile yapılan matematiksel hesaplama aşağıda gösterilmiştir:

$$(1 \times 0.1) + (2 \times 0.2) + (5 \times 0.3) + (6 \times 0.4) = 4.4$$

$$(2 \times 0.1) + (3 \times 0.2) + (6 \times 0.3) + (7 \times 0.4) = 5.4$$


Bu işlem resmin tamamı hesaplanancaya kadar devam etmektedir.

Havuzlama katmanı (pooling layer)

Ardışık evrşim katmanlarının arasına havuzlama katmanı (pooling layer) olarak adlandırılan bir katman yerleştirmek yaygın bir uygulamadır. Havuzlama katmanı, evrşim katmanında üretilen özellik haritalarını alır ve bunları bir matriste biriktirir. Bu


katman, veri boyutunu azaltmak için kullanılır. Böylece modelin karmaşıklığı azaltılır ve hesaplama süresi kısalır. CNN modelinde havuzlama işlemi ile resme ait özellik haritasının %75 oranında atılması sağlanır. Havuzlama katmanında iki tür işlem gerçekleştirilebilir. Bunlar, en fazla değeri havuzlama (maksimum pooling) ve ortalama değeri havuzlama (average pooling)'dir (Vasilev ve ark., 2019).

Maksimum havuzlama tercih edilen en popüler yoldur. Bu işlemde, her bir matris elemanının en yüksek aktivasyon değeri dikkate alınır. Şekil 3.13'te, 2x2'lik bir maksimum havuzlama örneği görülmektedir.



Şekil 3.13. Maksimum havuzlama örneği (Vasilev ve ark., 2019)

Ortalama havuzlama işleminde ise her bir matris alanının ortalama değeri hesaplanır ve çıktı olarak dikkate alınır. Şekil 3.14'te ortalama havuzlama örneği yer almaktadır.

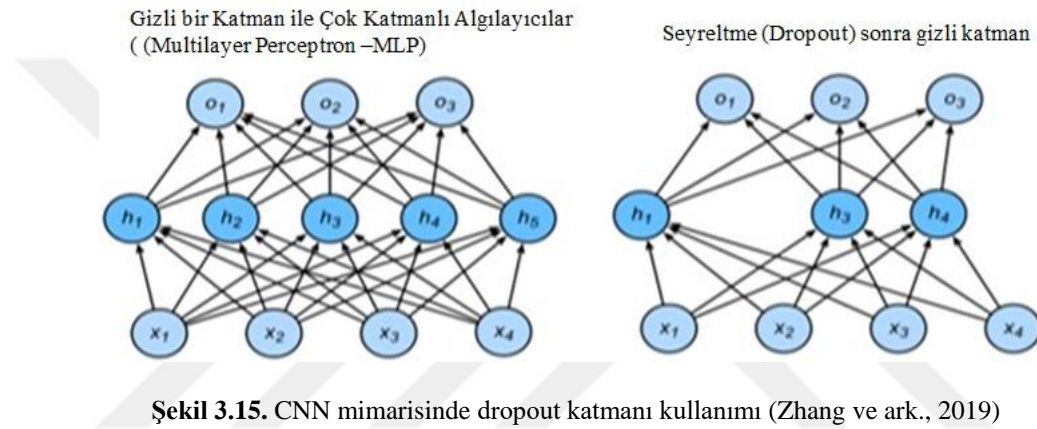


Şekil 3.14. Ortalama havuzlama örneği (Vasilev ve ark., 2019)

Seyreltme katmanı (dropout layer)

CNN modelinde, iyi bir performans elde etmek için katman parametrelerinin iyi ayarlanması gerekir. Bir ağın kapasitesi, öğrenebileceği fonksiyonun karmaşıklık seviyesini ifade eder. Küçük ağlar, göreceli olarak az sayıda parametreye sahiptir. Bu nedenle uyumsuz olmaları muhtemeldir, çünkü karmaşık veri kümelerinin temel yapısını öğrenemediklerinden düşük performansla neden olurlar. Çok büyük ağlarda (Multi Layer Network_MLN) ise, ağın eğitim verilerini ezberlemesinde çok fazla

parametre bulunması modeli yavaşlatabilmektedir. Modeldeki parametre sayılarının azaltılması amacıyla son yıllarda, Seyreltme (dropout) adı verilen bir teknik geliştirilmiştir. Bu katmanın ilave edilmesi ile derin sinir ağlarının inanılmaz derecede iyi çalışan modellere dönüşmesi sağlanmıştır. Bu seyreltme, ağdaki gereksiz verilerin öğrenilmesini engeller. Şekil 3.15'te eğitim aşamasında $p=0.5$ olasılıkla sadeleştirme uygulaması örneği gösterilmektedir. Burada nöronların yarısı rastgele olarak etkin değildir. Bununla birlikte, tahmin sırasında tüm nöronlar bir sonraki katman çekirdeğinin ön aktivasyonlarının hesaplanmasına katkıda bulunacaktır (Raschka ve Mirjalili, 2017).



Tam bağlı katman (fully connected layer)

Bu katmandaki herhangi bir nöron, önceki katmandaki tüm aktivasyon haritalarına bağlanır. Bu katman genellikle, evrimsel, havuzlama ve aktivasyon katmanlarından sonra yerleştirilir. Bu katmana gelen resim bilgisi, orijinal girişlerden önemli ölçüde daha küçük olmaktadır. Tam bağlı katmanın, girişine gelen iki ($2B$) veya üç boyutlu ($3B$) matris verisini bir boyutlu ($1B$) matris verisi haline dönüştürmesini Şekil 3.16'da gösterilmiştir (Zhang ve ark., 2019).

$$\begin{bmatrix} 1 & 3 & 4 \\ 0 & 2 & 1.1 \\ 5 & 2.1 & 0 \end{bmatrix} = [1, 3, 4, 0, 2, 1.1, 5, 2.1, 0]$$

Şekil 3.16. Tam bağlı katman ile elde edilen matris yapısı


Aktivasyon katmanı (activation layers)

Bu katmanda, hesaplanan resim özellik verilerinin belirli özel fonksiyonlar yardımıyla sınıflandırılması yapılmaktadır. En çok kullanılan aktivasyon fonksiyonları; ReLU, softmax, tanh, exponential, linear ve sigmoid'dir.

ReLU Fonksiyonu, Aktivasyon fonksiyonlarından Düzeltilmiş Doğrusal Birim (Rectified Linear Unit - ReLU) fonksiyonu, uygulama basitliği ve eğitimdeki etkinliği nedeniyle en popüler seçenek olarak karşımıza çıkmaktadır. ReLU fonksiyonu basit bir doğrusal olmayan dönüşüm sağlamaktadır. ReLU fonksiyonunda, x girişinin aldığı negatif değerler 0'a eşitlenmekte, pozitif değerler ise korunmaktadır (Denklem 3.2) (Zhang ve ark., 2019).

$$\text{Relu}(x) = \max(x, 0) \quad (3.2)$$


Relu fonksiyonunun kullanılması ile ortaya çıkan sonuca ait grafik Şekil 3.17'de görülmektedir. ReLU fonksiyonuna göre giriş negatif olduğunda, fonksiyonunun türevi 0 ve giriş pozitif olduğunda ise fonksiyonunun türevi 1 çıkışını vermektedir.



Şekil 3.17. ReLU aktivasyon fonksiyonu grafiği (Zhang ve ark., 2019)

Sigmoid Fonksiyonu, Sigmoid fonksiyonu, girişine uygulanan $(-\infty, +\infty)$ değer aralığını $(0, 1)$ aralığına dönüştürür. Bu nedenle, sigmoid fonksiyonu “sıkıştırma” fonksiyonu olarak adlandırılır. Sigmoid fonksiyonunun matematiksel gösterimi Denklem 3.3'te, grafiksel gösterimi ise Şekil 3.18'de gösterilmiştir (Zhang ve ark., 2019).


$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (3.3)$$



Şekil 3.18. Sigmoid aktivasyon fonksiyonu grafiği (Zhang ve ark., 2019)

Tanh Fonksiyonu, Sigmoid fonksiyonu gibi, tanh (Hiperbolik Tangent) aktivasyon fonksiyonu da girişine gelen değerleri sıkıştırılmaktadır. Ancak giriş değerleri burada -1 ile 1 aralığındaki değerlere dönüştürmektedir. Tanh fonksiyonunun matematiksel gösterimi Denklem 3.4'te yer almaktadır (Zhang ve ark., 2019).

$$\text{Tanh}(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (3.4)$$



Şekil 3.19. Tanh aktivasyon fonksiyonu grafiği (Zhang ve ark., 2019)

Şekil 3.19'da görüldüğü üzere, fonksiyonda girdi 0'a yaklaştığında, *tanh fonksiyonunun* doğrusal bir dönüşüme yaklaştığı görülmektedir. Fonksiyonun şekli her ne kadar sigmoid fonksiyonununkine benzese de, *tanh fonksiyonu* koordinat sisteminde orijine göre nokta simetrisini ifade etmektedir.

Softmax Fonksiyonu Softmax fonksiyonu, verileri normalleştirmek için birçok yapay zeka modelinde tercih edilmektedir. Bu fonksiyonla, çıktı niteliğindeki matris yapısının toplamlarının 1 olacak şekilde normalleştirilmesi yapılmaktadır. Örneğin Denklem 3.5'te yer alan matris yapılı (v) vektöründeki altı seçenek arasından olası bir seçim yapılması gerekmektedir. Ancak, (v) değerlerinin toplamı 1'i geçmektedir. Dolayısıyla (v) vektör matrisinin softmax fonksiyonu ile normalleştirilmesi gerekmektedir. Sonuçta softmax fonksiyonu kullanılarak toplamları "1" olan bir matris

dağılımı elde edilmektedir. Karar verme aşamasında, en yüksek değer olan 0.273'ün dolayısıyla da 3'üncü seçeneğin en muhtemel değer olarak seçilmesi gerekmektedir (Rothman ve ark., 2018).

$$v = \begin{bmatrix} 0.0002 \\ 0.2 \\ 0.9 \\ 0.0001 \\ 0.4 \\ 0.6 \end{bmatrix} \rightarrow \text{Softmax} \rightarrow v = \begin{bmatrix} 0.111 \\ 0.135 \\ 0.273 \\ 0.111 \\ 0.165 \\ 0.202 \end{bmatrix} \quad (3.5)$$

Derin öğrenmenin eğitim için hata oranı(error) değeri, nesnelere arasındaki mesafe öklit uzaklığı denklem (3.6) formülü kullanılır(Akküçük, 2011).

$$\text{hata(error)} = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 \dots + (x_n - y_n)^2} \quad (3.6)$$

Derin öğrenmenin eğitim doğruluk (accuracy) oran değeri de, bulunan dahili hesaplamalar (denklem 3.7) formülü kullanılır.

$$\text{Doğruluk(accuracy)} = 1 - \text{hata} \quad (3.7)$$

Çapraz Entropi en yaygın kullanıma sahip olan derin öğrenmenin eğitim için kayıp (*loss*) aşağıda açıklanmaktadır. Bütün sınıfları, olasılıklarına bağlı olarak uzunluk kodu olan, yani $-y \log \hat{y}$, burada \hat{y} , tahmin edilen olasılıklığıdır, daha sonra, gerçekte beklenen uzunluk (y , gerçek olasılıktır), çapraz entropi tarafından verilmektedir (Denklem 3.8) (Murugan, 2018).

$$L = -y \log \hat{y} + (1 - y) \log(1 - \hat{y}) \quad (3.8)$$

Aynı zamanda bir veri kümesinin entropisi ile hesaplanmaktadır (Denklem 3.9)

$$L(y_i, \hat{y}_i^{l+1}) = \frac{1}{t} \sum_1^{i=t} -(y_i) \hat{y}_i^{l+1} + (1 - y_i) \log(1 - \hat{y}_i^{l+1}) \quad (3.9)$$

3.2.1.1.2. Evrişimsel sinir ağı modelleri

Bu tez kapsamında incelenmiş olan evrişimsel sinir ağı modelleri Artık Dikkat Ağı, VGG16, ResNet50, InceptionV3 ve AlexNet'tır.


➤ Artık dikkat ağı (residual attention network) ve bölümleri

Bilgisayarlı görme ve görüntü sınıflandırma problemlerine uygulanan evrişimsel sinir ağları, çok büyük görüntülerde ve model öğrenmenin zor olabileceği durumlarda sorunlar yaşamaktadır. Bu problemin çözümü için, bir tahmin yapmadan önce görüntünün yaklaşık bir izleniminin denklemlenmesi büyük bir görüntünün sadeleştirilmesini sağlamaktadır. Dikkat (attention) işlemi, kod çözücü-kodlayıcı mimarisinin sabit uzunluktaki iç gösteriminden kurtarılması için ortaya atılmış bir fikirdir. Artık dikkat ağı mimarisi (Residual Attention Network – RAN) Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN) ve Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) sistemlerinde yaygın olarak uygulanmaktadır. Bu işlem, LSTM katmanlarına gelen girdi resimlerine “dikkat etmeyi öğretmek” ve bunları çıktı dizisi ile ilişkilendirmek için eğitmek şeklinde gerçekleştirilir. Başka bir ifadeyle, çıkıştaki her öge girişteki belirgin seçici ögelere bağlı olmaktadır. Artık dikkat ağı, modelin hesaplama yükünü arttırır, ancak daha doğru ve daha iyi performans gösteren bir model elde edilir. Resim sınıflandırmada evrişimli sinir ağının en etkili biçimde kullanılması için, sekansa dayalı dikkat mekanizması kullanılarak görüntünün belirli bir bölümüne yoğunlaşmaktadır. Şekil 3.20’de doğru nesneye odaklanmaya ilişkin örnekler gösterilmektedir (Brownlee, 2019).



Şekil 3.20. Resim içerisinde doğru nesneye odaklanma örnekleri (Xu ve ark., 2015)


Girişte kullanılan resimdeki doğru nesneye dikkat sağlanması için iki ayrı yöntem kullanılmaktadır. Bunlar, “soft attention mask” ve “hard attention mask” tır. Soft ve hard attention metodu kullanılarak yapılmış hesaplama ile elde edilen örnek resmin görüntüsü Şekil 3.21’de gösterilmiştir.



Şekil 3.21. Zamana bağlı olarak dikkat bölgesinin hesaplanması (Xu ve ark., 2015)

RAN yöntemi, dikkat mekanizmasını kullanan evrişimli bir sinir ağı mimarisidir. RAN istifleme ile oluşturulmaktadır. Dikkat çekici özellikler üreten modüller kullanılarak, katmanlar derinleştikçe farklı modül değişimlerinden dikkat çekici özellikler üretilebilmektedir. Örneğin, dostça görülen bir insan yüzünde, kırmızı renk bizim dikkatimizi daha çok çekmektedir. Görüntü sınıflandırmadaki son gelişmeler, “çok derin” yapı kullanarak ileriye dönük evrişimli sinir ağlarının eğitime odaklanmaktadır. Dikkat mekanizması ve derin sinir ağındaki son gelişmelerden esinlenerek, “çok derin” yapı içindeki karma dikkat mekanizmalarını benimseyen ve evrimsel bir ağı olan “Artık Dikkat Ağı” yaygınlaşmaya başlamıştır (Wang ve ark., 2017a).

Artık dikkat ağı kullanılarak oluşturulan evrişimsel sinir ağı mimarisi Şekil 3.22’de gösterilmiştir. Şekilde p birimlerin işleme sayısını, t artık birimlerin sayısını, r havuz katmanları arasındaki artık birim sayısını belirtir. Genellikle, $p = 1$, $t = 2$ ve $r = 1$ ’dir.




Şekil 3.22. ImageNet tarafından oluşturulan örnek “artık sinir ağı” mimarisi (Wang ve ark., 2017a)

Maske ve Gövde Bölümleri (mask ve trunk branch): Artık dikkat ağı ile oluşturulan CNN modelinde iki bölüm vardır. Bunlar; maske ve gövde bölümleridir. Gövde bölümü, resim özelliklerinin çıkarımı için kullanılan dikkat modülündeki üst koldur. Maske bölümü ise, aynı boyuttaki maske öğrenme için bottom-up, top-down yapısının kullanıldığı katmandır. Dikkat modülünde kullanılan Denklem 3.10 ile H değeri elde edilmektedir (Wang ve ark., 2017a).

$$H_{i,c}(x) = M_{i,c}(x) * T_{i,c}(x) \quad (3.10)$$

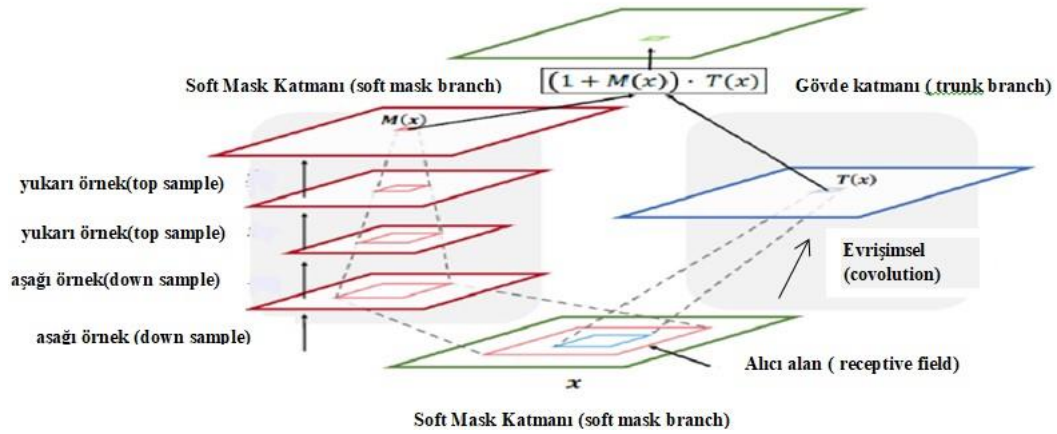
Denklemden; i değeri, resim özelliklerine göre değişiklik göstermektedir. Denklemden c değeri ise, 1'den başlayarak artan resim kanal numarasıdır.

Şekil 3.21'te gösterildiği gibi, sıcak hava balon görüntülerinde, alt katmandan gelen mavi renk özellikleri, arka planı ortadan kaldırmak için karşılık gelen gökyüzü maskesine sahipken, üst katmandan gelen nesne özellikleri resimdeki balon maskesi tarafından rafine edilir. Bu şekilde, karmaşık görüntülerdeki nesnelere odaklanan dikkat mekanizması yavaş yavaş artırılabilir.



Şekil 3.21. Dikkat ağı modeli kullanılarak oluşturulan örnek görüntü (Wang ve ark., 2017a)

Soft Mask Katmanı (soft mask branch): Şekil 3.22'de görüldüğü üzere soft mask katmanında bottom-up ve top-down temelli bir evrişim yapısı kullanılır. Artık değerlerinin artırılması için birkaç kez maksimum havuzlama gerçekleştirilir. Daha sonra, her bir giriş özelliğini belirlemek için simetrik bir yukarıdan-aşağıya (bottom-up ve top-down) mimarisi kullanılır. Doğrusal bir enterpolasyon, Artık değerlerin sonraki çıkışlarını hesaplamak için kullanılır. Son olarak bir sigmoid katmanı ile 1×1 'lik evrişim işlemi uygulanarak çıkış normalleştirilir.



Şekil 3.22. Dikkat ağı modelinde kullanılan soft mask katmanı (Wang ve ark., 2017a)


Örnek bir artık dikkat ağı modeli Çizelge 3.2’de gösterilmiştir. Bu yapı 3 aşamadan oluşmakta ve aktivasyon öncesi ResNet modeline benzemektedir. Modelin her bir aşamasında eşit sayıda Dikkat Modülü yer almaktadır. Ayrıca, modelin her aşamasına iki Artık Birim (Residual Unit) eklenmiştir.

Çizelge 3.2. Örnek bir dikkat ağı model mimarisi

Katmanlar	Çıkış Boyutu	Dikkat-56	Dikkat-92
Conv 1	112 x 112	7 x 7, 64,	2 adım
Maksimum Havuzlama (mask poling)	56 x 56	3 x 3, 2 adım	
Artık Birim(Residual unit)	56 x 56	$\begin{pmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{pmatrix} \times 1$	
Dikkat Modeli(Attention Module)	56 x 56	Dikkat x 1	Dikkat x 1
Artık Birim(Residual unit)	28 x 28	$\begin{pmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{pmatrix} \times 1$	
Dikkat Modeli(Attention Module)	28 x 28	Dikkat x 1	Dikkat x 2
Artık Birim(Residual unit)	14 x 14	$\begin{pmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{pmatrix} \times 1$	
Dikkat Modeli(Attention Module)	14 x 14	Dikkat x 1	Dikkat x 3
Artık Birim(Residual unit)	7 x 7	$\begin{pmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{pmatrix} \times 1$	
Ortalama Havuzlama(Average poling)	1 x 1	7 x 7, 1 adım	
Tam Bağlı Katman.Softmax			1000

➤ VGG16 Modeli

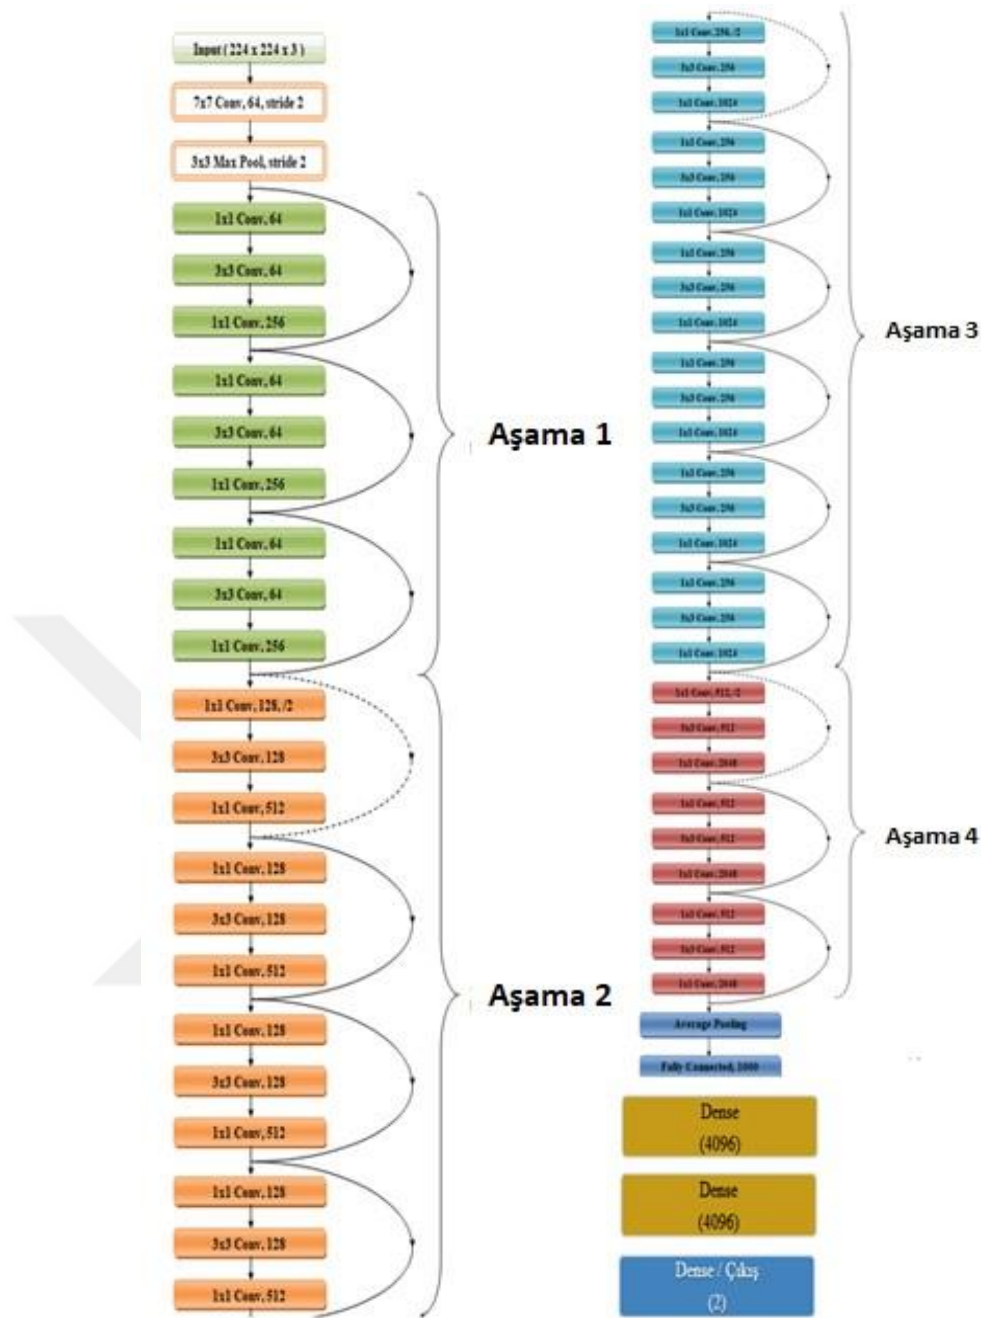
VGG16, Oxford Üniversitesi'nden Simonyan.K ve Zisserman. A tarafından yazılan “Very Deep Convolutional Networks for Large-Scale Image Recognition” isimli makaledeki Evrişimsel Sinir Ağı modelidir. Model, 1000 sınıfa ait 14 milyondan fazla görüntünün veri seti olan ImageNet'te%92.7'lik ilk 5 test doğruluğunu elde etmiştir. ILSVRC (ImageNet Large Scale Visual Recognition Challenge) -2014'te sunulan ünlü modellerden birisidir. Büyük çekirdek boyutlu filtreleri (sırasıyla birinci ve ikinci evrimli katmanda sırasıyla 11 ve 5) birbiri ardına birden fazla 3x3 çekirdek boyutlu filtreyle değiştirerek, AlexNet üzerinde iyileştirme yapar. VGG16 uzun süre eğitilmiştir ve NVIDIA Titan Black GPU'ları kullanılmaktadır. VGG16 temel yapısı Şekil 3.23'te gösterilmiştir (Simonyan ve Zisserman, 2014).



Şekil 3.23. VGG16 modelinde kullanılan soft mask katmanı(Simonyan ve Zisserman, 2014)

➤ ResNet-50 Modeli

ResNet-50, ImageNet veritabanından bir milyondan fazla görüntü üzerinde eğitilmiş bir Evrişimsel Sinir Ağıdır. Ağ, 50 katman derinliğindedir ve görüntüleri 1000 nesne kategorisinde sınıflandırabilir. Bu sonuç, ILSVRC 2015 sınıflandırma görevinde birincilik kazanmıştır (Alom ve ark., 2018). ResNet birçok farklı katman ile geliştirilmiştir; 34, 50, 101, 152 ve hatta 1202. Popüler ResNet50, ağın sonunda, 49 evrişim katmanı ve 1 tamamen bağlı katman içermektedir (Şekil 3.24).




Şekil 3.24. ResNet50 modeli (Alom ve ark., 2018)

➤ InceptionV3 Modeli

InceptionV3, ImageNet veritabanından bir milyondan fazla görüntü üzerinde eğitilmiş, evrişimli bir sinir ağı modelidir. InceptionV3 modeli 48 katmanlı bir yapıya sahiptir. Kendisine verilen görüntüleri 1000 ayrı nesne olarak sınıflandırabilmektedir (Schulte ve ark., 2019). Çalışmada çıkış katmanına yapılan ilavelerle InceptionV3 modeli iki ayrı resmi sınıflandırabilecek şekilde geliştirilmiştir. Modelin resim giriş boyutu orijinalinde 299x299 olmasına karşın çalışma için model girişi 128x128

boyutlarına ayarlanmıştır. InceptionV3 modelinin mimari yapısı Şekil 3.25'te gösterilmiştir.




Şekil 3.25. InceptionV3 modeli (Alom ve ark., 2018)

➤ AlexNet Modeli

AlexNet, 2010 yılında ImageNet tarafından derin öğrenme alanında yapılan (Large-Scale Visual Recognition Challenge ILSVRC) bir modeldir. Model her birinde yaklaşık 1000 resim olan 1000 ayrı kategorideki toplam 1,2 milyon eğitim görüntüsü, 50.000 doğrulama görüntüsü ve 150.000 test görüntüsünden oluşan bir kütüphane ile eğitilmiştir (Alom ve ark., 2018).

AlexNet mimarisi sekiz katmandan oluşmaktadır. Bunlar, beş evrişim katmanı (conv. layer) ve üç tam bağlantılı katmandır. AlexNet modeli, ilk CNN modellerinden olmasına rağmen, onu diğerlerinden ayıran ve evrişimli sinir ağlarına yeni yaklaşımlar getiren bazı gelişmiş özellikleri bulunmaktadır. Bunlardan birincisi AlexNet'in, o dönemde standart olarak kullanılan "*tanh*" fonksiyonu yerine "*ReLU*" kullanmasıdır. *ReLU* eğitim zamanını kısaltarak avantaj sağlamaktadır. *ReLU* kullanan bir CNN modeli, CIFAR-10 veri kümesinde *tanh* kullanan bir modelden altı kat daha hızlı sonuç vermektedir. AlexNet, model nöronlarının yarısını bir GPU'da, diğer yarısını başka bir GPU'da çalıştırarak çoklu GPU eğitimine izin vermektedir. Böylece, daha büyük modeller eğitilebilmekte ve eğitim süresi de kısalmaktadır. Yine, AlexNet'in Seyreltme (Dropout) katmanı sayesinde modelin yakınsaması için gerekli eğitim süresi kısalmaktadır (Wei, 2019). AlexNet mimarisi Şekil 3.26'de görülmektedir.




Şekil 3.26. AlexNet modeli (Alom ve ark., 2018)

3.2.1.2. Tekrarlayan sinir ağları (recurrent neural network-RNN)


Tekrarlayan Sinir Ağları (RNN) etkili bir CNN modeli olup, hemen hemen her türden hesaplamalarda kullanılabilir. RNN'ler hesaplama işlemlerini iki temel yapıda gerçekleştirirler. Birincisi, birçok geçmiş bilgiyi depolamaları ve bunları verimli bir şekilde aktarmalarıdır. Diğeri ise, gizli durumlarda doğrusal olmayan yöntemleri kullanmalarıdır. RNN mimarisinde, geçici veri kümelerini modellemek için her adımda yinelenme fonksiyonu çağrılmaktadır. Örneğin, bir şirketin hisse fiyatı, önceki günler/haftalar/aylar/yıllar üzerindeki fiyatlarına bağlıdır. Bu nedenle önceki zamanlara bağımlılık veya önceki adımlar önemlidir (Goyal ve ark., 2018).

RNN'ler, müzik üretimi ve karakter üretim ile ses, metin ve görüntü işlemeye kadar çeşitli alanlarda yaratıcı uygulamalar hazırlanmasını sağlarlar. RNN temel işlevi Şekil 3.27'de gösterilmiştir.



Şekil 3.27. RNN'nin temel işlevi (Raschka ve Mirjalili, 2017)


Standart bir ileri beslemeli sinir ağında, bilgiler girdiden gizli katmana ve ardından gizli katmandan çıktı katmanına akar. Öte yandan, yinelenen bir ağda, gizli katman girişini hem giriş katmanından hem de gizli katmanının önceki zaman adımından alır. Gizli katmandaki bitişik zaman adımlarındaki bilgi akışı, ağın geçmiş olaylara yönelik bir hafızaya sahip olmasını sağlar. Bu bilgi akışı grafiksel olarak bir döngü Şekil 3.28’de gösterilir (Raschka ve Mirjalili, 2017).



Şekil 3.28 Katmanlı RNN mimarisi (Raschka ve Mirjalili, 2017)

3.2.1.3. Uzun kısa süreli bellek (long short-term memory unit)

Uzun Kısa Süreli Bellek (LSTM) yapıları ilk olarak 1997’de Sepp Hochreiter ve Jürgen Schmidhuber tarafından kaybolan gradyan sorununun üstesinden gelmek için geliştirilmiştir. Bu yöntemle RNN’lerdeki uzun süre bilgi tutma problemi çözülmüştür. Bir LSTM’nin yapı taşı, Şekil 3.29’da gösterildiği gibi esas olarak gizli katmanı temsil eden bir bellek hücresi şeklindedir. (Hochreiter ve Schmidhuber, 1997)




Şekil 3.29. LSTM hücre yapısı (Alom ve ark., 2018)

Bir LSTM ağı, modelin uzun süren tekrarlarla eğitilmesine ve modele beslenen girişin önceki zaman adımlarında bellekte tutulmasına yardımcı olan bir RNN mimarisi türüdür. İdeal olarak, hangi bilgilerin korunmasını ve nelerin unutulmasını sağlayarak,

gradyan üzerinde daha iyi kontrol yapılmasını sağlayan ek kapılar ve girişler ekleyerek, gradyan kaybolması problemini çözerler. Böylece bilgiye erişim kontrol edilir. “Uzun vadeli bağımlılıkların” daha iyi korunmasını sağlayan *ReLU* gibi diğer aktivasyon fonksiyonları kullanılsa da, sorun tamamen çözülememektedir. RNN’lerin bu dezavantajının giderilmesi ve sorunun etkili bir şekilde çözülmesi için LSTM ağları kullanılmaya başlanmıştır (Goyal ve ark., 2018).

LSTM hücre yapısının kullanılması ile oluşturulan katman mimarisi Şekil 3.30’da gösterilmektedir. Geliştirilen bu mimari karmaşık olmanın yanı sıra, diğer modellere göre genellikle daha yavaştır. İyi bir eğitim ile bir RNN modeli bile LSTM’nikilere benzer sonuçlar verebilir ve aynı zamanda daha az hesaplama karmaşıklığına da sahip olabilir. Son bilgiler eski bilgilerden daha fazla önem taşıyorsa, LSTM modeli her zaman daha iyi bir seçim olmaktadır (Vasilev ve ark., 2019).



Şekil 3.30. LSTM katman mimarisi (Vasilev ve ark., 2019)

3.2.1.4. Otomatik ve Yığınlı otomatik kodlayıcılar (auto-encoders, stacked auto-encoders)

Otomatik kodlayıcılar, x çıkış katındaki girişi tek bir gizli katmandan h ile yeniden yapılandırmak için eğitilmiş basit ağlardır. Girdiden saklı duruma kadar bir ağırlık matrisi W , h ve önyargı b_x , h ve saklı katmandan rekonstrüksiyona karşılık gelen önyargı b_h , x ile yönetilir. Gizli katmandaki aktivasyonu hesaplamak için doğrusal olmayan bir fonksiyon kullanılır. Bu fonksiyon Denklem 3.11’de gösterilmiştir (Vincent ve ark., 2010).

$$h = \sigma(W_{-}(x, h) x + b_{-}(x, h)) \quad (3.11)$$

Ayrıca, gizli katmanın boyutu h / x ’den daha küçük olacak şekilde alınır. Bu şekilde, veriler girdideki baskın bir gizli yapıyı temsil eden daha küçük boyutlu bir alt

alana yansıtılır. Keşif sürecini geliştirmek için düzenleme veya seyreklik kısıtlamaları kullanılabilir. Gizli katman girdiyle aynı boyuta sahipse ve başka doğrusallık eklenmemişse, model basitçe kimlik fonksiyonunu öğrenir. Ses kesen otomatik kodlayıcı, modelin önemsiz bir çözüm öğrenmesini engelleyen başka bir çözümdür. Burada model, gürültüyü bozmuş bir versiyondan gelen girişi yeniden yapılandırmak için eğitilmiştir. Yığılı otomatik kodlayıcılar ya da derin otomatik kodlayıcılar, otomatik kodlayıcı katmanlarının üst üste yerleştirilmesi ile oluşturulur (Vincent ve ark., 2010).

3.2.1.5. Sınırlı Boltzmann Makineleri (RBM) ve Derin İnanç Ağları (DBN)

Sınırlı Boltzmann Makineleri (RBM), bir giriş katmanı veya görülebilir katman ile gizli bir katman özelliklerini taşımaktadır. Bu yapıda düğümler arasındaki bağlantılar çift yönlüdür. Bir giriş vektörüne bir x değeri verildiğinde gizli özellik gösterimi h elde edilebilir ve bunun tersi de geçerlidir. Dolayısıyla, RBM üretken bir modeldir ve yeni veri noktaları oluşturulabilir. Fiziksel sistemlere benzeyen bir girdi ve gizli birimlerin belirli bir durumu için bir enerji işlevi tanımlanır. Bu durum Denklem 3.12 ile hesaplanmaktadır (Hinton, 2012).

$$E(x, h) = h^T W x - c^T x - b^T h \quad (3.12)$$

Denklemdaki c ve b önyargı (bias) terimleri, sistemde “belirtme” olasılığı, enerjiyi üssel ve normalleştiriciye iletmek suretiyle Denklem 3.13’te gösterildiği şekilde hesaplanır. Şartlandırılmış hesaplama ve koşullu çıkarım için ise Denklem 3.14’te gösterilen formül kullanılır (Hinton, 2012).

$$p(x, h) = \frac{1}{Z} \exp^{-E(x, h)} \quad (3.13)$$

$$P(x_i | h) = \frac{1}{1 + \exp^{(-b_j - W_j x)}} \quad (3.14)$$

Ağ simetrik olduğundan, benzer bir ifade $P(x_i | h)$ için de geçerlidir. Derin inanç ağları ise, esas olarak otomatik kodlayıcı katmanlarının, Sınırlı Boltzmann Makineleri ile değiştirildiği yığılı otomatik kodlayıcı yapısına sahiptir. Bu modelde bireysel katmanların eğitimi yine denetimsiz bir şekilde yapılır. Son ince ayar, Derin İnanç

Ağları (DBN)'un üst katmanına doğrusal bir sınıflandırıcı eklenerek ve denetimli bir optimizasyon gerçekleştirilerek oluşturulur (Hinton ve ark., 2006; Bengio ve ark., 2007).


3.2.1.6. Varyasyonel otomatik kodlayıcılar ve üretken ters ağlar

Son zamanlarda, iki yeni denetimsiz mimari geliştirilmiştir. Bunlar Varyasyonel Otomatik Kodlayıcı (VAE) (Kingma ve Welling, 2013) ve Üretken Ters Ağlar (GAN)'dır (Goodfellow ve ark., 2014). Henüz bu modellerin tıbbi görüntülere uygulanmasını içeren bir çalışma yapılmamıştır. Ancak doğal görüntülere yönelik çalışmalarda başarılı sonuçlar elde edilmiştir. Bu modellerin gelişim süreci halen devam etmektedir.

3.3. Destek Vektör Makinesi Yöntemi (Support Vector Machine)

SVM yöntemi, istatistiksel öğrenme teorisi ve yapısal risk azaltma ilkesine dayanmaktadır. Bu sınıflandırıcının stratejisi, sınıf dağılımının kenarında bulunan eğitim örneklerine odaklanarak, sınıflar arasında maksimum marjlı, optimum bir ayırma hiper düzleminin bulunmasını amaçlamaktadır (Glowacz, 2015).

Bu ön bilgiler ışığında “destek vektör makinelerinin” temel çalışma mantığı; belirli bir tür öğrenme problemine, yani ikili sınıflandırmaya odaklanmasıdır. Modelde kullanılan girdilerin (örneğin resimlerin) sınıflandırılmasında kullanılan ve oldukça etkili yöntemlerden birisi Destek Vektör Makinesi (SVM) yöntemidir. Literatürde daha çok makine öğrenmesi alanında kullanılan SVM yöntemi, derin öğrenme alanında da tercih edilen bir tekniktir. Yöntem temelde, bir düzlemde bulunan iki grup arasında yer alan bir sınır çizgisi kullanılarak iki grubu ayırmak mantığıyla çalışmaktadır. Bu iki grubu ayıran sınırın çizileceği yer ise iki grubun da üyelerine en yakın olan yer olmalıdır. SVM yöntemi işte bu sınırın nasıl ve nerede çizileceğini belirlemektedir. Bu işlemin yapılması için iki gruba da yakın ve birbirine paralel iki sınır çizgisi çizilir ve bu sınır çizgileri birbirine yaklaştırılarak ortak sınır çizgisi üretilir. Şekil 3.31’de, $f(x) = (w * x) - b$ örnek denklemi kullanılarak yapılan bir sınıflandırma işlemi sonucunda ortaya çıkan grafik görülmektedir (Yu ve ark., 2013)



Şekil 3.31. SVM yöntemi ile sınıflandırma yapılması (Yu ve ark., 2013)

SVM algoritmaları, çekirdek (kernel) olarak tanımlanan bir dizi matematiksel fonksiyon kullanır. Çekirdeğin işlevi veriyi girdi olarak almak ve gerekli forma dönüştürmektir. Farklı SVM algoritmaları farklı çekirdek fonksiyonları kullanırlar. Bu fonksiyonlar farklı tiplerde olabilir. Örneğin doğrusal, doğrusal olmayan, polinom, radyal temel işlevi (RBF) ve sigmoid. Dizi verileri, grafikler, metinler, görüntüler ve vektörler için en çok kullanılan çekirdek fonksiyonu türü RBF'dir (Achirul Nanda ve ark., 2018).

Sınıflandırma sürecinde karşılaşılan engellerden biri, farklı eğilimler gösteren verilerin dağılmasıdır, bu nedenle doğrusal olarak ayrılması da zor olmaktadır (Zhang ve ark., 2015; Wang ve ark., 2017b). Bu noktada çekirdek fonksiyonu önemini artırmaktadır. Çekirdek fonksiyonlarının kullanılmasındaki amaç, yüksek bir boyuta dönüştürülen verinin kolayca ayrılabilmesidir.

Makine öğrenmesinde kullanılan SVM algoritmalarının python uygulamalarında kullanılması için geliştirilmiş scikit-learn kütüphanesi içerisinde yer alan SVM çekirdek (kernel) fonksiyonları, doğrusal, radyal temel fonksiyonu (RBF), sigmoid ve polinom fonksiyonlarıdır (Çizelge 3.3). Her bir çekirdek fonksiyonunun, en iyi tahmin ve sınıflandırma sonucunu üretebilmesi için optimize edilmesi gereken belirli parametre değerleri bulunmaktadır (Nandika ve ark., 2015).

Çizelge 3.3. Scikit-learn SVM çekirdek fonksiyonları

Çekirdek (Kernel) Fonksiyonu	Formül	Parametresi(s)
Homogeneous Polynomial (HPOL)	$K(x_n, x_i) = (x_n \cdot x_i)^d$	d
RBF	$K(x_n, x_i) = \exp(-\gamma \ x_n - x_i\ ^2 + c)$	c ve γ
Sigmoid	$K(x_n, x_i) = \tanh(\gamma (x_n \cdot x_i) + r)$	c, γ ve r
Polynomial	$K(x_n, x_i) = (\gamma (x_n \cdot x_i) + r)^d$	c, γ , r ve d

Not, C: maliyet (cost), γ : Çekirdek katsayısı (gamma), r: katsayı (coefficient), d: derece (degree)

SVM çekirdek parametrelerinin (c , γ , r ve d) optimum değerinin analiz edilmesi en etkili sonucu ortaya koyacak şekilde belirlenmesi gerekmektedir. Böylece bilinmeyen veriler sınıflandırma işleminde doğru biçimde tahmin edilebilir (Zhang ve Wu, 2012; Achirul Nanda ve ark., 2018).

3.4. Derin Öğrenme Amacıyla Kullanılan Kütüphaneler ve Hata Matrisi

Bu bölümde, akademik çalışmalarda temel argüman olarak derin öğrenme kütüphaneleri ve hata matrisi incelenmiştir.

3.4.1. Derin öğrenme kütüphaneleri

Keras Kütüphanesi, Keras, Theano veya TensorFlow modülleri ile bütünleşik olarak çalışan oldukça popüler bir sinir ağı kütüphanesidir. Keras, hem CNN'leri hem de RNN'leri destekleyen kütüphanelerden biridir. Uygulama GPU veya CPU üzerinde çalışabilmektedir. Bu model, olabildiğince az kodlama ile birlikte kullanılabilen bağımsız ve tamamen yapılandırılabilir modüllerden oluşmaktadır. Keras kütüphanesi özellikle, sinir ağı katmanları, maliyet fonksiyonları, optimize ediciler, başlatma şemaları, aktivasyon fonksiyonları ve düzenleme şemaları oluşturmak için tercih edilen bir kütüphanedir. Keras, literatürde çok kullanılan hazır CNN modellerini içermektedir. Her model, farklı katmanlardan, hesaplama ve etkinleştirme işlevlerinden ve düzenleme şemalarından oluşan özelleştirilebilir bir yapıdadır. Keras, sinir ağı modellerinde, evrişim, havuzlama ve azaltma katmanları (convolutional, dropout, pooling) gibi çeşitli hazır katmanlar kolayca kullanılabilir. Bu yapıdaki modelde her bir katman, bir sonraki katman için bir giriş nesnesi olarak kabul edilir (Goyal ve ark., 2018).

TensorFlow Kütüphanesi, TensorFlow, Google tarafından büyük ölçekli makine öğrenimi uygulamaları için kullanılan açık kaynaklı bir kütüphanedir. TensorFlow, gerçek anlamda Google'ın, büyük veri yapılarını kapsayan modelleri eğitmek için binlerce makineye sahip bilgi işlem kümelerini kullanma yeteneğine sahiptir. TensorFlow, Google şirketinin bir parçası olan ve öncelikle de derin öğrenme uygulamalarına odaklanan "Google Beyin Takımı" (Google Brain Team) tarafından geliştirilmiştir. Bu kütüphane çok büyük miktardaki sayısal hesaplamalar için veri akış grafiklerini kullanır. Tek bir masaüstü, sunucu sistemleri ya da mobil cihazlarda, CPU

veya GPU sistemleri kullanılarak hesaplamalar yapılacak şekilde tasarlanmıştır. TensorFlow ile yapılan yoğun hesaplama işlemlerinde, CPU veya GPU odaklı platformlara geçiş çok az kod değişikliği ile mümkün olmaktadır. Ayrıca, geliştirilen uygulamalar, Android özellikli mobil cihazlarda da kullanılabilir (Goyal ve ark., 2018).

TensorFlow, Google arama motorunu kullanan kullanıcıların, arama sonuçlarının işlenmesine ve bu sonuçlarına bağlı olarak çıktı sağlanmasına yardımcı olan RankBrain gibi uygulamaların temelini oluşturmaktadır.

PyTorch Kütüphanesi, PyTorch, Torch ve Facebook şirketleri tarafından geliştirilen bir derin öğrenme kütüphanesidir. Kullanımı nispeten kolaydır ve son zamanlarda popülerlik kazanmıştır. PyTorch kütüphanesi de TensorFlow gibi CPU ya da GPU kullanarak çalışabilmektedir (Vasilev ve ark., 2019).

3.4.2. Hata matrisi (confusion matrix)

Hata matrisi, makine öğrenimi ve derin öğrenme alanlarında test sonuçlarını elde etmek için kullanılmaktadır. Derin öğrenme algoritmalarının hesaplama sonuçlarının değerlendirilmesi amacıyla kullanılan hata matrislerinden yararlanılarak birçok değerlendirme yapılabilmektedir. Hata matrisleri kullanılarak yapılan hesaplamalar Çizelge 3.4'te gösterilmiştir (Fawcett, 2004).

Çizelge 3.4. Hata matrisi ile yapılan test hesaplamalar

		Gerçek(Predicted)		
		Pozitif(positive)	Negatif(Negative)	
Tahmin (Actual)	Pozitif (positive)	Doğru Pozitif (dp)	Yanlış Pozitif (yp)	Kesinlik (Precision) $\frac{dp}{dp + yp}$
	Negatif (Negative)	Yanlış Negatif (yn)	Doğru Negatif (dn)	Negatif Öngörü Değeri (Negative Predictive Value) $\frac{dn}{dn + yn}$
		Duyarlılık (Sensitivity) $\frac{dp}{dp + yn}$	Birleyicilik (Specificity) $\frac{dn}{dn + yp}$	Doğruluk (Accuracy) $\frac{dp + dn}{dp + dn + yn + yp}$

Doğru Pozitif (dp): Bir örneğin pozitif olduğu doğru tahminlerin sayısıdır; yani pozitif sınıf doğru ve pozitif olarak tanımlanmıştır. Örneğin, verilen sınıf uninfected olup sınıflandırıcı tarafından da uninfected olarak doğru bir şekilde tahmin edilmiştir.

Yanlış Pozitif (yp): Bir örneğin pozitif olduğuna dair yanlış tahminlerin sayısıdır; yani negatif sınıf yanlış ve pozitif olarak tanımlanmıştır. Örneğin, verilen sınıf infected olmasına karşın, sınıflandırıcı tarafından yanlış ve uninfected olarak tahmin edilmiştir. Bu duruma “*tip I hata*” denilmektedir.

Yanlış Negatif (yn): Bir örneğin negatif olduğu, yani negatif olarak yanlış olarak tanımlanan pozitif sınıf anlamına gelen yanlış tahminlerin sayısıdır. Örneğin, verilen sınıf uninfected olmasına karşın, sınıflandırıcı tarafından infected olarak ve yanlış bir şekilde tahmin edilmiştir. Bu duruma “*tip II hata*” denilmektedir.

Doğru Negatif (dn): Bir örneğin negatif olduğu, yani negatif olarak doğru bir şekilde tanımlanmış negatif sınıf anlamına gelen doğru tahminlerin sayısıdır. Örneğin, verilen sınıf infected özelliğindedir ve sınıflandırıcı da infected ve negatif olarak doğru bir şekilde tahmin etmiştir.

Doğruluk (Accuracy): Test için doğru olarak yapılan toplam tahmin sayısının oranını göstermektedir. Bu oranın yüksek olması modelin başarısını göstermektedir.

Duyarlılık (Sensitivity): Aynı zamanda Gerçek Pozitif Oranı (True Positive Rate) veya Geri Çağırma (Recall) olarak adlandırılmaktadır. Sınıflandırıcı tarafından pozitif ve doğru olarak etiketlenmiş örneklerin oranıdır. Bu oran başarılı derin öğrenme algoritmalarında yüksek olmalıdır. Örnek olarak, tüm uninfected resimlerin arasında ne kadar uninfected resmin doğru tahmin edildiğinin oranı verilebilir.

Hassasiyet (Specificity): Gerçek Olumsuz Oranı (True Negative Rate) olarak da bilinmektedir. Sınıflandırıcı tarafından negatif olarak etiketlenen negatif örneklerin ölçüsüdür. Bu oran da yüksek olmalıdır. Örneğin, tüm infected resimlerin arasında ne kadar infected resmin doğru tahmin edildiğinin oranı verilebilir.

Kesinlik (Precision): Doğru sınıflandırılmış pozitif örneklerin toplam sayısının ve tahmin edilen örneklerin toplamının oranıdır. Pozitif tahminde elde edilen doğruluğu ifade etmektedir.

F- Ölçütü (F1 Skoru): Modelin doğru ve dengeli tahminler yaptığını gösteren bir hesaplama sonucudur. Tahmin aşamasında bu değer yüksek olması beklenmektedir. Bu durum Denklem 3.14 ile hesaplanmaktadır.

$$F_Ölçütü = \frac{2*(kesinlik*duyarlılık)}{kesinlik+duyarlılık} \quad (3.14)$$

Derin öğrenme yöntemleri kullanılarak yapılan sınıflandırma işleminin başarı durumunu değerlendirmek için ise iki temel değişken öne çıkmaktadır. Bunlar kayıp (*loss*) ve doğruluk (*accuracy*) oranlarıdır. Bu fonksiyonlar modelin optimizasyonu için diğer bir ifadeyle en ideal eğitim sonuçlarına ulaşılması amacıyla kullanılır.



4. UYGULAMA SONUÇLARI

Bu bölümde, sıtma hastalığının derin öğrenme yöntemi kullanılarak, sıtma parazitleri taşıyan ve taşımayan kan hücrelerine ait görüntülerin incelenmesi ve sınıflandırılması gerçekleştirilmiştir. Python sürüm (version) 3.7.4, diğer kütüphaneler (TensorFlow, Keras ve Scikit-learn), Matlab yazılımları ve Intel Core i7-6700HQ işlemcili, 4 GB NVIDIA GeForce GTX 970M ekran kartlı donanım yapısı kullanılmıştır.

4.1. Uygulama Modüllerinin İncelenmesi

Sıtma görüntülerinin analizi için CNN içindeki RAN modeli kullanılmıştır. Ayrıca diğer CNN modelleri AN, VGG16, ResNet50, InceptionV3 ve AlexNet karşılaştırılarak değerlendirilmiş ve sonuçlar elde edilmiştir.

Sıtma görüntülerinin SVM metodu kullanılarak analizi için ise *scikit-learn* kütüphanesinden yararlanılmıştır.

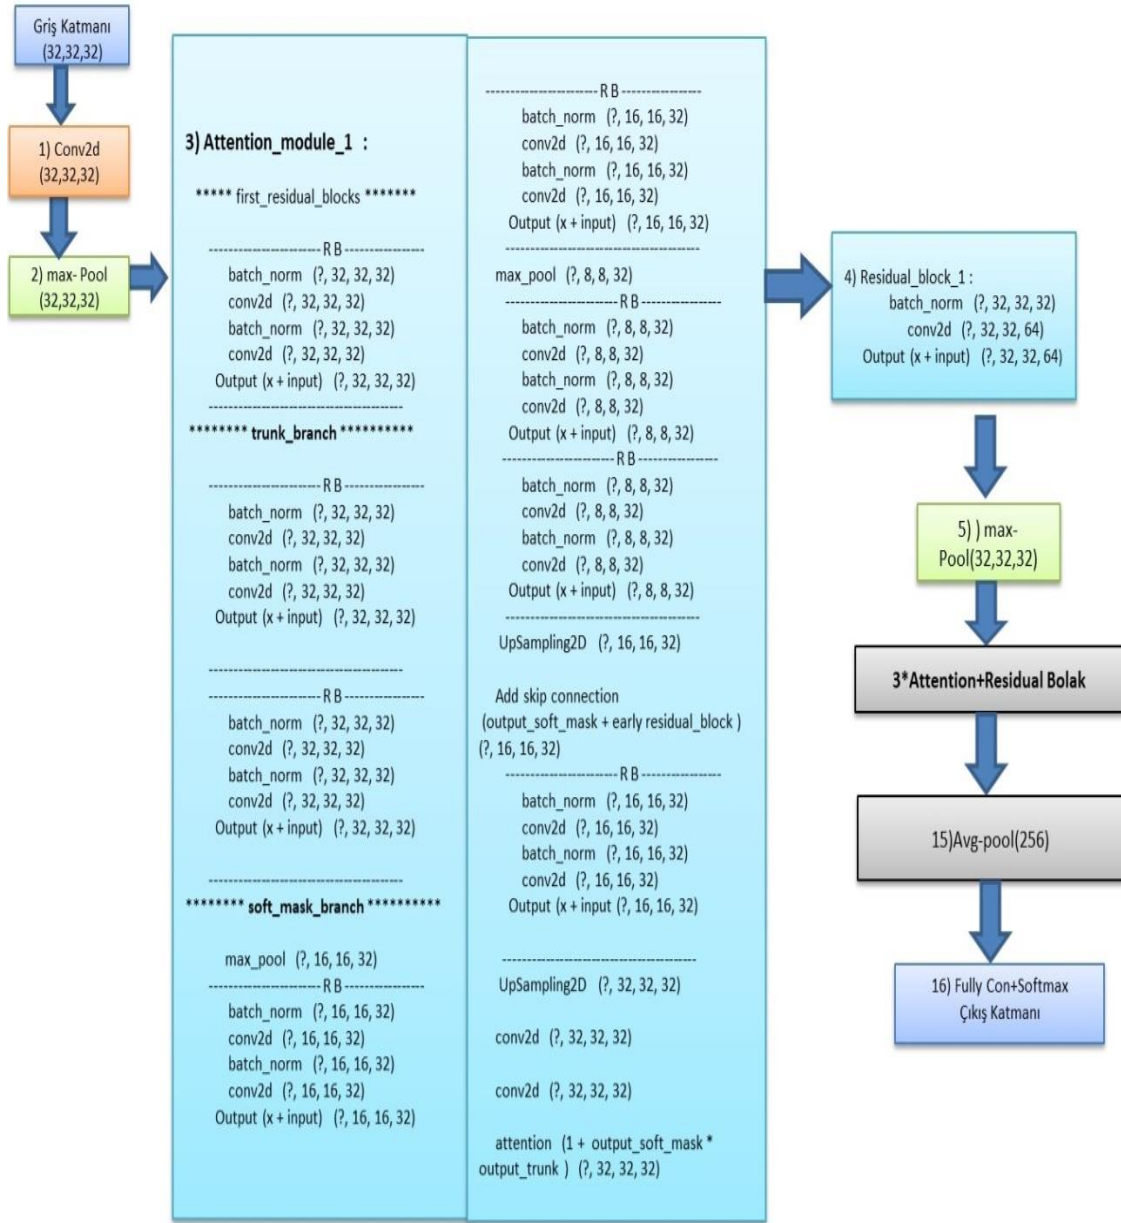
4.2. Sıtma Görüntülerinin CNN Tekniği ile Analizi

CNN yöntemi ile resim sınıflandırma işlemi için katman mimarisine dayanan derin öğrenme teknikleri kullanılmıştır. Araştırmada kullanılan sıtma görüntüleri parazitli ve parazitsiz (infected-uninfected) olmak üzere iki gruba ayrılmış durumdadır. Bu bağlamda, 20,658 adet görüntü eğitim (training) için ve 6,900 adet görüntü ise test için, toplam 27,558 adet smear görüntü veri seti kullanılmıştır.

4.2.1. RAN Modeli

Çalışmanın amacı kapsamında, öncelikle gelişmiş bir Evrimsel Sinir Ağı (CNN) modeli olan Artık Dikkat Ağı (RAN) modeli kullanılmıştır. Bu amaçla geliştirilen RAN temelli derin öğrenme mimarisi Şekil 4.1'de gösterilmiştir.

Geliştirilen RAN modeli, 4 ayrı Attention Modülü ve 5 ayrı Residual Block'tan oluşan bir katman (layer) yapısına sahiptir. Sınıflandırma yapılacak resimlerin 32x32 ebatlarında renkli resimler olarak belirlenmesi nedeniyle, modelin giriş matrisi 32x32x3 şeklinde oluşturulmuştur. Daha yüksek doğruluk için belirlenen matris boyutları artırılarak daha yüksek çözünürlükte resimler analiz edilecektir. Ancak, bu durumda modelin eğitim (training) süresi daha uzun olacaktır.



Şekil 4.1. Resim sınıflandırma için geliştirilen RAN modeli

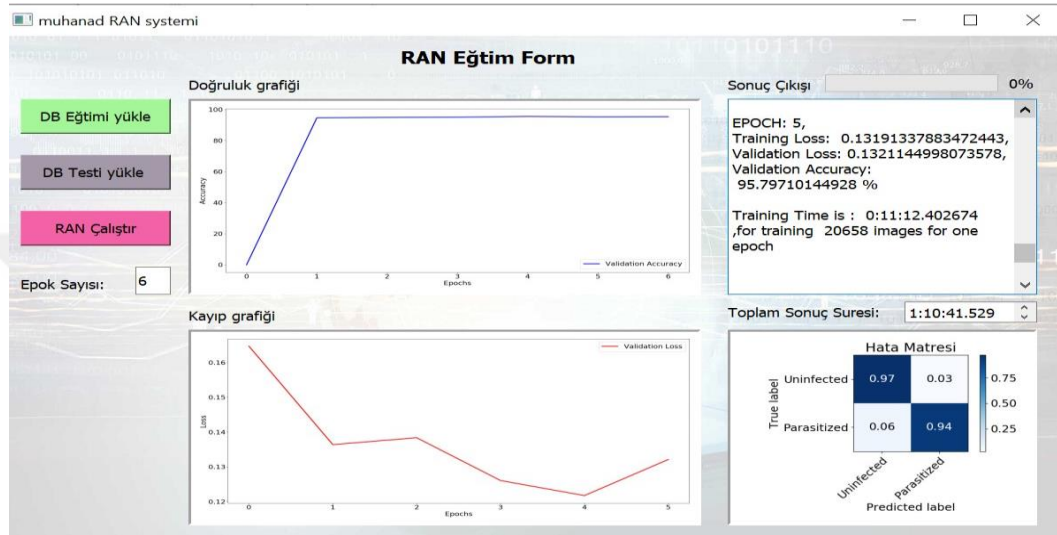
Şekil 4.2’de görüldüğü üzere, RAN modeli kullanılarak oluşturulan (eğitim) uygulamada, 10,329 adet sıtma paraziti taşıyan ve 10,329 adet sıtma paraziti taşımayan resim modelde girdi olarak kullanılmıştır. Çizelge 4.1’de yer alan eğitim sonuç verileri ile Şekil 4.2’de gösterilen kayıp ve doğruluk grafiği elde edilmiştir.

Buna göre:

- Eğitim (training) işlemi için 6 tekrar sayısı (epoch) uygulanmıştır.
- Modelin eğitimi 01 s. 10 dk. sürmüştür.
- Doğruluk oranı %95.79 olmuştur.

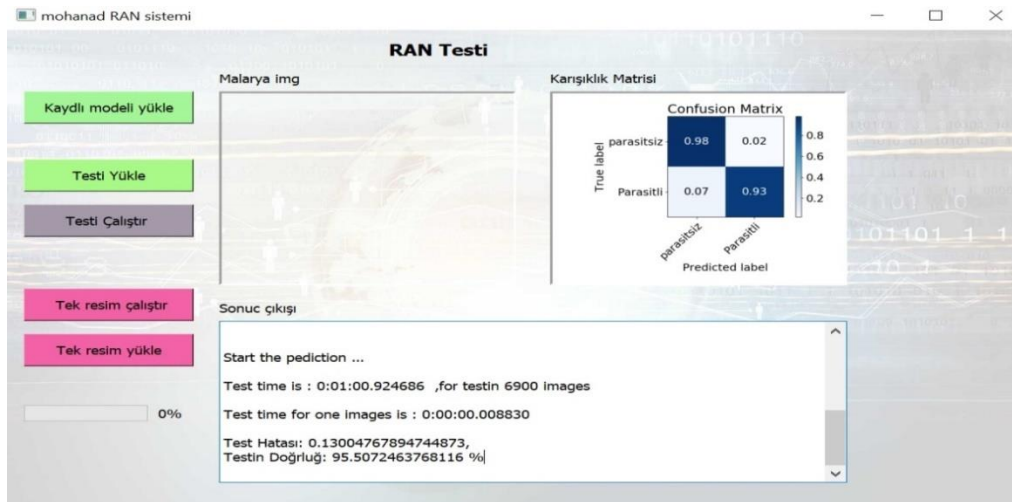
Çizelge 4.1. RAN modeli eğitim sonuç verileri

Tekrar (Epoch)	Doğruluk (Accuracy)	Kayıp (Loss)	Resim Sayısı
1	%94.07	0.1848	20,658
2	%92.80	0.2414	20,658
3	%95.02	0.1422	20,658
4	%95.13	0.1396	20,658
5	%94.94	0.130	20,658
6	%95.79	0.1338	20,658



Şekil 4.2. RAN modeli kullanan uygulamanın eğitim (training) sonucuna ait ekran görüntüsü

Modelin resim sınıflandırma eğitimindeki başarısının değerlendirilmesi için test işlemi uygulanmıştır. Modelde test işleminin yapılabilmesi için ise 3,450 adet sıtma paraziti taşımayan ve 3,450 adet sıtma paraziti taşıyan resim kullanılmıştır. RAN modeli ne kadar başarı sağladığının denemesi amacıyla yapılan test (tahmin) işlemine ait ekran görüntüsü ise Şekil 4.3'te yer almaktadır.




Şekil 4.3. RAN modeli kullanan uygulamanın test (tahmin) sonucuna ait ekran görüntüsü

Şekil 4.3 ve Çizelge 4.2 birlikte incelendiğinde ise, RAN modeli kullanılarak oluşturulan uygulamada sıtma paraziti taşıyan ve taşımayan toplam 6,900 adet resim, modelin testi amacıyla kullanılmıştır. Modelin test doğruluk oranı ise %95.51 olarak gerçekleşmiştir.

Çizelge 4.2. RAN modeli test sonuç verileri

Testte Kullanılan Resim Sayısı	Doğruluk Oranı (Accuracy)	Başarılı Olunan Parazitli Resimlerin		Başarılı Olunan Parazitsiz Resimlerin	
		Sayısı	Oranı	Sayısı	Oranı
6,900	%95.51	3,430	%98.00	3,290	%93.00

RAN modeli ile hazırlanan uygulamanın örnek bir resim üzerindeki tahmin işlemine ait ekran görüntüsü ise Şekil 4.4'te görülmektedir.



Şekil 4.4. RAN modeli kullanan uygulamanın örnek resim üzerindeki test sonucuna ait görüntü

Şekil 4.4 ve Çizelge 4.3 birlikte incelendiğinde ise görüldüğü üzere, RAN modeli ile oluşturulan uygulamaya bir adet sıtma paraziti taşıyan örnek bir resim yüklenmiş ve modelin bu resmi %97.24 oranında sıtma paraziti taşıyan resim olarak tahmin ettiği ve başarılı olduğu tespit edilmiştir.

Çizelge 4.3. RAN modeli tek resim test sonuç verileri

Testte Kullanılan Resim Sayısı	Doğruluk Oranı (Accuracy)	Başarılı Olunan Parazitli Resimlerin		Başarılı Olunan Parazitsiz Resimlerin	
		Sayısı	Oranı	Sayısı	Oranı
1	%97.24	1	-	-	-

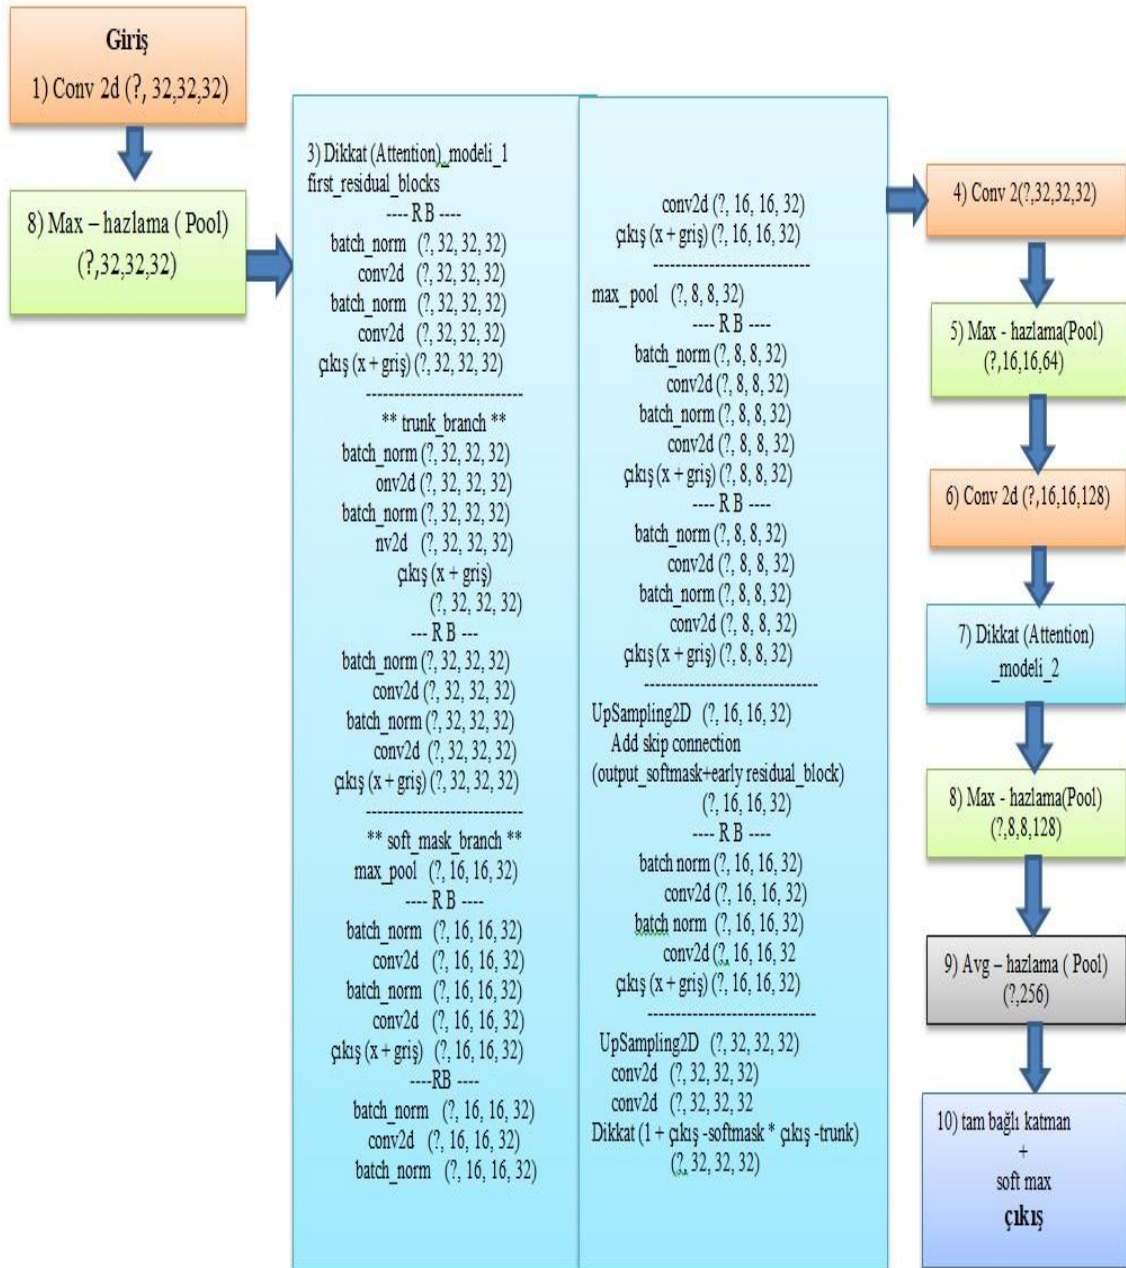
Ayrıca CNN'in RAN modeli kullanılarak, 10 tekrardan 60 tekrara(epoch) kadar çizelge 4.4'teki sonuçları verilmiştir. Bu sonuçların 60 tekrarda (epoch) %96.05 çıktığı görülmektedir. 60 tekrar haricindekilerde ciddi bir artışın söz konusu olmadığı gözlemlenmiştir (Çizelge 4.4).

Çizelge 4.4. RAN modeli eğitim sonuç verileri

Tekrar (Epoch)	Doğruluk (Accuracy)	Kayıp (Loss)	Resim Sayısı
10	%95.55	0.1274	20,658
20	%95.66	0.1192	20,658
30	%95.94	0.1145	20,658
40	%95.71	0.1370	20,658
50	%96.04	0.1140	20,658
60	%96.05	0.1105	20,658

4.2.2. AN Modeli

Bu çalışma kapsamında, bir Evrişimsel Sinir Ağı (CNN) modeli olan Dikkat Ağı (AN) modeli de sunulmuştur. Bu amaçla geliştirilen AN temelli derin öğrenme mimarisi Şekil 4.5'te gösterilmiştir.




Şekil 4.5. Resim sınıflandırma için geliştirilen AN modeli.

Şekil 4.6'da geliştirilen AN modeli, RAN modeline benzemekle birlikte, 2 ayrı Attention Modülünden oluşan bir katman yapısına sahiptir. Dikkat Ağı (AN) modeli temel alınarak geliştirilen katman mimarisinin çalıştırılması neticesinde

- Eğitim işlemi için 6 tekrar sayısı uygulanmıştır.
- Training işlemi 01 s. 08 dk. sürmüştür.
- Elde edilen eğitim doğruluk oranı %95.52 olmuştur (Çizelge 4.5).

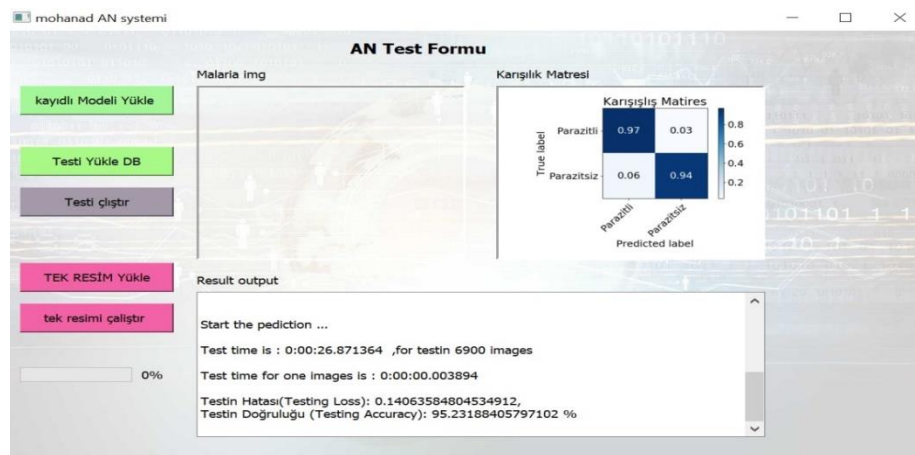
Çizelge 4.5. AN modeli eğitim sonuç verileri

Tekrar (Epoch)	Doğruluk (Accuracy)	Kayıp (Loss)	Resim Sayısı
1	%94.43	0.1576	20,658
2	%94.72	0.1528	20,658
3	%95.37	0.1494	20,658
4	%95.60	0.1401	20,658
5	%94.49	0.1501	20,658
6	%95.52	0.1382	20,658



Şekil 4.6. AN modeli kullanan uygulamanın eğitim (tarining) sonucuna ait ekran görüntüsü

AN modeli kullanılarak hazırlanan uygulamanın resim sınıflandırma işleminde yapılan test ekran görüntüsü Şekil 4.7’de yer almaktadır.



Şekil 4.7. AN modeli kullanan uygulamanın test (tahmin) sonucuna ait ekran görüntüsü

Şekil 4.7 ve Çizelge 4.6 birlikte incelendiğinde ise, AN modeli kullanılarak oluşturulan uygulamada sıtma paraziti taşıyan ve taşımayan toplam 6,900 adet resim, modelin testi amacıyla kullanılmıştır. Modelin test doğruluk oranı ise %95.23 olarak gerçekleşmiştir.


Çizelge 4.6. AN modeli test sonuç verileri

Testte Kullanılan Resim Sayısı	Doğruluk Oranı (Accuracy)	Başarılı Olunan Parazitli Resimlerin		Başarılı Olunan Parazitsiz Resimlerin	
		Sayısı	Oranı	Sayısı	Oranı
6,900	%95.23	3346	%97.00	3243	%94.00

Çalışmada, RAN modeli ile elde edilen başarılı eğitim ve tahmin sonuçlarının diğer modellerle karşılaştırılması amacıyla, CNN yöntemi temel alınarak oluşturulan farklı modellerin karşılaştırılması yapılmıştır. Bu amaçla, önceden öğretilmiş metodlar (pre-trained methods) olarak bilinen ve bilimsel araştırmalarda yaygın olarak kullanılan VGG16, ResNet50, InceptionV3 ve AlexNet gibi hazır modellerde eğitim ve testler yapılarak sonuçlar alınmıştır.

4.2.3. VGG16 Modeli

Bu modellerden VGG16 modelinin katman yapısında yapılan değişiklikler Şekil 4.8'de gösterilmiştir.



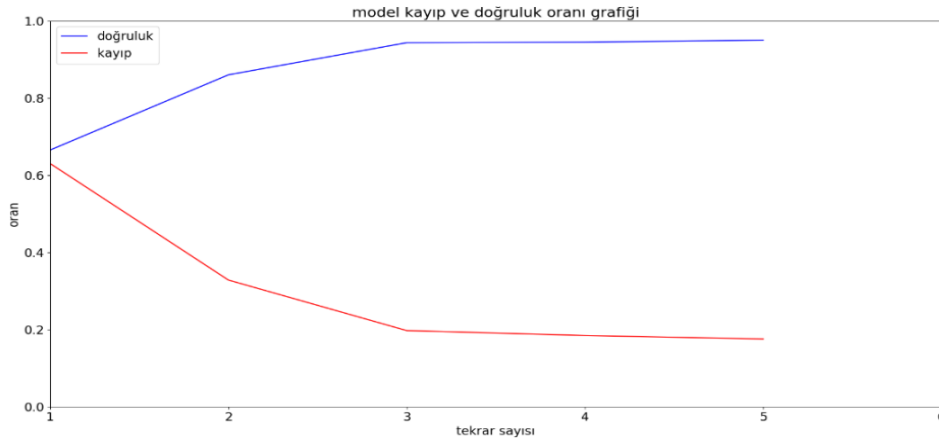
Şekil 4.8. VGG16 mimarisi ile oluşturulan CNN modeli

VGG16 modeli temel alınarak geliştirilen katman mimarisinin çalıştırılması neticesinde, Çizelge 4.7’de yer alan eğitim sonuç verileri ile Şekil 4.9’da gösterilen kayıp ve doğruluk grafiği elde edilmiştir. Buna göre,

- Eğitim (training) işlemi için 6 epoch (tekrar sayısı) uygulanmıştır.
- Modelin eğitimi 01 s. 01 dk. sürmüştür.
- Modelin eğitim doğruluk oranı %95.04 olmuştur.


Çizelge 4.7. VGG16 modeli eğitim sonuç verileri

Eğitim Tekrar Basamağı	Eğitim Doğruluk Oranı (Accuracy)	Eğitim Kayıp Oranı (Loss)	Eğitimde Kullanılan Resim Sayısı
1	%57.93	0.7568	20,658
2	%66.55	0.6305	20,658
3	%86.04	0.3284	20,658
4	%94.38	0.1974	20,658
5	%94.50	0.1846	20,658
6	%95.04	0.1756	20,658



Şekil 4.9. VGG16 Modeli kayıp ve doğruluk oranı grafiği

Şekil 4.9 'da incelendiğinde, VGG16 modelinin eğitim doğruluk oranının 3'üncü tekrara kadar hızla arttığı ve 6'nci tekrarda %95.04 seviyesine ulaştığı görülmüştür. VGG16 modelinin testi sonucunda oluşan hata matrisi Şekil 4.10'da gösterilmektedir.



Şekil 4.10. VGG16 Modelinin testi sonucunda oluşan hata matrisi


Şekil 4.10 ve Çizelge 4.8 birlikte incelendiğinde ise modelin, 3,258 parazitli ve 3,293 parazitsiz olmak üzere toplam 6,900 örnek resim ile yapılan testin sonucunda tespit ettiği belirlenmiştir. Elde edilen bu bulgulara göre, sıtma paraziti taşıyan ve taşımayan resimlerin sınıflandırmasında VGG16 modelinin etkinlikle kullanılabilirliği değerlendirilmektedir. Modelin test doğruluk oranı ise %94.94 olarak gerçekleşmiştir.

Çizelge 4.8. VGG16 modeli test sonuç verileri

Testte Kullanılan Resim Sayısı	Test Doğruluk Oranı (Accuracy)	Başarılı Olunan Parazitli Resimlerin		Başarılı Olunan Parazitsiz Resimlerin	
		Sayısı	Oranı	Sayısı	Oranı
6,900	%94.94	3,293	%95.45	3,258	%94.44

4.2.4. ResNet50 Modeli

Çalışmada kullanılan ResNet50 modeli ve katman yapısında yapılan değişiklikler Şekil 4.11’de gösterilmiştir.



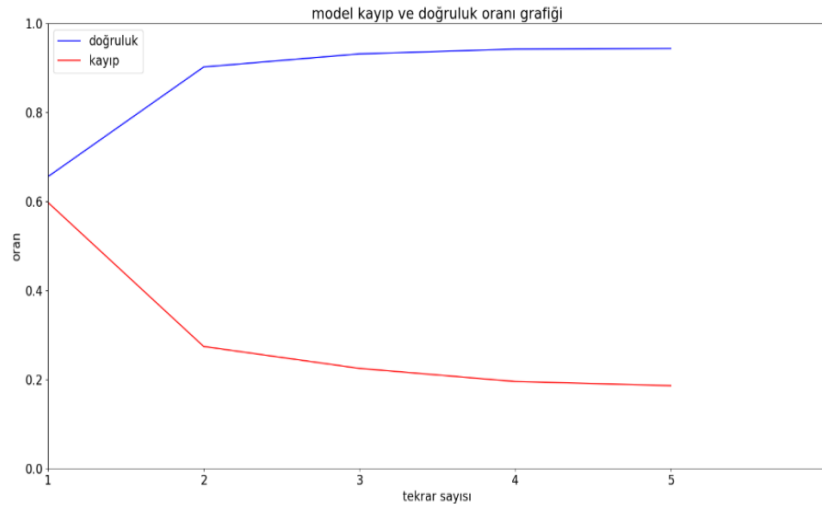
Şekil 4.11. ResNet50 mimarisi ile oluşturulan CNN model

ResNet50 modeli temel alınarak geliştirilen katman mimarisinin çalıştırılması neticesinde, Çizelge 4.9'da yer alan eğitim sonuç verileri ile Şekil 4.12'de gösterilen kayıp ve doğruluk grafiği elde edilmiştir. Buna göre;

- Training işlemi için 6 tekrar sayısı uygulanmıştır.
- Modelin eğitimi 01 s. 38 dk. sürmüştür.
- Modelin eğitim doğruluk oranı %94.37 olmuştur (Çizelge 4.9).


Çizelge 4.9. ResNet50 modeli eğitim sonuç verileri

Eğitim Tekrar Basamağı (Epoch)	Eğitim Doğruluk Oranı (Accuracy)	Eğitim Kayıp Oranı (Loss)	Eğitimde Kullanılan Resim Sayısı
1	%51.41	0.7271	20,658
2	%65.56	0.5977	20,658
3	%90.20	0.2741	20,658
4	%93.15	0.2248	20,658
5	%94.22	0.1954	20,658
6	%94.37	0.1860	20,658



Şekil 4.12. ResNet50 Modeli kayıp ve doğruluk oranı grafiği

ResNet50 modelinin testi sonucunda oluşan hata matrisi Şekil 4.13'te gösterilmektedir.



Şekil 4.13. ResNet50 Modelinin testi sonucunda oluşan hata matrisi

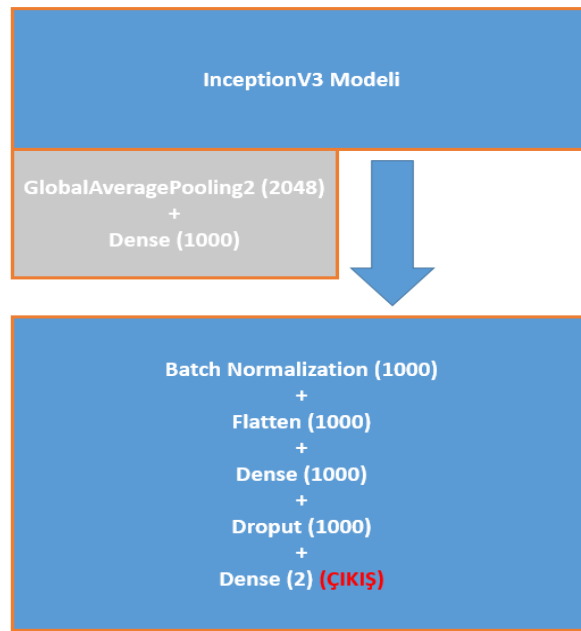
Şekil 4.13 ve Çizelge 4.10 birlikte incelendiğinde ise; modelin, 3,450 parazitli ve 3,450 parazitsiz olmak üzere toplam 6,900 örnek resim ile yapılan testinde, 3,450 parazitli resimden 3,338'ini ve 3,450 parazitsiz resimden de 2,055'ini doğru olarak tespit ettiği belirlenmiştir. Elde edilen bu bulgulara göre, sıtma paraziti taşıyan ve taşımayan resimlerin sınıflandırmasında ResNet50 modelinin etkinlikle kullanılabilceği değerlendirilmektedir. Ancak model, parazitsiz resimleri daha düşük bir doğruluk oranı ile sınıflandırabilmiştir. Modelin test doğruluk oranı ise %78.16 olarak gerçekleşmiştir.

Çizelge 4.10. ResNet50 modeli test sonuç verileri

Testte Kullanılan Resim Sayısı	Test Doğruluk Oranı (Accuracy)	Başarılı Olunan Parazitli Resimlerin		Başarılı Olunan Parazitsiz Resimlerin	
		Sayısı	Oranı	Sayısı	Oranı
6,900	%78.16	3338	%96.75	2055	%59.57

4.2.5. InceptionV3 Modeli

Çalışmada kullanılan InceptionV3 modelinin katman yapısında yapılan değişiklikler Şekil 4.14'te gösterilmiştir.




Şekil 4.14. InceptionV3 mimarisi ile oluşturulan CNN modeli

InceptionV3 modeli temel alınarak geliştirilen katman mimarisinin çalıştırılması neticesinde, Çizelge 4.11’de yer alan eğitim sonuç verileri ile Şekil 4.15’te gösterilen kayıp ve doğruluk grafiği elde edilmiştir. Buna göre:

- Training işlemi için 6 tekrar sayısı uygulanmıştır.
- Modelin eğitimi 01 s. 31 dk. sürmüştür.
- Modelin eğitim doğruluk oranı %94.82 olmuştur (Çizelge 4.11).

Çizelge 4.11. InceptionV3 modeli eğitim sonuç verileri

Eğitim Tekrar Basamağı (Epoch)	Eğitim Doğruluk Oranı (Accuracy)	Eğitim Kayıp Oranı (Loss)	Eğitimde Kullanılan Resim Sayısı
1	%64.88	0.9512	20,658
2	%90.54	0.2567	20,658
3	%93.83	0.2005	20,658
4	%94.61	0.1728	20,658
5	%94.60	0.1828	20,658
6	%94.82	0.1711	20,658




Şekil 4.15. InceptionV3 Modeli kayıp ve doğruluk oranı grafiği

Şekil 4.15'te incelendiğinde, InceptionV3 modelinin eğitim doğruluk oranının 2'nci tekrardan sonra arttığı ve istikrarlı bir seyir izlediği, 6'nci tekrar sonucunda da %94.82 seviyesine ulaştığı görülmüştür. Modelin test işlemi sonucunda ulaşılan değerler ise Çizelge 4.12'de yer almaktadır.

Çizelge 4.12. InceptionV3 modeli test sonuç verileri

Testte Kullanılan Resim Sayısı	Test Doğruluk Oranı (Accuracy)	Başarılı Olunan Parazitli Resimlerin		Başarılı Olunan Parazitsiz Resimlerin	
		Sayısı	Oranı	Sayısı	Oranı
6,900	%94.27	3,246	%94,58	3,279	%94



Şekil 4.16. InceptionV3 Modelinin testi sonucunda oluşan hata matrisi

Şekil 4.16 ve Çizelge 4.12’de birlikte incelendiğinde, modelin, 3,450 parazitli ve 3,450 parazitsiz olmak üzere toplam 6,900 örnek resim ile yapılan testinde, 3,450 parazitli resimden 3,246’sını ve 3,450 parazitsiz resimden de 3,279’unu doğru olarak tahmin ettiği belirlenmiştir. Modelin test doğruluk oranı %94.27 olarak gerçekleşmiştir. Elde edilen bu bulgulara göre, InceptionV3 modelinin sıtma paraziti taşıyan ve taşımayan resimlerin sınıflandırmasında başarılı şekilde kullanılabileceği görülmektedir.

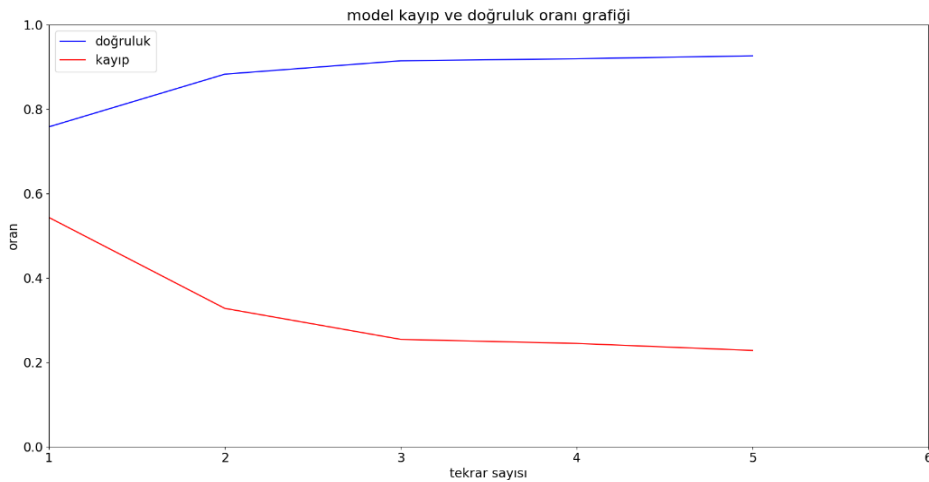
4.2.6. AlexNet Modeli

Çalışmada kullanılan AlexNet modeli temel alınarak geliştirilen katman mimarisinin python uygulamasında çalıştırılması neticesinde, Çizelge 4.13’te yer alan eğitim sonuç verileri ile Şekil 4.17’de gösterilen kayıp ve doğruluk grafiği elde edilmiştir. Buna göre;

- Eğitim işlemi için 6 epoch uygulanmıştır.
- Modelin eğitimi 01 s. 35 dk. sürmüştür.
- Modelin eğitim doğruluk oranı %92.64 olmuştur (Çizelge 4.13).


Çizelge 4.13. AlexNet modeli eğitim sonuç verileri

Eğitim TekrarBasamağı	Eğitim Doğruluk Oranı	Eğitim Kayıp Oranı	Eğitimde Kullanılan Resim Sayısı
1	%59.06	0.8895	20,658
2	%75.81	0.5434	20,658
3	%88.29	0.3279	20,658
4	%91.46	0.2544	20,658
5	%91.95	0.2448	20,658
6	%92.64	0.228	20,658



Şekil 4.17. AlexNet Modeli kayıp ve doğruluk oranı grafiği

AlexNet modelinin testi sonucunda oluşan hata matrisi Şekil 4.18’de gösterilmektedir.



Şekil 4.18. AlexNet modelinin testi sonucunda oluşan hata matrisi

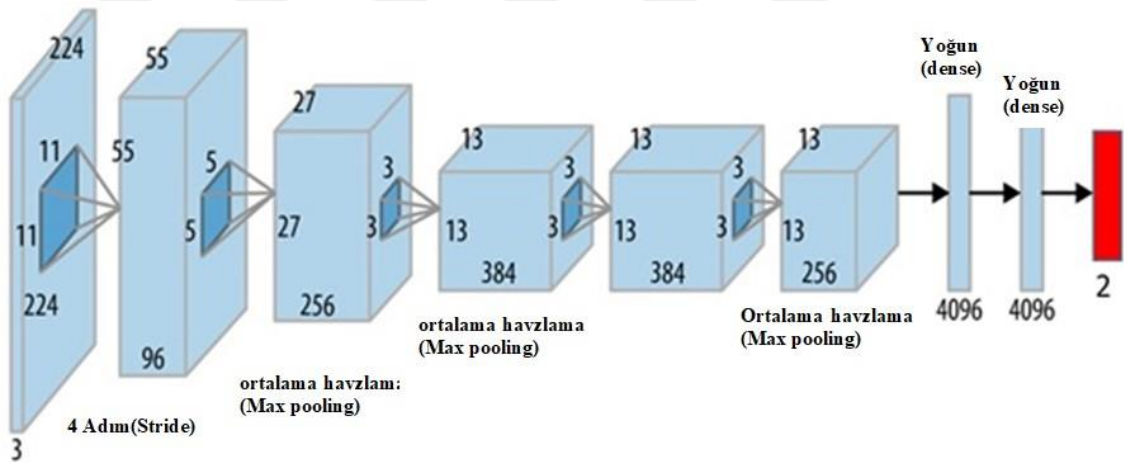
Şekil 4.18 ve Çizelge 4.14’te birlikte incelendiğinde ise; modelin, 3,450 parazitli ve 3,450 parazitsiz olmak üzere toplam 6,900 örnek resim ile yapılan testinde, 3,450 parazitli resimden 3,066’sını ve 3,450 parazitsiz resimden de 3,389’unu doğru olarak tespit ettiği belirlenmiştir. Elde edilen bu bulgulara göre, sıtma paraziti taşıyan ve taşımayan resimlerin sınıflandırmasında AlexNet modelinin de etkinlikle kullanılabileceği değerlendirilmektedir. Modelin test doğruluk oranı ise %93.55 olarak gerçekleşmiştir.

Çizelge 4.14. AlexNet modeli test sonuç verileri

Testte Kullanılan Resim Sayısı	Test Doğruluk Oranı (Accuracy)	Başarılı Olunan Parazitli Resimlerin		Başarılı Olunan Parazitsiz Resimlerin	
		Sayısı	Oranı	Sayısı	Oranı
6900	%93.55	3,066	%88.87	3,389	%98.23


4.2.7. Alexnet Modeli İle Gerçekleştirilen Matlab Uygulaması

Çalışma kapsamında, MATLAB programı ile derin öğrenme uygulaması geliştirilmesi amacıyla, Alexnet tabanlı bir model mimarisi kullanılmıştır. Kullanılan AlexNet mimarisi Şekil 4.19’da gösterilmiştir.



Şekil 4.19. AlexNet mimarisi ile oluşturulan CNN modeli (Anwar, 2019)

AlexNet modeli kullanılarak oluşturulan Matlab uygulamasının eğitim aşaması sonucunda elde edilen ekran görüntüsü Şekil 4.20’de gösterilmiştir.



Şekil 4.20. AlexNet kullanan uygulamanın eğitim sonucuna ait ekran görüntüsü

AlexNet modeli temel alınarak geliştirilen katman mimarisinin çalıştırılması neticesinde;

- Eğitim işlemi için 6 epoch uygulanmıştır.
- Eğitim işlemi 1 s. 45 dk. 16 sn. sürmüştür.
- Eğitim işlemi sonucunda %95.31'lik bir doğruluk oranı elde edilmiştir (Çizelge 4.15).

Çizelge 4.15. AlexNet modeli eğitim sonuç verileri(matlab dilinde)

Eğitim Tekrar Basamağı	Eğitim Doğruluk Oranı	Eğitim Kayıp Oranı	Eğitimde Kullanılan Resim Sayısı
1	%93.75	0.107	18.372
2	%90.63	0.2845	18.372
3	%93.75	0.107	18.372
4	%95.31	0.1495	18.372
5	%95.31	0.1283	18.372
6	%95.31	0.1457	18.372

AlexNet modeli kullanılarak oluşturulan Matlab uygulamasının test aşaması sonucunda elde edilen ekran görüntüsü Şekil 4.21'de gösterilmiştir.

Şekil 4.21’de AlexNet modelinin 4,593 görüntü matlab dilinde kullanılarak yapılan testi neticesinde elde edilen hata matrisi görülmektedir. İncelendiğinde, kullanılan model ile %95.87’luk bir tahmin doğruluk oranı elde edildiği görülmektedir. Diğer bir ifadeyle, AlexNet modeli 4,593 parazitli resmin 4,385’ini ve 4,593 parazitsiz resmin de 4,422’sini doğru olarak tahmin etmiştir. Modelin test doğruluk oranı ise %95.87 olarak gerçekleşmiştir. (Çizelge 4.16).



Şekil 4.21. AlexNet mimarisinin hata matrisi

Çizelge 4.16. AlexNet modeli test sonuç verileri(matlab dilinde)

Testte Kullanılan Resim Sayısı	Test Doğruluk Oranı (Accuracy)	Başarılı Olunan Parazitli Resimlerin		Başarılı Olunan Parazitsiz Resimlerin	
		Sayısı	Oranı	Sayısı	Oranı
9186	%95.87	4385	%95.47	4422	%96.27

Ayrıca, AlexNet kullanılırken Python dilinde çıkan sonuç %92.64 doğruluk oranı verirken, Matlab diliyle çıkan sonuç %95.31 olarak bulunmuştur. Buna bağlı olarak AlexNet’in sonuçlarının Matlab dilinde daha yüksek çıktığı görülebilir. AlexNet modelin sonuçundaki fark, Matlab dilinde sinir ağının ağırlığından kaynaklandığı program tarafından değerlendirilmektedir.

4.3. Sıtma Görüntülerinin SVM Tekniđi ile Analizi

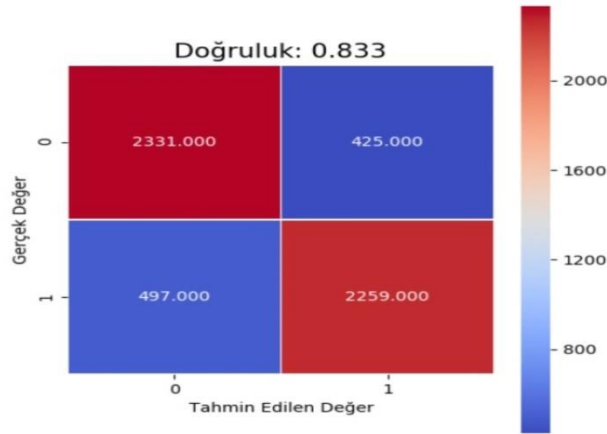
Çalıřmanın bu ařamasında, Destek Vektör Makinesi (SVM) tekniđi ile sıtma görüntülerinin sınıflandırılması incelenmiřtir. Bařlangıçta, müdahaleci hücreler ve etkilenmemiř hücreler görsel olarak, gri tonlama yoluyla ayırt edilmelidir. Tüm görüntüleri gri tonlamaya dönüřtürmek için sıtma veri setinin iřlendiđi yer kullanılır. Bu nedenle, tüm sıtma veri kümesini iřlemeden önce boyutlarını 32x32 piksel olarak deđiřtirerek, hücresel görüntülerin boyutlarını standartlařtırmak gerekmektedir. Sonrasında ise SVM algoritması kullanılmaktadır. Bu amaçla Python programlama dili için geliřtirilmiř olan ve Scikit-learn kütüphanesi içerisinde yer alan Vektör Sınıflandırma (SVC) algoritmalarından faydalanılmıřtır.

Yapılan çalıřmada radyal temel fonksiyonu (RBF) çekirdek fonksiyonu kullanılmıřtır. Fonksiyonda kullanılan parametreler řu řekildedir.

- C = Düzenleme parametresidir. Düzenlemenin gücü, C ile ters orantılıdır. Bu deđer pozitif deđerli olmalıdır. Çok fazla gürültülü gözlemin olduđu durumlarda C deđeri azaltılmalıdır. C , eđitim örneklerinin karar yüzeyinin sadeliđine karřı yanlış sınıflandırılmasını iřlemektedir. Düşük bir C karar yüzeyini düzleřtirir, yüksek bir C ise tüm eđitim örneklerini dođru sınıflandırmayı amaçlar. Ayrıca, büyük C deđerleri bazen 10 kata kadar daha uzun eđitim süresi gerektirebilmektedir.
- γ (*Gamma*) = Çekirdek atsayıdır. *Gamma* deđerleri tek bir eđitim örneđinin ne kadar etkili olduđunu tanımlar. *Gamma* deđerleri arttıka diđer örneklem deđerleri de etkilenmektedir.

Resim sınıflandırma uygulamalarında kullanılan bir yöntem olarak SVM yöntemi de geliřmiř bir regresyon hesaplama yöntemi olarak literatürde yer almaktadır. Bu bağlamda SVM yöntemi bilimsel arařtırmalarda sıklıkla kullanılmaktadır.

Çalıřma kapsamında SVM yöntemi kullanılarak hazırlanan python uygulamasının testi sonucunda oluřan hata matrisi řekil 4.22'de gösterilmiřtir.



Şekil 4.22. SVM yöntemi ile elde edilen hata matrisi

Şekil 4.22. incelendiğinde SVM yöntemi ile yapılan test sonucunda 2,331 adet parazit taşımayan ve 2,259 adet parazit taşıyan resim doğru olarak tahmin edilmiştir. Ancak model, 425 adet parazit taşımayan ve 497 adet de parazit taşıyan resmi yanlış tahmin etmiştir. Model bu haliyle %83.30'lük doğruluk oranı elde edebilmiştir (Çizelge5.1).


SVM yönteminin de CNN yöntemleri gibi resim sınıflandırma işlemlerinde kullanılabileceği ancak doğruluk oranının diğer yöntemlere nazaran düşük kaldığı ve arzu edilen seviyede etkili sonuçlara ulaşamadığı belirlenmiştir.

4.4. CNN ve SVM Yöntemlerinin Birlikte Kullanılması

Çalışma kapsamında, CNN ve SVM modellerinin birlikte kullanılmasına yönelik aşağıdaki işlem basamakları takip edilmiştir;

- Öncelikle her bir sıtma resminin 512 ayrı özellik verisi (image features), CNN modelinin tam bağlı katmanından (fully connected layer) çıkış olarak elde edilmiştir.
- Daha sonra CNN yöntemi kullanılarak elde edilen veriler, SVM yönteminin giriş verisi olarak kullanılmıştır. Diğer bir ifadeyle, CNN modelinin sınıflandırma işlevini SVM modeli üstlenmiştir.

CNN ve SVM yöntemlerinin birleştirilmesi ile oluşturulan katman mimarisi Şekil 4.23'te gösterilmiştir.



Şekil 4.23. CNN ve SVM yöntemlerinin birleştirilmesi ile oluşturulan katman mimarisi (Vijayalakshmi, 2019)

Uygulama kapsamında, CNN ve SVM yöntemlerinin birleştirilmesiyle oluşturulan bu modelin kullanılması deneme amaçlı olarak tercih edilmiştir. Bu sayede her iki modelin birlikte çalışabilirliği tespit edilmiştir. Çalışmanın iki aşamadan oluşması, diğer bir ifadeyle, önce görüntü özelliklerinin belirlenmesi ve sonra ayrı bir hesaplama işlemine tabi tutulması uygulama etkinliğini zayıflatıcı bir unsur olarak karşımıza çıkmaktadır.

5. TARTIŞMA VE ÖNERİLER

5.1 Tartışma

Makine öğrenmesi yöntemlerinin sağlık sektöründe kullanımı artmaktadır. Biyomedikal, sağlık biyoinformatiği ve tıbbi görüntüleme makinesi öğrenme yöntemlerinin en popüler alanlardır. Çeşitli ağ mimarileri ve sağlıkta büyük verilerin analizinde başarılı öğrenme algoritmaları ve derin öğrenme yöntemleri hastalık tanısında ve erken teşhisi açısından önemlidir. Derin öğrenme çalışmalarında, büyük veri önemlidir ve öğrenme modelini verilere uyarlamak, uygulanan modelin doğru çalışmasını etkiler. Derin öğrenme mimarisinde matematiksel model ne kadar iyi anlaşılırsa, derin öğrenme yöntemi gelecekte o kadar başarılı olacaktır.

Birçok bilimsel çalışmada makine öğrenme yöntemleri etkinlikle kullanılmaktadır. Özellikle yapay zeka ve derin öğrenme sistemlerinde Evrimsel Sinir Ağı (CNN) ve Destek Vektör Makinesi (SVM) yöntemleri sağladıkları avantajlarla öne çıkmaktadır. Günümüzde CNN yöntemi ile resim sınıflandırma işlemlerindeki etkinliğin ve yapılan tahminlerdeki doğruluk oranlarının artırılması için birçok metot geliştirilmiştir.

Sıtma hastalığının, parazit taşıyan ve taşımayan kan örneklerine ait tıbbi resimlerin sınıflandırılması yapılarak teşhisinin derin öğrenme teknikleri kullanılarak yapılmasının incelendiği bu çalışmada aşağıda belirtilen hususlar gerçekleştirilmiştir;

- CNN yönteminin ve bu yöntemdeki temel yapı olan katman mimarisinin işleyişinin çalışma kapsamında incelenmesi,
- CNN ve SVM modellerinin Python ve diğer kütüphaneler ile kullanılarak analiz edilmesi,
- Gelişmiş bir CNN tekniği olan Artık Dikkat Ağı (RAN) ve önceden öğretilmiş metodlar (pre-trained methods) olarak bilinen VGG16, ResNet50, InceptionV3 ve AlexNet gibi hazır katman yapılarında çalışma amacına uygun değişiklikler yapılarak görüntülerin sınıflandırmasında kullanılabilirliğinin incelenmesi,
- Bir Makine öğrenme yöntemi olan SVM'nin, sıtma paraziti taşıyan ve taşımayan kan örneklerine ait tıbbi resimlerin sınıflandırılmasında kullanılabilirliği ve diğer yöntemlere göre farklılıklarının belirlenmesi,
- CNN ve SVM yöntemlerinin resim sınıflandırmasında birlikte kullanılabilirliği,

- Analizler neticesinde elde edilen bulguların değerlendirilmesi, ulaşılan sonuçların yorumlanması ve kullanılan modellerin birbirlerine göre avantaj ve dezavantajlarının incelenmesi yapılmıştır.

Tezde kullanılan 27,558 adet sıtma hastalığına ait parazitli ve parazitsiz (infected-uninfected) kan örneklerini içeren smear görüntüleri (Arunava, 2019) ve (Tensorflow, 2019)'dan alınmış, ayrıca ABD Ulusal Tıp Kütüphanesi'nin internet sitesinden (Jaeger, 2019) görüntülerin hangi şartlarda, ne şekilde, nasıl ve kaç hastadan alındığı gibi bilgiler temin edilmiştir. Veri setinden, 20,658 adet malaria smear görüntüsü, modelin eğitim (training) sürecinde kullanılmıştır. Aynı kaynaktan elde edilen 6,900 adet resim de test işlemleri için kullanılmıştır.

Resimlerin orijinal ebatlarının farklı boyutlarda olması sebebiyle derin öğrenme eğitiminde hata payının artabileceği göz önünde bulundurulmuş ve standardizasyon sağlanması ihtiyacı doğmuştur. Bu amaçla, her bir modeldeki giriş katmanına 32x32 boyutlarına indirgeyici dönüştürülme işlemi uygulanmıştır.

Çalışmada kullanılan derin öğrenme modellerinin eğitim sonuçlarına ait bilgiler Çizelge 5.1'de gösterilmiştir.

Çizelge 5.1. Uygulamada kullanılan modellerin eğitim sonuçları

Eğitim Sonuçları	RAN	AlexNet (matlab)	VGG16	InceptionV3	ResNet50	AlexNet	AN
Doğruluk Oranı (Accuracy)	%95.79	%95.31	%95.04	%94.27	%94.37	%92.64	%95.52
Kayıp Oranı (Loss)	0.1186	0.1457	0.1756	0.1711	0.1860	0.2289	0.1382

Çizelge 5.1. incelendiğinde, toplam 20,658 resim ile yapılan eğitim aşamasında RAN modelinin tüm modeller içerisinde %95.79 ile en yüksek eğitim doğruluk orana sahip olduğu belirlenmiştir. RAN modelini, %95.04 ile VGG16, %94.27 ile InceptionV3, %94.37 ile ResNet50 ve %92.64 ile AlexNet, %95.52 AN modelleri takip etmiştir.

Çizelge 5.1'de yer alan ve modellerin kayıp (*loss*) değerlerini içeren veriler incelendiğinde, RAN modeli hariç modellerin nispeten yüksek kayıp değerlerinin olduğu görülmüştür. Bunun sebebinin modellerin eğitim aşamasında uygulanan tekrar (*epoch*) sayılarının az olmasından kaynaklandığı, mimaride değişiklikler yapılarak kayıp oranlarının daha da azaltılabileceği değerlendirilmektedir.

Çalışmada kullanılan derin öğrenme modellerinin görüntü sınıflandırma etkinliklerinin test edilmesi neticesinde elde edilen sonuçlar ise Çizelge 5.2’de gösterilmiştir.

Çizelge 5.2. Uygulamada kullanılan modellerin test sonuçları

Test Sonuçları	RAN	AlexNet (matlab)	VGG16	Inception V3	ResNet50	Alex Net	AN	SVM
Doğruluk	%95.51	%95.87	%94.94	%94.57	%78.16	%93.55	%93.23	%83.30
Duyarlılık	%95.11	%95.47	%95.40	%94.14	%94.83	%89.82	%94.17	%82.42
Birleyicilik	%96.95	%96.27	%94.49	%95.00	%70.53	%98.05	%96.92	%84.13
Kesinlik	%97.01	%95.47	%94.43	%95.04	%59.57	%98.23	%97.01	%84.54
Negatif Öngörü Değeri	%93.00	%95.50	%95.45	%94.09	%96.75	%88.87	%94.00	%81.97
F – Ölçütü	%96.05	%95.87	%94.92	%94.59	%73.17	%93.84	%95.57	%83.47

Çizelge 5.2 incelendiğinde, toplam 6,900 resim ile yapılan test aşamasında RAN modelinin tüm modeller içerisinde %95.51 ile en yüksek test doğruluk oranını elde ettiği tespit edilmiştir. RAN modelini, %94.94 ile VGG16, %94.57 ile InceptionV3, %93.55 ile AlexNet, %78.16 ile de ResNet50 modeli takip etmiştir. Yine Çizelge 5.2’ye göre, SVM modeli %83.30’lik bir doğruluk oranı elde edebilmiş ve CNN modellerinin gerisinde kalmıştır.

Çalışmada ulaşılan sonuçlar özetle şu şekildedir:

- Artık Dikkat Ağı (RAN) modeli kullanılması ile yapılan sıtma görüntülerinin sınıflandırma işleminde %95.51 test doğruluk (accuracy) oranı ile en yüksek başarıyı elde etmiştir. Bu sonuca göre, sıtma hastalığının derin öğrenme yöntemleri ile teşhisinde, RAN modelinin kullanılmasının daha etkili sonuçlar verdiği tespit edilmiştir.
- Önceden öğretilmiş CNN metotları olan VGG16, ResNet50, InceptionV3 ve AlexNet modellerinin birbirlerine göre avantaj ve dezavantajları incelenmiştir. Buna göre, VGG16 modeli %94.94 ile ikinci en başarılı model olmuştur. InceptionV3 %94.57 oran ile üçüncü ve AlexNet modeli %93.55’lik doğruluk oranı ile dördüncü sırada yer almıştır. ResNet50 modelinin ise %78.16 ile resim sınıflandırması amacıyla kullanılacak en başarısız CNN modeli olduğu belirlenmiştir.

- Makine öğrenmesi alanında oldukça başarılı sonuçlar veren SVM yönteminin de sıtma görüntülerinin sınıflandırmasında kullanılabileceği, ancak, diğer gelişmiş derin öğrenme yöntemlerine nazaran %83.30'lık doğruluk oranı ile nispeten düşük bir seviyede kaldığı değerlendirilmiştir.
- Tıbbi resimlerin sınıflandırılması için CNN ve SVM yöntemlerinin uygun tekniklerle birleştirilebileceği, ancak, işlem basamağını artırması ve modelin tekrar kullanılmasına imkan vermemesi nedenlerinden dolayı bu amaçla kullanılmasının etkili ve verimli olmadığı belirlenmiştir.

Yapılan çalışma farklı CNN tekniklerinin incelenmesi sebebiyle geniş kapsamlı bir araştırma özelliği taşımaktadır. Yapılan literatür incelemesinde bu kapsam ve çeşitliliği içeren herhangi bir çalışmanın bulunmadığı görülmüştür. Özellikle çalışmada RAN modelinin incelenmesi ve kullanılabilirliğin test edilmesi ile CNN ve SVM modellerinin birleştirilmesine yönelik hususlar çalışmanın önemini daha da artırmaktadır. Bu yönüyle çalışmanın diğer bilimsel araştırmalara ışık tutacağı ve alana katkı sağlayacağı değerlendirilmektedir.

Sonuç olarak, derin öğrenme modeli ile oluşturulan uygulamalarda modelin eğitim sonucunun iyileştirilmesi ve sistemin etkinliğinin artırılması önemlidir. Bu işlem daha yüksek doğrulukta hastalık paraziti taşıyan ve taşımayan görüntülerin sınıflandırılması anlamına gelmektedir. Geliştirilecek derin öğrenme modeli, toplanan verilerin hastalığın teşhisine yönelik eğitim verileri için yeterli olup olmadığını belirleyen bir uzman konumunda olmaktadır. Yapılan çalışma ile derin öğrenme yöntemlerinin yüksek bir doğrulukla otomatik öğrenme avantajına sahip olduğu belirlenmiştir. Derin öğrenme yöntemleri sayesinde sıtma hastalığının teşhisinde daha az uzmanlık ve daha az kaynak ile daha hızlı ve etkili sonuçlar alınabileceği değerlendirilmektedir.

Bu çalışmada Sıtma hastalığı için Derin Öğrenme'nin, CNN algoritmasının RAN modeli tercih edilmiştir. Sıtma hastalığı üzerine RAN'in tercih edilme sebebi, daha önce bu modelin bu veri setinde kullanılmamış olmasıdır

5.2 Öneriler

Yapılan çalışma neticesinde, tıbbi görüntülerin sınıflandırılmasında derin öğrenme yöntemlerinin kullanılmasına yönelik öneriler belirlenmiştir.

Derin öğrenmede geliştirilen farklı algoritma mimarilerin sıtma hastalığı teşhisinde kullanılarak başarıları değerlendirilebilir.

Mevcut modelin başarısının artırılabilmesi için, farklı mimari ve algoritmalar kullanılabilir, parametreler değiştirilebilir, veri sayısı artırılabilir. Ayrıca bilgisayarın donanım kapasitesinin yükseltilebilir ve k-çapraz doğrulama kullanılabilir. Bu şekilde daha doğrulukta sonuçlar alınabilir. Tıp alanında uzmanlaşmış kişilerin sahip olduğu bilgi birikimi ve deneyimin, derin öğrenme tabanlı sistemler ile birleştirilmesi amacıyla disiplinlerarası akademik çalışmalar teşvik edilmeli, model etkinliği ve çeşitliliğinin artırılması sağlanmalıdır.



KAYNAKLAR

- Achirul Nanda, M., Boro Seminar, K., Nandika, D. ve Maddu, A., 2018, A comparison study of kernel functions in the support vector machine and its application for termite detection, *Information*, 9 (1), 5.
- Akdur, R., 2001, Sıtma. Koordinatörlüğü, T. S. B. S. S. D. B. v. S. P. G., Ankara. 1. Basım.
- Akilotu, B., Kadiroğlu, Z., Sengur, A. ve Kayaoğlu, M., 2019, Malaria Detection using both Convolutional Neural Networks and Transfer Learning Method, p.
- Akküçük, U., 2011, VERİ MADENCİLİĞİ, *YALIN YAYINCILIK*
Ordu Caddesi Özbek Çarşısı No. 25 / 41 (İstanbul), 51.
- Aktuglu, Y. S., 1992, İç Hastalıkları Ders Notları. 3. basım, 2. cilt, *Cerrahpaşa Tıp Fakültesi, İstanbul*, 124-135.
- Aladago, M. M., 2018, Classification and quantification of malaria parasites using convolutional neural networks.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Van Esesn, B. C., Awwal, A. A. S. ve Asari, V. K., 2018, The history began from alexnet: A comprehensive survey on deep learning approaches, *arXiv preprint arXiv:1803.01164*.
- Altıntaş, K., 2002, Tıbbi parazitoloji, *Kozan Ofset, 1. Baskı*, Nobel Tıp, p. 181-222.
- Anwar, A., 2019, Difference between AlexNet, VGGNet, ResNet and Inception, <https://towardsdatascience.com/the-w3h-of-alexnet-vggnet-resnet-and-inception-7baaecccc96>, (03.10.2019).
- Arunava, 2019, Malaria Cell Images Dataset, <https://www.kaggle.com/iarunava/cell-images-for-detecting-malariaAccess>, Erişim tarihi: 04.09.2019.
- Azif, F. M., Nugroho, H. A. ve Wibirama, S., 2018, Detection of malaria parasites in thick blood smear: A review, *Communications in Science and Technology*, 3 (1), 27-35.
- Bengio, Y., Lamblin, P., Popovici, D. ve Larochelle, H., 2007, Greedy layer-wise training of deep networks, *Advances in neural information processing systems*, 153-160.
- Beysolow II, T., 2017, Introduction to Deep Learning, In: Introduction to Deep Learning Using R, Eds: Springer, p. 1-9.
- Bibin, D., Nair, M. S. ve Punitha, P., 2017, Malaria parasite detection from peripheral blood smear images using deep belief networks, *IEEE Access*, 5, 9099-9108.
- Blanc, F., Blanc, F. P. ve Blanc, B., 1992, Geschichte der Tropfenmedizin. , *Vaduz*, Band 5, 2539-2579.
- Brownlee, J., 2019, Attention in Long Short-Term Memory Recurrent Neural Networks, <https://machinelearningmastery.com/attention-long-short-term-memory-recurrent-neural-networks>, Erişim tarihi: 10.09.2019.
- Das, D. K., Ghosh, M., Pal, M., Maiti, A. K. ve Chakraborty, C., 2013, Machine learning approach for automated screening of malaria parasite using light microscopic images, *Micron*, 45, 97-106.
- Dobaño, C., Ubillos, I., Jairoce, C., Gyan, B., Vidal, M., Jiménez, A., Santano, R., Dosoo, D., Nhabomba, A. J. ve Ayestaran, A., 2019, RTS, S/AS01E immunization increases antibody responses to vaccine-unrelated Plasmodium falciparum antigens associated with protection against clinical malaria in African children: a case-control study, *BMC medicine*, 17 (1), 157.

- Dong, Y., Jiang, Z., Shen, H., Pan, W. D., Williams, L. A., Reddy, V. V., Benjamin, W. H. ve Bryan, A. W., 2017, Evaluations of deep convolutional neural networks for automatic identification of malaria infected cells, *2017 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, 101-104.
- Fleischer, B., 2004, 100 years ago: Giemsa's solution for staining of plasmodia, *Tropical Medicine and International Health*, 9 (7), 755-756.
- Glowacz, A., 2015, Recognition of acoustic signals of induction motor using fft, smofs-10 and isvm, *Eksploracja i Niezawodność*, 17 (4).
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. ve Bengio, Y., 2014, Generative adversarial nets, *Advances in neural information processing systems*, 2672-2680.
- Goyal, P., Pandey, S. ve Jain, K., 2018, Deep Learning for Natural Language Processing: Creating Neural Networks with Python, <https://doi.org/10.1007/978-1-4842-3685-7>. New York. USA, Apress, p. 100-125.
- Hinton, G. E., Osindero, S. ve Teh, Y.-W., 2006, A fast learning algorithm for deep belief nets, *Neural computation*, 18 (7), 1527-1554.
- Hinton, G. E., 2012, A practical guide to training restricted Boltzmann machines, In: *Neural networks: Tricks of the trade*, Eds: Springer, p. 599-619.
- Hochreiter, S. ve Schmidhuber, J., 1997, Long short-term memory, *Neural computation*, 9 (8), 1735-1780.
- Hung, J. ve Carpenter, A., 2017, Applying faster R-CNN for object detection on malaria images, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 56-61.
- Jaeger, S., 2019, Malaria Datasets, <https://lhncbc.nlm.nih.gov/publication/pub9932>, Erişim tarihi: 04.09.2019.
- Kingma, D. P. ve Welling, M., 2013, Auto-encoding variational bayes, *arXiv preprint arXiv:1312.6114*.
- Kocaçıftçi, İ., 2008, Plasmodium Vivax'ın Tanısında kalın Damla İle İmmünokromatografik Yöntemlerin Karşılaştırılması, *Uzmanlık Tezi*, Çukurova Üniversitesi Tıp fakültesi Parazitoloji Anabilim Dalı, <https://docplayer.biz.tr/18954718-Uzmanlik-tezi-tez-danismani-doc-dr-i-soner-koltas.html>, Erişim tarihi: 04.09.2019.
- Ledingham, J. ve Warrel, D., 2000, *Concise Oxford Textbook of Medicine*, Malaria, Oxford.
- Lynne, S. G. ve Bruckner, D., 1997, *Diagnostic Medical Parasitology* 3rd Edit. Washington D. C, ASM Press.
- Markell, E., Voge, M. ve John, D., 1999, *Medical Parasitology*. Philadelphia, WB Saunders.
- Mehanian, C., Jaiswal, M., Delahunt, C., Thompson, C., Horning, M., Hu, L., Ostbye, T., McGuire, S., Mehanian, M. ve Champlin, C., 2017, Computer-automated malaria diagnosis and quantitation using convolutional neural networks, *Proceedings of the IEEE International Conference on Computer Vision*, 116-125.
- Merdivenci, A., 1984, Türkiye sivrisinekleri:(Yurdumuzda varlığı bilinen sivrisineklerin biyo-morfolojisi, biyo-ekolojisi, yayılışı ve sağlık önemleri), İÜ Cerrahpaşa Tıp Fak., p.
- Murugan, P., 2018, Implementation of deep convolutional neural network in multi-class categorical image classification, *arXiv preprint arXiv:1801.01397*.

- Nandika, D., Rismayadi, Y. ve Diba, F., 2015, Rayap: Biologi dan Pengendaliannya, Edisi ke-2 [Termite: Biology and its Control,], *Universitas Muhammadiyah Surakarta, Surakarta, Indonesia*.
- Okursoy, A., 2010, Türkiye'de sağlık sistemi ve kamu hastanelerinin performanslarının değerlendirilmesi.
- Özcel, E. M. A., 1999, Sıtma. Türkiye Parazitoloji Derneği Yayınları, İzmir.
- Özcel, M. A., 2007, Tıbbi Parazit Hastalıkları, *Türkiye Parazitoloji Derneği Yayını* (22), 3-68.
- Pan, W. D., Dong, Y. ve Wu, D., 2018, Classification of Malaria-Infected Cells Using Deep Convolutional Neural Networks, *Machine Learning: Advanced Techniques and Emerging Applications*, 159.
- Peng, M., Wang, C., Chen, T., Liu, G. ve Fu, X., 2017, Dual temporal scale convolutional neural network for micro-expression recognition, <https://www.frontiersin.org/articles/10.3389/fpsyg.2017.01745/full>, Erişim tarihi: 10.09.2019, *Frontiers in psychology*, 8, 1745.
- Poostchi, M., Ersoy, I., McMenamin, K., Gordon, E., Palaniappan, N., Pierce, S., Maude, R. J., Bansal, A., Srinivasan, P. ve Miller, L., 2018a, Malaria parasite detection and cell counting for human and mouse using thin blood smear microscopy, *Journal of Medical Imaging*, 5 (4), 044506.
- Poostchi, M., Silamut, K., Maude, R. J., Jaeger, S. ve Thoma, G., 2018b, Image analysis and machine learning for detecting malaria, *Translational Research*, 194, 36-55.
- Quinn, J. A., Nakasi, R., Mugagga, P. K., Byanyima, P., Lubega, W. ve Andama, A., 2016, Deep convolutional neural networks for microscopy-based point of care diagnostics, *Machine Learning for Healthcare Conference*, 271-281.
- Rajaraman, S., Antani, S. K., Poostchi, M., Silamut, K., Hossain, M. A., Maude, R. J., Jaeger, S. ve Thoma, G. R., 2018, Pre-trained convolutional neural networks as feature extractors toward improved malaria parasite detection in thin blood smear images, *PeerJ*, 6, e4568.
- Raschka, S. ve Mirjalili, V., 2017, Python machine learning, Packt Publishing Ltd, p.
- Razzak, M. I. ve Naz, S., 2017, Microscopic blood smear segmentation and classification using deep contour aware CNN and extreme machine learning, *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 801-807.
- Rothman, D., Lamons, M., Kumar, R., Nagaraja, A., Ziai, A. ve Dixit, A., 2018, Python: Beginner's Guide to Artificial Intelligence: Build applications to intelligently interact with the world around you using Python, Packt Publishing Ltd, p. 85-135.
- Sağlık Bakanlığı, H., Turan BUZGAN, Fatma Şebnem ERDİNÇ, Hasan IRMAK, Seher TOPLUOĞLU, Necla TÜLEK.,, 2019, Sıtma Vaka Yönetimi Rehberi, *T.C. Sağlık Bakanlığı*.
- Saygı, G., 1998, Temel tıbbi parazitoloji, Esnaf ofset matbaacılık, 1. Baskı, Sivas, p. 71-85.
- Schulte, J., Staps, D. ve Lampe, A., 2019, A feasibility study of deep neural networks for the recognition of banknotes regarding central bank requirements, *arXiv preprint arXiv:1907.07890*.
- Şeker, A., Diri, B. ve Balık, H. H., 2017, Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3 (3), 47-64.
- Simonyan, K. ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*.

- Sorgedraeger, R., 2018, High sensitive malaria diagnosis using convolutional.
- Taşkın, A., 2010, Sıtma hastalarında lökositlerin oksidatif stresinin araştırılması/Investigation of Leukocytes' oxidative stress in patients with malaria.
- Tensorflow, 2019, Malaria, <https://www.tensorflow.org/datasets/catalog/malaria>, Erişim tarihi: 04.09.2019.
- Unat, E. K., Yücel, A., Altaş, K. ve Samastı, M., 1995, Unat'ın Tıp parazitolojisi, *Baskı Cerr Tıp Fak. Vakfı Yay*, 15, 206-208.
- Vasilev, I., Slater, D., Spacagna, G., Roelants, P. ve Zocca, V., 2019, Python Deep Learning: Exploring deep learning techniques and neural network architectures with PyTorch, Keras, and TensorFlow, *Packt Publishing*, USA.
- Vijayalakshmi, A., 2019, Deep learning approach to detect malaria from microscopic images, *Multimedia Tools and Applications*, 1-21.
- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y. ve Manzagol, P.-A., 2010, Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion, *Journal of machine learning research*, 11 (Dec), 3371-3408.
- Wang, F., Jiang, M., Qian, C., Yang, S., Li, C., Zhang, H., Wang, X. ve Tang, X., 2017a, Residual attention network for image classification, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 3156-3164.
- Wang, S., Phillips, P., Liu, A. ve Du, S., 2017b, Tea category identification using computer vision and generalized eigenvalue proximal svm, *Fundamenta Informaticae*, 151 (1-4), 325-339.
- Xu, K., Ba, J., Kiros, R., Cho, K., Courville, A., Salakhudinov, R., Zemel, R. ve Bengio, Y., 2015, Show, attend and tell: Neural image caption generation with visual attention, *International conference on machine learning*, 2048-2057.
- Yu, S., Li, P., Lin, H., Rohani, E., Choi, G., Shao, B. ve Wang, Q., 2013, Support vector machine based detection of drowsiness using minimum EEG features, *2013 International Conference on Social Computing*, 827-835.
- Zhang, A., Lipton, Z. C., Li, M. ve Smola, A. J., 2019, Dive into Deep Learning, <https://www.d2l.ai/>, Erişim tarihi: 17.09.2019.
- Zhang, Y. ve Wu, L., 2012, Classification of fruits using computer vision and a multiclass support vector machine, *sensors*, 12 (9), 12489-12505.
- Zhang, Y., Dong, Z., Wang, S., Ji, G. ve Yang, J., 2015, Preclinical diagnosis of magnetic resonance (MR) brain images via discrete wavelet packet transform with Tsallis entropy and generalized eigenvalue proximal support vector machine (GEPSVM), *Entropy*, 17 (4), 1795-1813.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Mohanad Mohammed QANBAR
Uyuşu : IRAK
Doğum Yeri ve Tarihi : IRAK 01/01/1986
Telefon : 05387307484
Faks :
e-mail : mmqn.1986@gmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Tuz Erkek lisesi / Salahaddin/IRAK	2006
Üniversite	: Jaafer Sadak University/College of Information Technology / Baghdad	2009
Yüksek Lisans	: Selçuk Üniversitesi Bilişim Teknolojileri Mühendisliği Anabilim Dalı Konya / Türkiye	2018 -
Doktora	:	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi

UZMANLIK ALANI : Yazılım, Donanım

YABANCI DİLLER : İngilizce, Arapça, Türkçe

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR:

1. M. Qanbar, S. Tasdemir, (2019). Classification with Deep Learning: Malaria Images Example, *Gece Akademi Yayınevi*, Çankaya, Ankara, Türkiye, 291-308 pp.
2. M. Qanbar, S. Tasdemir, (2019). Detection of Malaria Diseases with Residual Attention Network, *International Journal of Intelligent Systems and Applications in Engineering*, 7(4), 238-244pp.
3. M. Qanbar, S. Tasdemir, (2019). Deep Learning Algorithm for Atrial Fibrillation Detection, *International Symposium on Implementations of Digital Industry and Management of Digital Transformation*, Konya, 192-202 pp.