

**T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



**BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİ ÜZERİNDE
DERİN ÖĞRENME TABANLI COVID- 19 TEŞHİSİNE
YÖNELİK HEKİM KARAR DESTEK SİSTEMİ TASARIMI**

Oğuzhan KATAR

Yüksek Lisans Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

HAZİRAN 2022

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

**BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİ ÜZERİNDE DERİN
ÖĞRENME TABANLI COVID- 19 TEŞHİSİNE YÖNELİK HEKİM
KARAR DESTEK SİSTEMİ TASARIMI**

Tez Yazarı
Oğuzhan KATAR

Danışman
Dr. Öğr. Üyesi Erkan DUMAN

HAZİRAN 2022
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Bilgisayarlı Tomografi Görüntüleri Üzerinde Derin Öğrenme Tabanlı COVID- 19 Teşhisine Yönelik Hekim Karar Destek Sistemi Tasarımı
Yazarı:	Oğuzhan KATAR
İlk Teslim Tarihi:	23.05.2022
Savunma Tarihi:	28.06.2022

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Dr. Öğr. Üyesi Erkan DUMAN Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Doç. Dr. Murat KARABATAK Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Muhammed YILDIRIM Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Bilgisayarlı Tomografi Görüntüleri Üzerinde Derin Öğrenme Tabanlı COVID- 19 Teşhisine Yönelik Hekim Karar Destek Sistemi Tasarımı” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

28.06.2022

Oğuzhan KATAR



ÖNSÖZ

COVID-19 pandemisinin yıkıcı etkileri sebebiyle birçok kişi fiziksel, sosyal, ekonomik veya psikolojik zararlara maruz kalmıştır. Bu tür zararları minimize etmek için COVID-19 hastalığının tespitinin erken yapılması ve gerekli önlemlerin alınması gerekmektedir. COVID-19 hastalığının damlacık yoluyla bulaştığı bilinmektedir. Bu sebeple COVID-19 hastalarının toplumla temasının en aza indirgenmesi gerekmektedir. COVID-19 hastalarının erken ve hızlı tespit edilmesi süreçlerinde gelişmiş işlem kapasitesine sahip bilgisayarlardan destek alınabilir. Gelişmiş işlem kapasitesine sahip bilgisayara derin öğrenme yöntemleriyle kazandırılacak sınıflandırma ve bölütleme yeteneği sayesinde hekimlerin karar verme aşamasında yapay sistemler yardımıyla destek sağlanabilir. Bu sayede COVID-19'un belirtilen yıkıcı etkilerinin önüne geçilebilir.

Bu tez çalışmasında bilgi ve deneyimleri ile beni destekleyen ve her konuda yardımcı olan, sayın danışman hocam Dr. Öğr. Üyesi Erkan DUMAN'a teşekkürlerimi sunarım. Radyolojik görüntülerin sağlanmasında, yorumlanmasında, işaretlenmesinde ve diğer tüm idari süreçlerde desteklerini esirgemeyen Elazığ Fethi Sekin Şehir Hastanesi Başhekimliği ve Bilgi Teknolojileri Birimi personellerine teşekkür ederim.

Bu tez çalışması, T.C Fırat Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulunun 18/03/2021 tarih ve 2021/04-40 sayılı izni ile gerçekleştirilmiştir.

Oğuzhan KATAR
ELAZIĞ, 2022

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xiii
EKLER LİSTESİ	xiv
SİMGELER VE KISALTMALAR	xv
1. GİRİŞ	1
1.1. Tezin Organizasyonu	8
2. KORONAVİRÜS	10
2.1. COVID-19	10
2.1.1. Bulaş.....	11
2.1.2. Klinik Özellikler.....	11
2.1.3. Tespit Yöntemleri.....	11
3. YAPAY ZEKA	14
3.1. Yapay Sinir Ağları.....	14
3.1.1. Tek Katmanlı Algılayıcılar.....	18
3.1.2. Çok Katmanlı Algılayıcılar	19
3.2. Derin Öğrenme	20
3.2.1. Evrişimli Sinir Ağları	20
3.2.2. Transfer Öğrenme	24
4. AKCİĞER GÖRÜNTÜLERİNİN SINIFLANDIRILMASI	25
4.1. EFSCH-19 Veri Seti	26
4.1.1. Radyolojik Altyapı	27
4.1.2. Raporlama Standartlarına Uygunluk	29
4.2. Sınıflandırıcı Derin Öğrenme Mimarisi.....	30
4.3. Sınıflandırıcı Derin Öğrenme Model Eğitimi	33
4.3.1. Önerilen Eğitim Kurgusu	33
4.3.2. Ön İşlem Adımları.....	35
4.4. Değerlendirme Metrikleri	36
4.5. Gradyan Ağırlıklı Sınıf Aktivasyon Eşleşmesi.....	38
4.6. Test Aşamasında Elde Edilen Bulgular	40
4.6.1. EfficientNet-B0 Modeli Bulguları.....	40
4.6.2. EfficientNet-B1 Modeli Bulguları.....	43
4.6.3. EfficientNet-B2 Modeli Bulguları.....	46
4.6.4. EfficientNet-B3 Modeli Bulguları.....	49
4.6.5. EfficientNet-B4 Modeli Bulguları.....	52
4.6.6. EfficientNet-B5 Modeli Bulguları.....	55
4.6.7. EfficientNet-B6 Modeli Bulguları.....	58
4.6.8. EfficientNet-B7 Modeli Bulguları.....	61

5. ENFEKSİYON VE AKCİĞER ALANLARININ BÖLÜTLENMESİ.....	64
5.1. EFSCH-19-Seg Veri Seti.....	65
5.2. Anlamsal Bölütleyici Derin Öğrenme Mimarisi	67
5.2.1. Kodlayıcı Ağ.....	67
5.2.2. Kod Çözücü Ağ.....	67
5.3. Anlamsal Bölütleyici Derin Öğrenme Model Eğitimi	68
5.3.1. Önerilen Eğitim Kurgusu	68
5.4. Ön İşlem Adımları	70
5.5. Değerlendirme Metrikleri	72
5.5.1. Piksel Doğruluğu.....	72
5.5.2. Jaccard İndeksi ve Dice Skoru	73
5.6. Test Aşamasında Elde Edilen Bulgular	75
5.6.1. ResNet-18 Tabanlı U-Net Modeli Bulguları	75
5.6.2. ResNet-34 Tabanlı U-Net Modeli Bulguları	78
5.6.3. ResNet-50 Tabanlı U-Net Modeli Bulguları	81
5.6.4. ResNet-101 Tabanlı U-Net Modeli Bulguları	84
5.6.5. ResNet-152 Tabanlı U-Net Modeli Bulguları	87
5.7. Görüntü Birleştirme Yöntemi	90
5.7.1. Birleştirilmiş Görüntü Tahminleri	91
6. SONUÇ.....	94
ÖNERİLER	96
KAYNAKLAR.....	97
EKLER	102
ÖZGEÇMİŞ	

ÖZET

Bilgisayarlı Tomografi Görüntüleri Üzerinde Derin Öğrenme Tabanlı COVID- 19 Teşhisine Yönelik Hekim Karar Destek Sistemi Tasarımı

Oğuzhan KATAR

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Haziran 2022, Sayfa: xv + 101

COVID-19 pandemisi tüm dünyayı birçok yönden olumsuz etkilemektedir. Ortaya çıktığı günden bu yana olumsuzluklarının çözümü için çeşitli yöntem ve yaklaşımların geliştirilmesine neden olmuştur. Bu çözüm arayışlarının ortak hedefi, COVID-19'un zararlarını en aza indirgeyebilmektir. Bu tez çalışmasında radyoloji uzmanlarına, göğüs bilgisayarlı tomografi görüntülerinden COVID-19 hastalığının tespit edilmesi sürecinde yardımcı olması için derin öğrenme tabanlı bir sistem tasarlanmıştır. Derin öğrenme tabanlı bu sistem sınıflandırma ve anlamsal bölütleme yeteneğine sahip iki farklı model üzerine kurgulanmıştır. Sınıflandırma yeteneğinin bilgisayara kazandırılması ve COVID-19 pozitif veya COVID-19 negatif bulgularına sahip göğüs bilgisayarlı tomografi görüntülerinin ayırt edilmesinde EfficientNet model ailesi üyelerinden yararlanılmıştır. Sekiz farklı EfficientNet model ailesi üyesi, T.C Sağlık Bakanlığı tarafından verilen izin sayesinde gerçek hasta görüntüleriyle oluşturduğumuz EFSCH-19 adlı veri seti örnekleriyle eğitilmiştir. Eğitim süreci sonucunda gerçekleştirilen test aşamasında %99.75 doğruluk, %99.50 duyarlılık, %100 kesinlik, %100 özgüllük, %99.75 F1-Skoru ve %99.50 MCC oranına ulaşan EfficientNet-B2 modeli sınıflandırıcı derin öğrenme modeli olarak seçilmiştir. Sınıflandırıcı derin öğrenme modeline giriş olarak verilen göğüs BT görüntüsü, çıkışta ikili sınıflandırma yöntemine uygun olarak COVID-19 pozitif veya COVID-19 negatif olarak tahmin edilmektedir. Anlamsal bölütleme yeteneğinin bilgisayara kazandırılabilmesi için göğüs BT görüntülerinde yer alan piksellerin hangi sınıfa ait olduğu bilgisi tanımlanmalıdır. Bu kapsamda EFSCH-19 veri setinde yer alan 200 adet göğüs bilgisayarlı tomografi görüntüsüne karşılık maske görselleri radyoloji uzmanı tarafından elle işaretlenerek EFSCH-19-Seg adını verdiğimiz ikinci veri seti oluşturulmuştur. Oluşturulan maske görsellerinde akciğer alanları, enfeksiyon alanları ve geriye kalan diğer alanları temsil etmek üzere üç adet farklı piksel değeri bulunmaktadır. EFSCH-19-Seg veri seti yardımıyla U-Net model eğitimleri gerçekleştirilmiştir. Bu eğitimlerde U-Net modelinin varsayılan kodlayıcı ağı yerine ResNet model ailesinde yer alan beş farklı modelden yararlanılmıştır. Resnet-50 tabanlı U-Net modeli diğer modellere kıyasla %93.76 Jaccard indeksi ve %96.61 Dice skoru değerleriyle test aşamasını en iyi tamamlayan model olmuştur. Bu tez kapsamında, sınıflandırma ve anlamsal bölütleme görevleri için elde edilen başarılı sonuçlar neticesinde COVID-19 pandemisiyle mücadelede hızlı bir şekilde sahaya entegre edilebilecek bir hekim karar destek sistemi önerilmiştir.

Anahtar Kelimeler: COVID-19, Sınıflandırma, Anlamsal Bölütleme, EfficientNet, U-Net, BT

ABSTRACT

Deep Learning Based Physician Decision Support System Design for COVID-19 Diagnosis on Computed Tomography Images

Oğuzhan KATAR

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

June 2022, Pages: xv + 101

COVID-19 pandemic negatively affects the whole world in many ways. Since its emergence, it has led to the development of various methods and approaches for the solution of its negativities. The common goal of these search for solutions is to minimize the damages of COVID-19. In this thesis, a deep learning-based system was designed to assist radiologists in the process of detecting COVID-19 disease from chest computed tomography images. This deep learning-based system is built on two different models capable of classification and semantic segmentation. Members of the EfficientNet model family were used to gain the classification capability of the computer and to distinguish the chest computed tomography images with COVID-19 positive or COVID-19 negative findings. Eight different EfficientNet model family members were trained with the EFSCH-19 dataset samples, which we created with real patient images, thanks to the permission given by the Ministry of Health of the Republic of Turkey. EfficientNet-B2 model, which reached 99.75% accuracy, 99.50% sensitivity, 100% precision, 100% specificity, 99.75% F1-Score and 99.50% MCC rate, was chosen as the classifier deep learning model in the test phase carried out as a result of the training process. The chest computed tomography image, which is given as input to the classifier deep learning model, is estimated as COVID-19 positive or COVID-19 negative by the binary classification method at the output. In order to gain the semantic segmentation capability of the computer, the information of which class the pixels in the chest computed tomography images belong to must be defined. In this context, the mask images were manually marked by the radiologist with 200 chest computed tomography images in the EFSCH-19 dataset, and the second dataset, which we named EFSCH-19-Seg, was created. In the mask images created, there are three different pixel values to represent lung areas, infection areas and the remaining areas. U-Net models trainings was carried out with the help of the EFSCH-19-Seg dataset. In these trainings, instead of the default encoder network of the U-Net model, five different models in the ResNet model family were used. Compared to other models, the ResNet-50-based U-Net model was the model that best completed the test phase with 93.76% Jaccard index and 96.61% Dice score values. In this thesis, as a result of the successful results obtained for classification and semantic segmentation tasks, a physician decision support system that can be quickly integrated into the field in the fight against the COVID-19 pandemic has been proposed.

Keywords: COVID-19, Classification, Semantic Segmentation, EfficientNet, U-Net, CT

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Koranvirüslerin Şematik Yapısı.....	10
Şekil 2.2. NF Sürüntü Örneğinin Alınması	10
Şekil 2.3. Göğüs X-ışını ve BT Taraması Örnekleri	13
Şekil 3.1. Biyolojik Sinir Hücresi ve Alt Bileşenleri	14
Şekil 3.2. Yapay Sinir Hücresi.....	15
Şekil 3.3. Basamak ve Doğrusal Aktivasyon Fonksiyonu Değer Grafikleri	16
Şekil 3.4. Sigmoid ve Softmax Aktivasyon Fonksiyonu Değer Grafikleri.....	17
Şekil 3.5. ReLU ve HT Aktivasyon Fonksiyonu Değer Grafikleri	18
Şekil 3.6. Tek Katmanlı Algılayıcı	19
Şekil 3.8. ESA Mimarisi	21
Şekil 3.9. Özellik Çıkarımı Örneği	21
Şekil 3.10. Dolgulama Yöntemi Çıktısı	22
Şekil 3.11. Maksimum Havuzlama Yöntemi	23
Şekil 3.12. Düzleştirme Yöntemi.....	24
Şekil 3.13. Transfer Öğrenme Yönteminin İşleme Mantığı.....	24
Şekil 4.1. Tasarlanan Sınıflandırıcı Sistem	25
Şekil 4.2. ‘SARS-CoV-2 CT-scan’ Veri Setinde Yanlış Etiketlendirilmiş Örnekler	25
Şekil 4.3. Halka Açık Veri Setindeki Farklı Standartta Sahip Örnekler	26
Şekil 4.4. EFSCCH-19’un Buzlu Cam Opasitesi Örnekleri	27
Şekil 4.5. EFSCCH-19’un Konsolidasyon Örnekleri	27
Şekil 4.6. EFSCCH-19’un Kaldırım Taşı Görünümü Örnekleri.....	28
Şekil 4.7. EFSCCH-19’un Hava Kabarcığı Örnekleri	28
Şekil 4.8. EFSCCH-19’un COVID-19 Negatif Örnekleri	29
Şekil 4.9. EFSCCH-19’un 3-Boyutlu t-SNE Grafiği.....	29
Şekil 4.10. EfficientNet-B0 Temel Ağ Yapısı	31
Şekil 4.11. EfficientNet Ölçeklendirme Yöntemleri	32
Şekil 4.12. ImageNet Doğruluk Karşılaştırılması	33
Şekil 4.13. Önerilen Sınıflandırıcı Model Eğitim Kurgusu.....	34
Şekil 4.14. DICOM-JPEG Dönüşümü	35
Şekil 4.15. Yeniden Boyutlandırma İşlemi	35
Şekil 4.16. Veri Bölme İşlemi.....	36

Şekil 4.17.	Karışıklık Matrisi Yapısı	37
Şekil 4.18.	Grad-CAM Algoritması Yaklaşımı.....	38
Şekil 4.19.	EfficientNet-B0 Modeli Son Evrişimli Katmanı.....	39
Şekil 4.20.	Örnek Grad-CaM Çıktıları	39
Şekil 4.21.	EfficientNet-B0'ın Kayıp ve Doğruluk Grafiği	40
Şekil 4.22.	EfficientNet-B0'ın Karışıklık Matrisi.....	40
Şekil 4.23.	EfficientNet-B0'ın Başarılı Tahmin Örnekleri	41
Şekil 4.24.	EfficientNet-B0'ın Başarısız Tahmin Örnekleri	41
Şekil 4.25.	EfficientNet-B0'ın Grad-CAM Çıktıları.....	42
Şekil 4.26.	EfficientNet-B1'in Kayıp ve Doğruluk Grafiği	43
Şekil 4.27.	EfficientNet-B1'in Karışıklık Matrisi.....	43
Şekil 4.28.	EfficientNet-B1'in Başarılı Tahmin Örnekleri	44
Şekil 4.29.	EfficientNet-B1'in Başarısız Tahmin Örnekleri	44
Şekil 4.30.	EfficientNet-B1'in Grad-CAM Çıktıları.....	45
Şekil 4.31.	EfficientNet-B2'nin Kayıp ve Doğruluk Grafiği	46
Şekil 4.32.	EfficientNet-B2'nin Karışıklık Matrisi	46
Şekil 4.33.	EfficientNet-B2'nin Başarılı Tahmin Örnekleri	47
Şekil 4.34.	EfficientNet-B2'nin Başarısız Tahmin Örnekleri	47
Şekil 4.35.	EfficientNet-B2'nin Grad-CAM Çıktıları.....	48
Şekil 4.36.	EfficientNet-B3'ün Kayıp ve Doğruluk Grafiği	49
Şekil 4.37.	EfficientNet-B3'ün Karışıklık Matrisi	49
Şekil 4.38.	EfficientNet-B3'ün Başarılı Tahmin Örnekleri	50
Şekil 4.39.	EfficientNet-B3'ün Başarısız Tahmin Örnekleri	50
Şekil 4.40.	EfficientNet-B3'ün Grad-CAM Çıktıları.....	51
Şekil 4.41.	EfficientNet-B4'ün Kayıp ve Doğruluk Grafiği	52
Şekil 4.42.	EfficientNet-B4'ün Karışıklık Matrisi	52
Şekil 4.43.	EfficientNet-B4'ün Başarılı Tahmin Örnekleri	53
Şekil 4.44.	EfficientNet-B4'ün Başarısız Tahmin Örnekleri	53
Şekil 4.45.	EfficientNet-B4'ün Grad-CAM Çıktıları.....	54
Şekil 4.46.	EfficientNet-B5'in Kayıp ve Doğruluk Grafiği	55
Şekil 4.47.	EfficientNet-B5'in Karışıklık Matrisi.....	55
Şekil 4.48.	EfficientNet-B5'in Başarılı Tahmin Örnekleri	56
Şekil 4.49.	EfficientNet-B5'in Başarısız Tahmin Örnekleri	56
Şekil 4.50.	EfficientNet-B5'in Grad-CAM Çıktıları.....	57

Şekil 4.51.	EfficientNet-B6'nın Kayıp ve Doğruluk Grafiği	58
Şekil 4.52.	EfficientNet-B6'nın Karışıklık Matrisi	58
Şekil 4.53.	EfficientNet-B6'nın Başarılı Tahmin Örnekleri	59
Şekil 4.54.	EfficientNet-B6'nın Başarısız Tahmin Örnekleri	59
Şekil 4.55.	EfficientNet-B6'nın Grad-CAM Çıktıları.....	60
Şekil 4.56.	EfficientNet-B7'nin Kayıp ve Doğruluk Grafiği	61
Şekil 4.57.	EfficientNet-B7'nin Karışıklık Matrisi	61
Şekil 4.58.	EfficientNet-B7'nin Başarılı Tahmin Örnekleri	62
Şekil 4.59.	EfficientNet-B7'nin Başarısız Tahmin Örnekleri	62
Şekil 4.60.	EfficientNet-B7'nin Grad-CAM Çıktıları.....	63
Şekil 5.1.	Tasarlanan Bölütleyici Sistem	64
Şekil 5.2.	Maske Görüntüsü Oluşturma Adımları	65
Şekil 5.3.	Maske Görüntülerinde Kullanılan Renklendirme Yapısı.....	65
Şekil 5.4.	EFSCH-19-Seg Veri Seti Örneği	66
Şekil 5.5.	U-Net Mimarisi.....	67
Şekil 5.6.	Önerilen Bölütleyici Model Eğitim Kurgusu	69
Şekil 5.7.	Renk Modu ve Piksel Bazlı Değer Değiştirme İşlemi	70
Şekil 5.8.	Görüntü Parçalama İşlemi	71
Şekil 5.9.	Veri Bölme İşlemi.....	72
Şekil 5.10.	PD Değeri Bileşenleri	73
Şekil 5.11.	IoU ve DS Değeri Bileşenleri	74
Şekil 5.12.	ResNet-18 Tabanlı U-Net'in Kayıp ve Doğruluk Grafiği.....	75
Şekil 5.13.	ResNet-18 Tabanlı U-Net Tahminleri.....	75
Şekil 5.14.	ResNet-18 Tabanlı U-Net Tahminlerinde Oluşan YP ve YN Bulgular	76
Şekil 5.15.	ResNet-18 Tabanlı U-Net Tahminlerinde Oluşan Kesişimler ve Birleşimler	77
Şekil 5.16.	ResNet-34 Tabanlı U-Net'in Kayıp ve Doğruluk Grafiği.....	78
Şekil 5.17.	ResNet-34 Tabanlı U-Net Tahminleri.....	78
Şekil 5.18.	ResNet-34 Tabanlı U-Net Tahminlerinde Oluşan YP ve YN Bulgular	79
Şekil 5.19.	ResNet-34 Tabanlı U-Net Tahminlerinde Oluşan Kesişimler ve Birleşimler	80
Şekil 5.20.	ResNet-50 Tabanlı U-Net'in Kayıp ve Doğruluk Grafiği.....	81
Şekil 5.21.	ResNet-50 Tabanlı U-Net Tahminleri.....	81
Şekil 5.22.	ResNet-50 Tabanlı U-Net Tahminlerinde Oluşan YP ve YN Bulgular	82
Şekil 5.23.	ResNet-50 Tabanlı U-Net Tahminlerinde Oluşan Kesişimler ve Birleşimler	83
Şekil 5.24.	ResNet-101 Tabanlı U-Net'in Kayıp ve Doğruluk Grafiği.....	84

Şekil 5.25.	ResNet-101 Tabanlı U-Net Tahminleri.....	84
Şekil 5.26.	ResNet-101 Tabanlı U-Net Tahminlerinde Oluşan YP ve YN Bulgular	85
Şekil 5.27.	ResNet-101 Tabanlı U-Net Tahminlerinde Oluşan Kesişimler ve Birleşimler	86
Şekil 5.28.	ResNet-152 Tabanlı U-Net'in Kayıp ve Doğruluk Grafiği.....	87
Şekil 5.29.	ResNet-152 Tabanlı U-Net Tahminleri.....	87
Şekil 5.30.	ResNet-152 Tabanlı U-Net Tahminlerinde Oluşan YP ve YN Bulgular	88
Şekil 5.31.	ResNet-152 Tabanlı U-Net Tahminlerinde Oluşan Kesişimler ve Birleşimler	89
Şekil 5.32.	Önerilen Görüntü Birleştirme Yöntemi	90
Şekil 5.33.	ResNet-50 Tabanlı U-Net'in Birleştirilmiş Görüntü Tahminleri.....	91
Şekil 5.34.	ResNet-50 Tabanlı U-Net'in COVID-19 İçermeyen Görüntülerde Tahminleri	92
Şekil 5.35.	ResNet-50 Tabanlı U-Net'in Halka Açık Veri Seti Örneklerinde Tahminleri	93

TABLÖLAR LİSTESİ

	Sayfa
Tablo 4.1. EFSCH-19 Veri Seti Detayları.....	26
Tablo 4.2. CO-RADS Kategorileri.....	30
Tablo 4.3. EfficientNet-B0 Modeli Mimarisi [70]	31
Tablo 4.4. EfficientNet Model Ailesi Üyelerinin Detayları [72]	32
Tablo 4.5. EFSCH-19'un Veri Bölme Sonrası Sayısal Dağılımı	36
Tablo 4.6. EfficientNet-B0'in Performans Değerleri	41
Tablo 4.7. EfficientNet-B1'in Performans Değerleri	44
Tablo 4.8. EfficientNet-B2'nin Performans Değerleri	47
Tablo 4.9. EfficientNet-B3'ün Performans Değerleri	50
Tablo 4.10. EfficientNet-B4'ün Performans Değerleri	53
Tablo 4.11. EfficientNet-B5'in Performans Değerleri	56
Tablo 4.12. EfficientNet-B6'nın Performans Değerleri	59
Tablo 4.13. EfficientNet-B7'nin Performans Değerleri	62
Tablo 5.1. EFSCH-19-Seg Veri Seti Detayları	66
Tablo 5.2. EFSCH-19-Seg Sınıflarının Değerleri ve Dağılımları	66
Tablo 5.3. EFSCH-19-Seg'in Veri Bölme Sonrası Sayısal Dağılımı.....	72
Tablo 5.4. ResNet-18 Tabanlı U-Net Tahminlerinde PD Bileşenleri.....	76
Tablo 5.5. ResNet-18 Tabanlı U-Net Tahminlerinde IoU ve DS Bileşenleri.....	77
Tablo 5.6. ResNet-34 Tabanlı U-Net Tahminlerinde PD Bileşenleri.....	79
Tablo 5.7. ResNet-34 Tabanlı U-Net Tahminlerinde IoU ve DS Bileşenleri.....	80
Tablo 5.8. ResNet-50 Tabanlı U-Net Tahminlerinde PD Bileşenleri.....	82
Tablo 5.9. ResNet-50 Tabanlı U-Net Tahminlerinde IoU ve DS Bileşenleri.....	83
Tablo 5.10. ResNet-101 Tabanlı U-Net Tahminlerinde PD Bileşenleri.....	85
Tablo 5.11. ResNet-101 Tabanlı U-Net Tahminlerinde IoU ve DS Bileşenleri.....	86
Tablo 5.12. ResNet-152 Tabanlı U-Net Tahminlerinde PD Bileşenleri.....	88
Tablo 5.13. ResNet-152 Tabanlı U-Net Tahminlerinde IoU ve DS Bileşenleri.....	89

EKLER LİSTESİ

	Sayfa
Ek- 1: Etik Kurul Onayı.....	102
Ek- 2: Elazığ Fethi Sekin Şehir Hastanesi Başhekim Onayı	103
Ek- 3: T.C Sağlık Bakanlığı Bilimsel Araştırma Onayı.....	104



SİMGELER VE KISALTMALAR

Simgeler

X_i	: Girdiler
W_i	: Ağırlıklar
b	: Bias
y	: Çıktı
$\vec{z}_i$	: Giriş vektörü
z_i	: Giriş vektörü elemanları
K	: Sınıf sayısı
e	: Euler sayısı

Kısaltmalar

BT	: Bilgisayarlı Tomografi
DICOM	: Tıpta Dijital Görüntüleme ve İletişim
DN	: Doğru Negatif
DP	: Doğru Pozitif
DS	: Dice Skoru
DSÖ	: Dünya Sağlık Örgütü
ESA	: Evrişimli Sinir Ağı
Grad-CAM	: Gradyan Ağırlıklı Sınıf Aktivasyon Eşleşmesi
HT	: Hiperbolik Tanjant
ICD	: Hastalıkların Uluslararası Sınıflaması
IoU	: Birleşim Üzerinden Kesişme
JPEG	: Birleşik Fotoğraf Uzmanları Grubu
KÇÜA	: Koşullu Çekişmeli Üretken Ağlar
MCC	: Matthews Korelasyon Katsayısı
MERS-CoV	: Orta Doğu Solunum Sendromu Koronavirüsü
NAAT	: Nükleik Asit Amplifikasyon Testleri
NF	: Nazofarengeal
NG	: Net Girdi
PD	: Piksel Doğruluğu
PNG	: Taşınabilir Ağ Grafiği
px	: Piksel
ReLU	: Rektifiye Lineer Birim
RGB	: Kırmızı-Yeşil-Mavi
RNA	: Ribonükleik Asid
RT-PCR	: Gerçek Zamanlı Ters Transkripsiyon-Polimeraz Zincir Reaksiyonu
SARS-CoV-2	: Şiddetli Akut Solunum Sendromu Koronavirüsü-2
t-SNE	: t-dağıtılmış Stokastik Komşu Yerleştirme
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları
XOR	: Özel Veya

1. GİRİŞ

Dünyamız kara veba, kolera ve ispanyol gribi olmak üzere birçok pandemi dönemi yaşamıştır ve günümüzde Çin'in Hubei Eyaleti, Wuhan kentinde ortaya çıkan COVID-19 küresel salgını ile mücadelesini sürdürmektedir [1]. Dünya Sağlık Örgütü (DSÖ) 31 Aralık 2019 tarihinde, pnömöni vakalarından oluşan ve bulguların sebebi bilinmeyen bir hasta grubu hakkında bilgi edildi. İlgili hastalardan çeşitli örnekler alındı ve bu örneklerin genom dizilimlerinin incelenmesi sonucunda yeni tip bir koronavirüsün bu salgına neden olduğu DSÖ tarafından 12 Ocak 2020 tarihinde açıklandı. Bu virüs Şiddetli Akut Solunum Sendromu Koronavirüsü-2 (SARS-CoV-2) ve sebep olduğu hastalık COVID-19 olarak isimlendirilmiştir [2]. SARS-CoV-2'nin zoonotik özelliğinden dolayı ilk olarak hayvanlardan insanlara bulaştığı bilinmektedir [3]. Virüs, Wuhan şehrinde ortaya çıkmasının ardından kısa bir süre içerisinde dünyanın geneline kolaylıkla yayılmıştır. Yayılma hızı ve etkileri sebebiyle 31 Ocak 2020 tarihinde DSÖ tarafından uluslararası öneme sahip halk sağlığı acil durumu ilan edildi ve daha sonra 11 Mart 2020 tarihinde pandemi ilan edilmiştir [4]. Mayıs 2022 itibarıyla dünya genelinde 520 milyondan fazla kişi enfekte olmuşken, 6 milyondan fazla kişi hayatını bu hastalık sebebiyle yitirmiştir [5].

COVID-19'un en belirgin bulguları yüksek ateş, kuru öksürük, solunum problemleri, şiddetli boğaz ağrısı ve ishaldir. Belirtilen bulgulara ek olarak çoğu hastada tat ve koku alma kaybı, eklem ağrısı ve burun tıkanıklığı da görülmektedir. Hastalığı daha ağır geçiren vakaların %2 ile %3'ünde ölüme yol açabilecek çoklu organ işlev kaybı yaşanabilmektedir [6]. COVID-19 gibi yeni tip bulaşıcı hastalık türlerine karşı tamamen korunmaya yönelik herhangi bir önlem bulunmamaktadır. Geliştirilen aşılarda, büyük oranda fayda sağlasa dahi hastalık için kesin bir çözüm değildir. Aşı olmuş kişilerin bile hastalığa yakalanabildiği örnekler bunu doğrulamaktadır [7]. Bu sebeple kişileri bilinçlendirerek sağlıklı ve enfekte kişiler arasında izole bir alan oluşturmak, maske kullanımını teşvik etmek gibi önlemler virüs enfeksiyonuyla mücadelede toplumlara fayda sağlamaktadır. Günümüzde COVID-19 hastalığını tespit ederek sağlıklı ve enfekte kişilerin ayrımını yapmak için moleküler tespit yöntemleri ve radyolojik görüntülerin yorumlanmasıyla gerçekleştirilen metotlar kullanılmaktadır [8].

Moleküler tespit yöntemleriyle virüsü tanımlamak için numunede bulunan nükleik asitlerin analiz edilmesi gerekmektedir. Gerçek Zamanlı Ters Transkripsiyon-Polimeraz Zincir Reaksiyonu (RT-PCR), COVID-19'un klinik teşhisi için en yaygın kullanılan laboratuvar tespit yöntemidir. Orta Doğu Solunum Sendromu Koronavirüsü (MERS-CoV) tespitinde de kullanılan bu yöntem, virüsün Ribonükleik Asid (RNA) bileşenini gözlemleyerek virüsün varlığını tespit eder ve tanımlanmasını sağlamaktadır [9]. Testin yapılabilmesi için pamuklu çubuk yardımıyla kişilerin boğaz ve burunlarından sürüntü örnekleri alınmalıdır. RT-PCR testleri bu sürüntü örneklerine karşılık sonuç üretmek için PCR sürümüne bağlı olarak bir saat ile birkaç gün arasında değişebilen

zaman aralığına ihtiyaç duymaktadır. RT-PCR test sonucunun güvenilirliği; numune toplama biçimine, kullanılan primer ve problemlerin tiplerine, uygun kontrollerin kullanımı ve sıcaklık değeri gibi çokça sayıda parametreye bağlıdır [10]. Kit üretiminde farklı üreticilerin farklı viral yük oranlarını referans alabilmesi, kitlerin arzında eksikliklerin bulunması, kiti kullanacak yetkin sağlık personeli sayısının azlığı ve hastalardan sürüntü örneklerinin alınması esnasındaki bulaş riski gibi dezavantajlardan dolayı RT-PCR testi verimsiz ve güvenilir olmayan bir yöntem haline gelmektedir [11]. Bu sebepten ötürü hastalığın erken evrelerinde RT-PCR testi yerine farklı metotlar kullanmak faydalı olacaktır. T.C Sağlık Bakanlığı'nın yayınlamış olduğu "COVID-19 Erişkin Tedavi Algoritması" göz önüne alındığında RT-PCR testinin dezavantajlarından sıyrılmak için testin öncesinde radyolojik görüntülerin incelenmesi önerilmektedir [12]. Çünkü COVID-19 hastalığında en fazla hasar alan organlar arasında akciğerler yer almaktadır. SARS-CoV-2 enfeksiyonu akciğer dokularına ağır ve kalıcı zararlar verebilmektedir [13]. Bu sebeple COVID-19 hastalığının tespit edilmesinde veya hastalığın ilerleyişinin takibinde akciğer dokuları mutlaka görüntülenip yetkin kişiler tarafından yorumlanmalıdır. Göğüs grafisi veya göğüs Bilgisayarlı Tomografi (BT) taraması yöntemleri COVID-19'u radyolojik olarak teşhis etmek için sıkça kullanılmaktadır [14]. Tıbbi ve sağlık protokolleri tarafından, akciğer görüntüleme hızlı ve kolay olduğu için birçok prosedürde ilk yaklaşım olarak önerilmiştir [15]. BT cihazları ayrıntılı anatomik çözünürlüğe sahip olması nedeniyle COVID-19 hastalığının etkilerinin görüntülenmesinde pandeminin başından itibaren sıklıkla kullanılmaktadır [16]. Radyoloji uzmanları bu cihazlar yardımıyla çekilen göğüs BT taramalarını inceleyerek ilgili hastaya tanı koyulması için önerilerde bulunduğu raporunu oluşturmaktadır. Bu rapor oluşturma süreci hayati bir önem taşıdığı için titizlikle yürütülmektedir. Sağlık sektörünü çok kötü etkileyen bu pandemi döneminde COVID-19 hastalığının teşhisi için radyoloji uzmanlarına standart limitlerinin çok üzerinde radyolojik görüntü yorumlama görevi atanmaktadır [17]. Bundan dolayı hastanın raporunun yorumlanıp ilgili tedaviye başlanabilmesi için geçen süre bir hayli artmaktadır. Ek olarak harcanan zamanın fazlalığı sebebiyle yorgunluk gibi insani faktörlerinde ortaya çıkmasıyla raporlama süreci hataya açık bir süreç haline gelmektedir. Hızlı işlem yapabilme kapasitesine ve insani faktörlerden etkilenmeme özelliğine sahip bilgisayarlar bu süreçte radyoloji uzmanlarına karar verme aşamasında yardımcı olabilir [18].

Yapay zeka tabanlı sistemler çeşitli hastalıkların tespitinde veya tedavilerdeki ilerleme süreçlerinin takip edilmesinde aktif bir şekilde kullanılmaktadır [19, 20]. Günümüzde tıbbi görüntülerin hastalık tabanlı sınıflandırılması ve ilgili hastalık alanlarının görüntü üzerinde işaretlenmesi için derin öğrenme modellerinin kullanılmasını ve geliştirilmesini içeren çalışmalar hız kazanmıştır [21]. İnme hastalığının tespitinde [22], böbrek taşı problemine sahip hastaların sınıflandırılmasında [23], kanser hücrelerinin belirlenmesi [24] gibi doğrudan insan hayatına etki edebilecek görevlerde yapay zeka tabanlı sistemler hekimlere destek sağlamaktadır. Pandemi sürecindeki sosyal, ekonomik ve toplumsal zararları en aza indirgeyebilmek ve diğer çalışmalarda

olduğu gibi hekimlere destek olabilmek için araştırmacılar tarafından çokça sayıda yapay zeka tabanlı COVID-19 tespit çalışması ortaya koyulmuştur. Bu çalışmalar sınıflandırma ve anlamsal bölütleme olmak üzere iki ana başlık altında toplanmaktadır.

Sınıflandırma çalışmalarında temel amaç, sahip olunan veri referans alınarak COVID-19 hastalığı açısından pozitif durumların olup olmadığını belirlemektir. Bogu ve ark. [25], 15 saniye ve 1 dakika aralığındaki uzunluklarda gerçek kişilerin kalp atış hızlarını akıllı saat cihazı yardımıyla toplamışlardır. Bu verileri COVID-19 hastalığı açısından enfekte ve enfekte olmayan süreç olarak iki sınıfa ayırmışlardır. LSTM tabanlı derin öğrenme metotları sayesinde kalp atış hızlarından COVID-19 hastalığına sahip kişileri %92 doğruluk oranıyla sınıflandırmışlardır. Pahar ve ark. [26], akıllı telefonlar yardımıyla toplanan COVID-19 pozitif ve COVID-19 negatif tanıya sahip kişilerin öksürük kayıtlarını yapay zeka tabanlı sınıflandırmışlardır. Çalışmada kullandıkları veri setleri hem doğal hem de zorunlu öksürük örneklerini içermektedir. COVID-19 pozitif tanısına sahip öksürük kayıtları diğer kayıtlara göre %15 ila %20 arasında daha kısa olduğu araştırmacılar tarafından gözlemlenmiştir. Yedi farklı makine öğrenmesi sınıflandırıcısına girdi olarak verilen öksürük kayıtları, ResNet50 sınıflandırıcısı tarafından %95.33 doğruluk oranıyla sınıflandırarak en yüksek başarıya ulaşmıştır. Giyilebilir sensörler ve akıllı telefon teknolojilerinin yanı sıra COVID-19 hastalığının tespit edilmesiyle ilgili çalışmalarda radyolojik görüntüler en çok kullanılan yöntemdir. Hemdan ve ark. [27], COVID-19 hastalığını x-ışını görüntülerinden otomatik tespit edebilen derin öğrenme tabanlı bir sistem sunmuştur. Araştırmacılar tarafından, 25 adet COVID-19 pozitif ve 25 adet COVID-19 negatif örneklerden oluşan halka açık bir veri seti kullanılmıştır. Farklı çözünürlüğe sahip veri seti örnekleri ön işlem yardımıyla 224×224 Piksel (px) olarak yeniden boyutlandırılmıştır. Veri seti örneklerinin %80'i eğitim, %20'si test aşamalarında kullanılmıştır. VGG-19, DenseNet-201, ResNetV2, InceptionV3, InceptionResNetV2, Xception ve MobileNetV2 olmak üzere yedi farklı sınıflandırıcı model eğitilmiştir. Gerçekleştirilen test adımları sonrasında VGG-19 ve DenseNet-201 modellerinin, 0.91 F1-skoru ile en iyi performansı gösteren modeller olduğu belirtilmiştir. Wang ve ark. [28], göğüs x-ışını görüntülerinden COVID-19 vakalarının tespiti için özel olarak tasarlanmış derin bir Evrişimli Sinir Ağı (ESA) olan ve COVID-Net olarak isimlendirilen modeli sunmuştur. Halka açık veri setlerinden toplanan 13,975 adet örnek model eğitiminde kullanılmıştır. Bu örneklerle kırpma, döndürme, yatay çevirme, yakınlaştırma ve yoğunluk kaydırılması gibi ön işlem adımları uygulanmıştır. COVID-Net modeli ImageNet ağırlıkları ve Adam optimizasyonu kullanılarak parti boyutu 64 olacak şekilde 22 tur sayısı boyunca eğitilmiştir. Test aşamaları sonucunda COVID-Net modeli aynı veri seti ile eğitilmiş VGG-19 ve ResNet-50 modelleriyle karşılaştırılmıştır ve %93.3 doğruluk oranıyla en iyi performansı gösteren model olduğu araştırmacılar tarafından paylaşılmıştır. Ali ve ark. [29], koronavirüs enfekte kişilerin göğüs x-ışını görüntülerinden tespiti için ön eğitilmiş ESA tabanlı modeller yardımıyla bir sistem önermiştir. İlgili çalışmada kullanılan veri seti halka açık bir veri setidir ve COVID-19 pozitif, viral

pnömoni, bakteriyel pnömoni ve herhangi bir hastalık bulgusu içermeyen normal görüntülerin yer aldığı toplam dört sınıfı içermektedir. İkili sınıflandırma yöntemine dayalı bir kurguya sahip olan çalışmada 341 adet örneğe sahip COVID-19 pozitif sınıfı sabit tutularak diğer üç sınıfın değiştirilmesiyle üç alt veri seti oluşturulmuştur. Veri seti örnekleri rastgele bir şekilde %80 eğitim ve %20 test aşamalarında kullanılmak üzere katlamalı çapraz doğrulamayla ayrıştırılmıştır. ResNet-50, ResNet-101, ResNet-152, InceptionV3 ve InceptionResNetV2 ön eğitilmiş modelleri 30 tur sayısı boyunca eğitilmiştir. Gerçekleştirilen test aşaması sonucunda diğer modellere kıyasla en iyi tahmin yeteneğine sahip ResNet-50 modeli COVID-19 pozitif ve normal görüntülerin ikili sınıflandırılması için tasarlanan alt veri seti için %96.1, COVID-19 pozitif ve viral pnömoni görüntülerin ikili sınıflandırılması için tasarlanan alt veri seti için %99.5, COVID-19 pozitif ve bakteriyel pnömoni görüntülerin ikili sınıflandırılması için tasarlanan alt veri seti için %99.7 doğruluk oranına ulaştığı paylaşılmıştır. Hussain ve ark. [30], COVID-19 hastalığının x-ışını görüntülerinden tespit edilmesinde CoroDet adını verdikleri ESA modelini oluşturmuştur. İkili ve çoklu sınıflandırma görevini yerine getirebilmesi için kurgulanan CoroDet modeli 50 tur sayısı boyunca eğitilmiştir. Üç farklı senaryo için test sonuçları incelenen model COVID-19 ve normal görüntülerin ikili sınıflandırılmasında %99.1 doğruluk oranına ulaşmıştır. COVID-19, normal ve pnömoni görüntülerinin çoklu sınıflandırılmasında model %94.2 doğruluk oranına ulaşmıştır. COVID-19, normal, pnömoni ve bakteriyel pnömoni görüntülerinin çoklu sınıflandırılmasında model %91.2 doğruluk oranına ulaşmıştır. Araştırmacılar test kitlerinin arzında yaşanan sıkıntılara alternatif olarak CoroDet modelinin kullanılmasıyla hekimlere yardımcı olunabileceğini belirtmiştir. Luz ve ark. [31], COVID-19 bulgularını içeren x-ışını görüntülerini EfficientNet ailesinde yer alan modeller yardımıyla sınıflandırmıştır. Modellerin eğitiminde farklı kaynaklardan toplanan halka açık veri setleri ve çapraz veri seti değerlendirme yöntemi kullanılmıştır. COVID-19 pozitif, pnömoni ve normal olmak üzere üç sınıftan örnek içeren veri seti, farklı çözünürlük değerlerine sahip elemanlardan oluşmaktadır. 20 tur sayısı boyunca eğitilen modeller arasında EfficientNet-B3 modeli %93.9 doğruluk oranına ulaşarak en iyi performans gösteren model olmuştur. Apostolopoulos ve ark. [32], transfer öğrenme yöntemini kullanarak x-ışını görüntülerinden COVID-19, pnömoni ve normal bulgulara sahip örnekleri sınıflandıran bir sistem önermiştir. Araştırmacılar tarafından iki veri seti kullanılmıştır. İlk veri seti 224 adet onaylanmış COVID-19 pozitif, 700 adet bakteriyel pnömoni ve 504 adet normal bulgular olmak üzere toplamda 1428 adet x-ışını görüntüsü içermektedir. İkinci veri seti 224 adet onaylanmış COVID-19 pozitif, 504 adet normal ve 714 adet viral pnömoni örneğini içermektedir. Tüm veri seti örnekleri 200×266px boyutuna yeniden ölçeklendirilmiştir. 64 parti uzunluğu sabit tutularak 10 tur sayısı boyunca VGG-19, MobileNetv2, Inception, Xception ve InceptionResNetv2 modelleri eğitilmiştir. COVID-19 ve normal görüntülerin yer aldığı ikili sınıflandırma için %98.75 doğruluk, %92.85 duyarlılık ve %98.75 özgüllük değerine ulaşan VGG-19 modeli diğer dört modelden daha

başarılıdır. COVID-19, pnömoni ve normal görüntülerin yer aldığı üçlü sınıflandırma için en yüksek doğruluk oranına %93.48 ile ulaşan VGG-19 modelidir. İkinci veri seti ile gerçekleştirilen eğitim aşamasında MobileNetv2 modeli ikili sınıflandırma için %96.78 doğruluk oranına, üçlü sınıflandırma için %94.72 doğruluk oranına ulaşmıştır.

Radyolojik görüntülerden COVID-19 hastalığının tespitinde x-ışını görüntüleri yerine BT görüntülerinin kullanıldığı çalışmalar da mevcuttur. Shah ve ark. [33], COVID-19 hastalığının akciğerler üzerindeki bulgularından tespit edilebilmesi için CTnet-10 adı verilen ESA tabanlı modeli önermiştir. Radyolojik görüntü tipi olarak BT taramaları kullanılan çalışma veri setinde, 216 hastadan toplanan 349 adet COVID-19 ve 463 adet normal olmak üzere toplam 812 adet görüntü bulunmaktadır. Bu görüntülerin %80'i eğitim, %10'u doğrulama ve geriye kalan %10'u test aşamalarında kullanılmak üzere bölünmüştür. CTnet-10, DenseNet-169, VGG-16, ResNet-50, InceptionV3 ve VGG-19 olmak üzere toplamda altı adet modelin giriş boyutuna göre veri seti örnekleri yeniden boyutlandırılmıştır. CTnet-10 modelinin giriş boyutu $128 \times 128 \times 3px$ 'dir. 30 tur sayısı boyunca eğitilen modeller arasında %94.52 doğruluk oranına ulaşan VGG-19 modeli, eğitilen diğer tüm modellerden daha başarılı olduğu araştırmacılar tarafından belirtilmiştir. Shalhaf ve ark. [34], derin öğrenme tabanlı sistem yardımıyla COVID-19 hastalığının otomatik olarak tespitinin yapılabilmesi için yöntem önermiştir. Bu çalışmada halka açık ve BT taraması görüntülerinden oluşan bir veri seti kullanılmıştır. Toplamda 746 görüntü içeren veri setinde 349 adet görüntü COVID-19 pozitif olarak etiketlenilmişken geriye kalan 397 adet görüntü normal etiketine sahiptir. Normal olarak etiketli görüntülerde COVID-19 hastalığı haricinde diğer akciğer hastalıklarıyla ilişkili görüntülerin yer alabileceği belirtilmiştir. Bu görüntüler kullanarak 15 adet ön eğitilmiş model hedef görev için parti boyutu 32 alınarak 50 tur sayısı boyunca eğitilmiştir. %82 doğruluk oranına ulaşan EfficientNet-B0, EfficientNet-B3, EfficientNet-B5, InceptionResNetV2 ve Xception modelleri diğer modellere göre daha yüksek başarı göstermiştir. Loey ve ark. [35], derin transfer öğrenme modellerini kullanarak COVID-19 bulgularına sahip göğüs BT görüntülerini sınıflandıran sistem önermiştir. 345 adet COVID-19 pozitif ve 397 adet normal göğüs BT görüntüsü içeren halka açık bir veri seti tercih etmişlerdir. Fakat araştırmacılar halka açık veri setlerindeki örnek sayısının azlığı sebebiyle klasik veri çoklama ve Koşullu Çekişmeli Üretken Ağlar (KÇÜA) ile sentetik görüntüler üreterek veri setinde yer alan örnek sayısını arttırmıştır. Klasik veri çoklama yöntemi uygulandıktan sonra oluşturulan ilgili veri setinde 3106 adet COVID-19 pozitif ve 3609 normal göğüs BT görüntüsü bulunmaktadır. KÇÜA ile sentetik görüntüler üretilerek oluşturulan veri setinde 2495 COVID-19 pozitif ve 2547 normal göğüs BT görüntüsü yer almaktadır. AlexNet, VGGNet-16, VGGNet-19, GoogleNet ve ResNet-50 modelleri öğrenme oranı 0.001, parti boyutu 32 olacak şekilde 50 tur sayısı boyunca eğitilmiştir. Eğitim aşamasından sonra gerçekleştirilen test aşamasında, halka açık ham veri seti ile eğitilen modeller arasında en başarılı model %76.88 doğruluk oranına ulaşan VGGNet-19'dur. Klasik veri çoklama yöntemiyle

oluşturulan veri setiyle eğitilen modeller arasında en başarılı model %82.91 doğruluk oranına ulaşan ResNet-50'dir. KÇÜA yöntemiyle oluşturulan veri seti ile eğitilen modeller arasında en başarılı model %77.39 doğruluk oranına ulaşan ResNet-50 modeli olduğu araştırmacılar tarafından bildirilmiştir. Ying ve ark. [36], derin COVID-19 enfekte hastaları BT görüntülerinden tespit edilmesinde klinisyenlere yardımcı olabilecek bir sistem önermiştir. DRE-Net olarak adlandırılan modelleri Çin'de yer alan iki farklı hastaneden alınan BT görüntüleriyle eğitilmiştir. İlgili veri setinde 88 farklı BT taramasından seçilen 777 adet COVID-19 pozitif etiketli örnek, 100 farklı BT taramasından seçilen 505 adet bakteriyel pnömoni etiketli örnek ve 86 sağlıklı kişilerin BT taramasından seçilen 708 örnek yer almaktadır. Model eğitimi öncesinde veri seti %60 eğitim, %10 doğrulama ve %30 test aşamasında kullanılmak üzere rastgele bölünmüştür. Eğitim aşaması tamamlandıktan sonra performans metrikleri kullanılarak modelinin sonuçları incelendiğinde, DRE-Net'in %86 doğruluk oranına ulaşıldığı araştırmacılar tarafından bildirilmiştir. ESA tabanlı modelin sınıflandırma işlemini yaparken test görüntüsünde hangi alanlara odaklandığını belirtebilmek için Gradyan Ağırlıklı Sınıf Aktivasyon Eşleşmesi (Grad-CAM) yönteminden yararlanılmıştır. Çalışmada kullanılan veri seti ve kaynak kodlar halka açık olarak paylaşılmıştır. Wang ve ark. [37], derin öğrenme algoritması kullanarak göğüs BT görüntülerinden COVID-19 hastalığının tespit edilmesi için bir yöntem paylaşmıştır. Üç farklı hastaneden toplanan göğüs BT görüntüleri iki radyolog tarafından 325 adet COVID-19 pozitif ve 740 adet COVID-19 negatif olarak etiketlenilerek toplamda 1065 örnek içeren veri seti oluşturulmuştur. Veri seti elemanlarının boyutu 299×299px olacak şekilde boyutlandırılmıştır. Öğrenme oranı 0.01 olarak ayarlandıktan sonra 15,000 tur sayısı boyunca M-inception modelinin eğitim süreci yürütülmüştür. Performans değerlendirilmesi tamamlandıktan sonra ilgili modelin %89.5 doğruluk oranına ulaştığı araştırmacılar tarafından paylaşılmıştır. Belirtilen tüm bu sınıflandırma çalışmaları sayesinde ilgili radyolojik görüntülerin insani faktörlere bağlı olmadan hızlı ve güvenilir bir şekilde yorumlanması hedeflenmektedir.

Anlamsal bölütleme çalışmalarında temel amaç radyolojik görüntüler üzerinde COVID-19 hastalığı bulgularının yer aldığı piksellerin bilgisayarlar tarafından işaretlenmesini sağlamaktır. Anlamsal bölütleme çalışmaları, genel olarak iki sınıflı veya ikiden fazla anlamına gelen çok sınıflı yapılara sahiptir. İki sınıflı anlamsal bölütleme çalışmalarında COVID-19 hastalığı bulgularının yer aldığı pikseller bir sınıfla temsil edilirken geriye kalan diğer tüm pikseller arka plan olarak adlandırılan diğer bir sınıfla temsil edilmektedir. Zhou ve ark. [38], göğüs BT görüntüleri üzerinde COVID-19 hastalığı bulgularının yer aldığı piksellerin otomatik işaretlenmesi için U-Net tabanlı derin öğrenme modeli önermiştir. 60 farklı hastadan çekilen ve tamamında COVID-19 bulgularının yer aldığı bilinen 100 göğüs BT görüntüsü yardımıyla 'Dataset-1' adı verilen veri seti oluşturulmuştur. 512×512px boyutuna sahip olan veri seti örnekleri referans alınarak uzman radyolog tarafından maske görüntüleri oluşturulmuştur. Maske görüntülerinde buzlu cam opasitesi,

konsolidasyon ve plevral efüzyon alanları üç farklı sınıfla belirtilmiştir. ‘Dataset-2’ adı verilen ikinci veri seti dokuz farklı çekime ait 829 göğüs BT görüntüsünden oluşmaktadır. Ancak 829 göğüs BT görüntüsünün sadece 373 tanesi uzman radyolog tarafından işlenerek maske görüntüleri üretilmiştir. 630×630px çözünürlüğüne sahip veri seti örnekleri 512×512px çözünürlüğüne yeniden boyutlandırılmıştır. Uzman radyolog tarafından oluşturulan maske görüntülerinde yer alan COVID-19 bulguları tek bir sınıf içerisinde temsil edilecek şekilde düzenlenerek, 473 göğüs BT görüntüsü ve aynı sayıda maske görseliyle nihai veri seti oluşturulmuştur. Veri seti örneklerinin %80’i eğitim ve %20’si test aşamalarında kullanılmak üzere bölünmüştür. Nvidia Quadro P5000 donanımı kullanılarak 50 tur sayısı boyunca eğitilen modelin %83.1 Dice Skoruna (DS) ulaştığı araştırmacılar tarafından paylaşılmıştır. Ek olarak önerilen yöntem sayesinde bir göğüs BT görüntüsünde yer alan COVID-19 bulgularının otomatik olarak işaretlenmesi için harcanan sürenin 0.29 saniye olduğu bildirilmiştir. Amer ve ark. [39], mevcut U-Net modeli kurgusuna dayalı ancak uzun ve kısa atlama bağlantılarının güçlü yanlarından yararlanan otomatik bir derin öğrenme bölütleme modeli önermiştir. Halka açık ve 1705 adet göğüs BT görüntüsünden oluşan veri seti çalışmada kullanılmıştır. Veri seti örneklerinin çözünürlükleri 630×630px ve 512×512px aralığında değişmekte ve sadece 0 veya 1’lerden oluşmaktadır. U-Net modelinin varsayılan giriş boyutu 256×256px olduğu için veri seti örneklerinin tamamı bu değere yeniden boyutlandırılmıştır. Veri çoklama yöntemlerinin kullanılmasının ardından ilgili model 3410 göğüs BT görüntüsüyle 350 tur sayısı boyunca eğitilmiştir. Araştırmacılar tarafından önerilen model test aşamasında %85.3 DS ve %83.9 Jaccard indeksi değerine ulaşmıştır. Qingsen ve ark. [40], COVID-19 enfeksiyonlarını göğüs BT görüntülerinden tespit edip ilgili piksellerin otomatik olarak işaretlenmesi için COVID-SegNet adı verilen yeni bir derin ESA önermiştir. Araştırmacılar beş farklı hastaneden ve 861 hastadan alınan 21,658 adet COVID-19 pozitifliği onaylanmış göğüs BT görüntülerini toplayarak veri setlerini oluşturmuştur. Kişisel bilgilerin gizliliğini sağlamak için görüntülerde yer alan hasta bilgileri çıkarılmıştır. 731 hastanın göğüs BT görüntüleri eğitim, 130 hastanın göğüs BT görüntüleri test aşamasında kullanılmıştır. COVID-19 bulgularının ve akciğerlerin yer aldığı alanların işaretlenmesi olmak üzere iki farklı senaryoya sahip çalışmada iki farklı test aşaması yürütülmüştür. İlk test aşamasında önerilen modelin, göğüs BT görüntüleri üzerinde COVID-19 bulgularını içeren alanları %72.60 DS oranıyla işaretlediği paylaşılmıştır. İkinci test aşamasında göğüs BT görüntülerinde akciğer alanlarının kapladığı alanlar ilgili model tarafından %98.70 DS’le işaretlenmiştir. Kurgulanan iki farklı senaryoyu çok sınıflı anlamsal bölütleme yöntemiyle tek bir senaryoya indirgemek mümkündür. COVID-19 çalışmalarında çok sınıflı anlamsal bölütleme yöntemi genellikle enfeksiyon alanları, akciğer alanları ve değerli bilgi içermeyen alanları temsil eden arka plan olmak üzere toplam üç sınıftan oluşmaktadır. Fakat bu sınıf sayısı akciğerlerin sağ-sol olarak ayrımı veya enfeksiyon tiplerinin belirtilmesi gibi kurgularla artırılabilir. Chen ve ark. [41], U-Net modelinde yer alan blokların, ResNext bloklarıyla revize edilmesiyle oluşturulan

bölütleme modelini paylaşmıştır. Paylaşılan modelin eğitiminde 60 farklı hastadan alınan 110 farklı göğüs BT görüntüsü kullanılmıştır. İlgili halka açık veri setinde buzlu cam alanları, konsolidasyon ve plevral efüzyon alanları olmak üzere üç farklı COVID-19 bulgusu maske görsellerinde yer almaktadır. Orijinal boyutu 512×512px olan veri seti örnekleri 369×369px boyutuna yeniden boyutlandırılmıştır. Veri seti örnek sayısının yetersizliği sebebiyle veri çoklama işlemi araştırmacılar tarafından uygulanmıştır. Model, çoğaltılmış ve çoğaltılmamış olmak üzere iki farklı veri seti yardımıyla ve 100 tur sayısı boyunca eğitilmiştir. Eğitim sürecinde çoğaltılmış verilerin yer aldığı senaryoda %94 DS değerine ulaşılmıştır. Çoğaltılmamış verilerin yer aldığı eğitim süreci sonucundaysa elde edilen DS %83 olarak belirtilmiştir.

Literatürde bulunan çalışmalarda derin öğrenme modelleri genellikle halka açık veri setleri yardımıyla eğitilmiştir. Ancak ilgili çalışmalarda kullanılan halka açık veri setlerinde herhangi bir içerik düzenlemesi yapılmamıştır. Bundan dolayı veri setlerinde yer alan yanlış etiketlendirilmiş görüntüler ve dengesiz dağılımlar gibi sorunlar göz ardı edilmiştir. Halka açık veri setlerindeki olumsuzluklardan etkilenmemek ve tezin özgünlüğüne de önemli bir katkı sağlayacağı düşünüldüğünden T.C. Sağlık Bakanlığı, Fırat Üniversitesi Girişimsel Olmayan Etik Kurulu Kararı ve Elazığ Fethi Sekin Şehir Hastanesi Başhekimliği'nden alınan idari izinler sayesinde gerçek hasta görüntülerinin yer aldığı özel bir veri seti oluşturulmuştur. EFSCH-19 olarak adlandırdığımız veri seti COVID-19 pozitif ve COVID-19 negatif bulgularının yer aldığı göğüs BT taraması örneklerini içermektedir. COVID-19 pozitif göğüs BT görüntülerinde sadece ilgili radyolojik bulguların yer alması yeterli olmayıp, uzman hekim tarafından ilgili hastanın kayıtlarına 'U07.3' Hastalıkların Uluslararası Sınıflaması (ICD) tanısının girilmiş olması şartı da gözetilmiştir. EFSCH-19 veri setinde herhangi bir hastanın kişisel bilgisi bulunmamaktadır. Bu sayede gerekli izinlerin alınmasıyla birlikte EFSCH-19 veri setinin diğer araştırmacıların da kullanımına sunulması, tez çalışmasının hedefleri arasında yer almaktadır.

1.1. Tezin Organizasyonu

Birinci bölümde tezin çözümüne odaklandığı problem, literatürde ilgili problem için gerçekleştirilen çalışmalar ve tezin hedefleri hakkında genel bilgiler verilmiştir. Tezin diğer bölümlerine ait bilgiler aşağıdaki gibidir.

İkinci bölümde koronavirüsün yapısı incelenerek COVID-19 hastalığının özellikleri ve tespitinde kullanılan yöntemler detaylıca belirtilmiştir. Radyolojik görüntüleme yöntemlerinin açıklanmasıyla çalışmada kullanılan veri setinde yer alan BT taramalarının neden tercih edildiğine değinilmiştir.

Üçüncü bölümde, yapay zeka ve derin öğrenme kavramlarından bahsedilmiştir. Yapay sinir ağlarının açıklanmasıyla birlikte derin öğrenme algoritmalarının nasıl çalıştığı hakkında bilgiler

verilmiştir. Transfer öğrenme yönteminin açıklanması ve öneminin belirtilmesiyle birlikte görsel kurgusu bu bölümde verilmiştir.


Dördüncü bölümde, sınıflandırma görevi için geliştirilen derin öğrenme modeli kurgusu tanıtılmıştır. Sınıflandırıcı derin öğrenme modelinin eğitiminde kullanılan ve özel izinlerle oluşturulan veri seti hakkında detaylı bilgiler paylaşılmıştır. Oluşturulan veri setinin radyolojik bulgulara ve raporlama standartlarına uygunluğu açıklanmıştır. Sınıflandırıcı derin öğrenme modelinin eğitiminde kullanılan parametreler ve ortamlar hakkında bilgiler verilmiştir. Eğitilen modeller açıklanmış ve eğitim aşamasında oluşan grafikler sunulmuştur. Eğitimi tamamlanan modellerin nasıl değerlendirileceği hakkında performans metrikleri açıklanmıştır. Her bir modelin test aşamasında göstermiş olduğu performans model bazlı olarak incelenmiştir.

Beşinci bölümde, anlamsal bölütleme görevi için geliştirilen derin öğrenme modeli kurgusu tanıtılmıştır. Anlamsal bölütleyici derin öğrenme modelinin eğitiminde kullanılan veri setinin nasıl oluşturulduğuna dair açıklamalar ve yöntemler belirtilmiştir. Anlamsal bölütleyici derin öğrenme modelinin eğitiminde kullanılan parametreler ve ortamlar hakkında bilgiler verilmiştir. Eğitilen modeller açıklanmış ve eğitim aşamasında oluşan grafikler sunulmuştur. Eğitimi tamamlanan modellerin nasıl değerlendirileceği hakkında performans metrikleri açıklanmıştır. Her bir modelin test aşamasında göstermiş olduğu performans model bazlı olarak incelenmiştir. Görüntü parçalama ve birleştirme yöntemi önerilerek yüksek çözünürlükteki görsellerin eğitim ve test aşamasına nasıl dahil edilebileceği açıklanmıştır.

Altıncı bölümde, tez çalışması sonucunda elde edilen bulgular irdelenmiş ve gelecek çalışmalar için öneriler paylaşılmıştır.

2. KORONAVİRÜS

Koronavirüsler büyük, zarflı ve tek sarmallı RNA virüsleridir. Yüzeylerinde çubuksu uzantıları vardır ve bu çıkıntılara karşılık Latince’de taçlı virüs anlamına gelen ‘coronavirüs’ adı verilmektedir [42]. Koronavirüslerin şematik yapısı Şekil 2.1’de verilmiştir.



Şekil 2.1. Koronavirüslerin Şematik Yapısı

Koronavirüsler insanlarda ve memeli hayvanlarda solunum ve nörolojik hastalıklara sebep olmaktadır. Bağışıklık sistemi zayıf olmayan kişilerde soğuk algınlığı semptomlarına neden olan en yaygın koronavirüs türleri 229E, OC43, NL63 ve HKU1’dir [43]. İnsanda bulunan koronavirüs türlerinin yanı sıra hayvanlarda koronavirüsün birçok alt türü saptanmıştır ve hayvanlardan insanlara bulaş neticesinde ağır hastalıkların meydana geldiği bilinmektedir. Şiddetli hastalığa neden olan ilk koronavirüs, SARS-CoV’dur. 2003 yılında misk kedilerinden insanlara bulaştığı bilinen SARS-CoV 26 farklı ülkede 774 kişinin ölümüne sebep olmuştur [44]. SARS-CoV’un ortaya çıkışından yaklaşık 10 yıl sonra develerden bulaştığı bilinen MERS-CoV ilk kez Nisan 2012 tarihinde Ürdün’de görülmüştür. Ciddi hastalıkların küresel olarak yayılmasına neden olan üçüncü koronavirüs günümüzde COVID-19 pandemisiyle yıkıcı etkilerini ortaya koymaktadır [45].

2.1. COVID-19

Çin’in Wuhan şehrinde Aralık 2019 tarihinde, uzmanlar tarafından atipik olarak sınıflandırılan bir dizi solunum yolu enfeksiyonu ortaya çıktı ve büyük bir hızla Wuhan’dan tüm dünyaya yayıldı. Kısa bir süre içerisinde bu olaylara koronavirüsün yeni tipinin sebep olduğu keşfedilmiştir ve yüksek homolojisiinden dolayı SARS-CoV-2 olarak adlandırılmıştır [46]. SARS-

CoV-2, 60 ila 140 nanometre arasında bir çapa ve belirgin sivri uçlara sahiptir [47]. Yaralarının SARS-CoV-2 için doğal bir rezervuar olduğu bilinmektedir ancak insuların enfekte olma sürecinde pangolin gibi bir aracının rol oynadığı araştırmacılar tarafından öne sürölmektedir [48]. Çünkü koronavirüsler rekombinasyon ve varyasyon yoluyla yeni nesillere uyum sağlayabilir ve onları kolaylıkla enfekte edebilirler.

2.1.1. Bulaş

COVID-19 hastalığı damlacık yoluyla bulaşmaktadır [49]. Enfekte kişilerin hapşırma, öksürme benzeri faaliyetleri sonucunda ortama yayılan damlacıklara diğer kişilerin temas etmesiyle beraber ellerini burun, göz veya ağızlarına götürmesi hastalığın yayılması için yeterlidir. Semptomların ortaya çıkmasından 1-2 gün önce COVID-19 hastalığı için bulaştırmacılığın başladığı ve semptomların sonlanmasıyla birlikte bulaşıcılığında bittiği düşünölmektedir [50]. Viral saçılım semptomların görölmeye başlamasından önce başlamakta ve semptomların ortaya çıkmasıyla birlikte en yüksek noktaya ulaşmaktadır. Hastalığı ağır geçiren ve yaşlı kişilerde viral yükün fazla olduğunu belirten çalışmalar mevcuttur [51]. Bu sebeple hastalığın şiddeti ve prognozu açısından viral yük oldukça önemli bir parametredir.

2.1.2. Klinik Özellikler

COVID-19 hastalığı, kişileri farklı şekillerde etkilemektedir. Bu sebeple kişilerde görölen semptomlar farklılık gösterebilmektedir. COVID-19 hastalığı için semptomlar; yaygın semptomlar, daha seyrek görölen semptomlar ve ciddi semptomlar olmak üzere üç başlık altında incelenmektedir. Yüksek ateş, kuru öksürük, yorgunluk hissi ve tat alma veya koku duyusunun kaybolması enfekte kişilerde görölen en yaygın semptomlardır [52]. Genellikle sadece bu semptomlara sahip hastalar hastalığı hafif olarak atlatabilmektedir. Boğaz ağrısı, baş ağrısı, ishal, ciltte döküntü ve gözlerde kızarıklık gibi semptomlar ise daha seyrek görölen semptomlardır. Solunum güçlüğü veya nefes darlığı, konuşma ya da hareket kaybı, göğüs ağrısı gibi ciddi semptomlar tıbbi yardıma ihtiyaç duymaktadır. Ciddi semptom görölen kişilerde organ iflası ve hatta ölüm bile gerçekleşebilir [53]. Bu sebeple COVID-19 enfekte kişilerin tespitinin en erken sürede yapılması ve semptomların neden olduğu zararlar ağırlaşmadan tedaviye başlanması gerekmektedir.


2.1.3. Tespit Yöntemleri

Günümüzde COVID-19 hastalığının tespitinde laboratuvar testleri ve radyolojik görüntöleme olmak üzere iki farklı yöntem aktif bir şekilde kullanılmaktadır. Ülkemizde laboratuvar numunelerinin değerlendirilmesi yalnızca T.C Sağlık Bakanlığı tarafından belirlenerek

yetkilendirilmiş laboratuvarlarda yapılabilmektedir. Laboratuvar testleri Nükleik Asit Amplifikasyon Testleri (NAAT), sekans analizi, antijen testleri ve antikor testleri gibi yöntemleri içermektedir [54]. Pandeminin başlangıcından itibaren COVID-19 enfekte kişilerin tespit edilebilmesi ve ilgili tanının doğrulanması için bir NAAT metodu olan RT-PCR testi sıklıkla kullanılmaktadır. RT-PCR testi, SARS-CoV-2 virüsü RNA'sında yer alan özgül dizilerin saptanmasına yönelik bir testtir [55]. RT-PCR testi sadece ilk tespit aşamasında değil aynı zamanda karantina süreçlerinin sonlandırılmasında ve asemptomatik bireylerin taranması gibi işlemlerde de kullanılmaktadır. Bu sebeple dünyanın farklı noktalarında çeşitli ticari şirketler ve araştırma merkezleri tarafından birçok farklı RT-PCR test kiti geliştirilmiştir. Bu test kitlerinin odaklandığı ve tespit ettiği gen bölgeleri geliştiricisine bağlı olarak farklılık gösterebilmektedir. Genellikle RdRp, ORF1a/b, S, N ve E genleri test kitleri tarafından hedef alınan genlerdir [56]. RT-PCR testinin gerçekleştirilebilmesi için kişiden solunum yolu numuneleri toplanmalıdır. Solunum yolu numuneleri genel olarak altı farklı türdedir ve detayları aşağıdaki gibidir.

- Nazofarengeal (NF) sürüntü örneği
- Orofarengeal sürüntü örneği
- Kombine sürüntü örneği
- Orta burun bölgesi numuneleri
- Ön burun ucu numuneleri
- Alt solunum yolu numuneleri


Belirtilen solunum yolu numuneleri türleri arasında en fazla tercih edilen tür NF sürüntü örneğidir. NF sürüntü örneğinin alınabilmesi için öncelikle kişinin burun pasajı ile ilgili kanama benzeri bir probleminin olup olmadığı sorgulanır. Daha sonra kişinin tavana doğru bakması istenerek başı 70 derecelik bir açıyla arkaya doğru itilir. Eküvyon çubuğu burun deliğinden içeri sokularak ağız tavanına kadar ilerletilir. İstenen alana ulaşıldıktan sonra eküvyon çubuğu döndürülerek geri çekilir. Şekil 2.2'de NF sürüntü örneğinin nasıl alındığıyla ilgili görsel verilmiştir.



Şekil 2.2. NF Sürüntü Örneğinin Alınması [57]

Solunum yolu numunelerinin alınması sürecinin tamamı sağlık personelleri tarafından yürütülmektedir. Numune alınan kişiler COVID-19 hastalığı açısından şüpheli veya kesinleşmiş vakalar olduklarından ötürü sağlık personelinin her bir numune alma sürecinde yeni koruyucu ekipmanlar kullanması zorunludur. Bu da koruyucu ekipman sarfiyatına sebep olarak COVID-19 hastalığının ekonomik hasarlarına katkı sağlamaktadır. Ek olarak RT-PCR testinin negatif çıkması COVID-19 hastalık olasılığını dışlamak için yeterli değildir [58]. Çünkü örneklerin yanlış veya az miktarda alınmış olması, SARS-CoV-2 enfeksiyonu için erken veya çok geç dönemde alınmış olması, gerekli koşulların ve sürenin dikkate alınmadan örneklerin laboratuvara gönderilmiş olması gibi kişisel hatalar RT-PCR testinin sonucunun yanlış elde edilmesine yol açmaktadır. Tüm bu özelliklerinden dolayı RT-PCR testi güvensiz bir duruma bürünmekte ve alternatif tespit yöntemlerine ihtiyaç duyulduğunu ispatlamaktadır.

RT-PCR testinin dezavantajlarından sıyrılabilmek için radyolojik görüntüleme yöntemleri sıklıkla kullanılmaktadır. COVID-19 hastalığının varlığının tespitini yapabilmek için radyolojik görüntüleme yöntemleriyle akciğer dokuları izlenmektedir. Çünkü SARS-CoV-2 çıkıntılı yapısı yardımıyla akciğer hücrelerine tutunmakta ve hasarlar bırakmaktadır. Günümüzde akciğer dokularını görüntüleyebilmek için çeşitli radyolojik yöntemler mevcuttur. Bu yöntemler arasında x-ışını ve BT taramaları en fazla tercih edilen radyolojik görüntüleme yöntemleridir. Vücudun görüntülerini üretmek için radyasyon kullanılan tanısal görüntüleme tekniğine x-ışını adı verilmektedir [59]. Işınlardan vücuttan geçtiğinde, kemik gibi yoğun nesneler film üzerinde beyaz renkte görünmektedir. Genellikle kemik hastalığı, kırıklar, çıkıklar, enfeksiyonlar ve tümörleri görüntüleyip teşhis etmek için kullanılır. Ancak yumuşak dokuların görüntülenmesinde verimli bir yöntem değildir. Bu sebeple daha karmaşık ve güçlü bir x-ışını olan BT taraması geliştirilmiştir. BT taraması organların, kemiklerin, yumuşak dokuların ve kan damarlarının ayrıntılı görüntülerini üretir ve kanser, kalp hastalığı, kas-iskelet sistemi rahatsızlıkları ve bulaşıcı hastalıkları teşhis etmek için kullanılmaktadır. Belirtilen avantajlarından dolayı bu tez çalışmasında tercih edilen radyolojik görüntüleme yöntemi, göğüs BT taramalarıdır. Şekil 2.3’de farklı kişilere ait x-ışını ve BT taraması örnekleri verilmiştir.




Şekil 2.3. Göğüs X-ışını ve BT Taraması Örnekleri

3. YAPAY ZEKA

İnsanlar tarafından gerçekleştirilen düşünsel faaliyetlerin modellenip makinelere aktarılarak otonom hale getirilmesini hedefleyen bilim dalına yapay zeka adı verilmektedir. Yapay zekanın temel amacı, teknolojik uygulamalara entegre edilmesiyle birlikte makinelerin daha akıllı ve kullanışlı hale getirilmesidir. Charles Babbage tarafından 1884 yılında zeki davranışları makinelere kazandırmak için ortaya koyulan çalışmalar, yapay zeka alanında yapılan ilk çalışmalar olarak kabul edilmektedir [60]. 1930'lu yıllara yaklaşıldığında makinelere zeki davranış kazandırma çalışmalarında karşılaşılan esas sorun işlemlerin belirli sıralamalarla gerçekleşmemesiydi. İkinci Dünya Savaşı devam ederken savaş sırasında Almanların kullandığı Enigma makinesinin şifrelerini çözebilmek için birçok bilim insanı çalışmalar yapmaktaydı. Bu çalışmalar sırasında Allan Mathinson Turingin prensipleri doğrultusunda oluşturduğu bilgisayar prototipi yapay zeka kavramının temelini oluşturmuştur [61]. 1956 yılı Dartmouth Konferansında John McCarthy, isim babası olduğu yapay zeka terimini ortaya atmıştır. İlerleyen süreçte elektriksel ve donanımsal sınırlamalar sebebiyle yapay zeka çalışmalarında duraksamalar yaşanmıştır. 1980'lerden sonra donanım teknolojisindeki yeniliklerle birlikte çok katmanlı modeller yaratılmış ve farklı teknikler geliştirilerek yapay zeka alanındaki çalışma sayısı arttırılmıştır. Geliştirilen bu teknikler arasında insan sinir sisteminin modelini referans alan yapay sinir ağları gibi önemli çalışmalar bulunmaktadır [62].


3.1. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), insan beyinde bulunan biyolojik sinir hücrelerinin birbirine sinyal gönderme şeklini taklit ederek öğrenme, hatırlama ve genelleme gibi önemli temel işlevlerin matematiksel modeller yardımıyla makineler tarafından gerçekleştirilmesini sağlayan sentetik yapılardır. Şekil 3.1'de biyolojik sinir hücresi ve alt bileşenleri verilmiştir.



Şekil 3.1. Biyolojik Sinir Hücresi ve Alt Bileşenleri

YSA'lar yapay sinir hücrelerinin çeşitli yapılarda bağlanmasıyla oluşur ve katmanlı yapıya uygun olarak düzenlenir. Nöroloji hekimi olan Warren McCulloch ve matematikçi Walter Pitts tarafından hazırlanan “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap” adlı makaleyle birlikte ilk kez yapay sinir hücrelerinin matematiksel modeli önerilmiştir [63]. Yapay sinir hücrelerinin temel görevi kendisine girdi olarak verilen bilgilere karşılık bir çıktı üretmektir. Yapay sinir hücresinin görsel kurgusu Şekil 3.2’de verilmiştir.



Şekil 3.2. Yapay Sinir Hücresi

Yapay sinir hücresinin girişine n adet veri girişi yapılmaktadır. Girdi olarak verilen veriler ağırlık değerleriyle çarpılır ve bu işlemlerin sonucu toplama fonksiyonu yardımıyla toplanır. Bias değerinin de eklenmesiyle birlikte aktivasyon fonksiyonuna girecek net girdi elde edilmektedir. Net Girdi (NG) (3.1)’de verilen matematiksel denklemle hesaplanmaktadır.

$$NG = \sum_{i=1}^n X_i W_i + b + y \quad (3.1)$$

YSA’da yer alan her bir hücre birbirinden bağımsız olarak farklı bir fonksiyonuna veya hepsi aynı tip fonksiyona sahip olabilir. Oluşturulan net girdi aktivasyon fonksiyonundan geçirilerek ilgili hücrenin üreteceği çıktı belirlenmektedir. Aktivasyon fonksiyonları genellikle doğrusal olmayan bir fonksiyondur. Yapay sinir hücrelerine gelen net girdiye karşılık çıktıyı aktivasyon fonksiyonu belirlemektedir. Temel olarak bir sinir hücresinin aktive edilip edilmeyeceğine karar vermek için kullanılır. Böylece net girdinin değeri sınırlanmış olur. Doğrusal ve doğrusal olmayan olmak üzere iki farklı tipte aktivasyon fonksiyonları bulunmaktadır. Doğrusal aktivasyon fonksiyonları karmaşık problemlerin çözümünde verimsiz oldukları için çok fazla tercih edilmezler.

Basamak fonksiyonu ve doğrusal fonksiyon doğrusal aktivasyon fonksiyonları sınıfında yer almaktadır. Basamak fonksiyonu çıkışında sadece sıfır veya bir değerlerinden birini vermektedir. NG değeri sıfırdan küçükse basamak fonksiyonu sıfır değerini döndürür. Eğer NG değeri sıfıra eşit


veya sıfırdan büyükse basamak fonksiyonu bir değerini döndürür. Basamak aktivasyon fonksiyonunun matematiksel ifadesi (3.2)'de verilmiştir.

$$f(NG) = \begin{cases} 0, & NG < 0 \\ 1, & NG \geq 0 \end{cases} \quad (3.2)$$

Doğrusal fonksiyon, doğrusal problemlerin çözümünde kullanılmaya uygundur. Doğrusal aktivasyon fonksiyonunun çıkışı doğrudan NG değerine eşittir veya sabit bir sayıyla çarpım uygulanabilir. Her bir sinir hücresinde doğrusal aktivasyon fonksiyonu kullanırsa giriş katmanlarıyla çıkış katmanları arasında hep aynı sonuç olacaktır. Bu sebeple, kullanıldığı durumlarda çok katmanlı çalışma kurgusu geçersiz kılınır. Doğrusal aktivasyon fonksiyonunun matematiksel ifadesi (3.3)'de verilmiştir.

$$f(NG) = NG \quad (3.3)$$

Basamak fonksiyonu ve doğrusal fonksiyonun koordinat düzleminde -20 ve +20 aralığında NG değerlerine karşılık üretmiş oldukları çıkış değerleri Şekil 3.3'de verilmiştir.



Şekil 3.3. Basamak ve Doğrusal Aktivasyon Fonksiyonu Değer Grafikleri


Doğrusal olmayan aktivasyon fonksiyonları çok katmanlı ağlarda etkin bir şekilde kullanılmaktadır. En popüler doğrusal olmayan aktivasyon fonksiyonları arasında sigmoid, softmax, Rektifiye Lineer Birim (ReLU) ve Hiperbolik Tanjant (HT) aktivasyon fonksiyonları bulunmaktadır. Sigmoid aktivasyon fonksiyonu NG değerlerine karşılık sıfır ve bir aralığında değerler döndürür. Sınırlara yakın ağırların hızlı öğrenmemesi nedeniyle sıfıra yakınsar ve bu sebeple yapay sinir ağı modelinden alınabilecek maksimum performans alınamaz. Sigmoid aktivasyon fonksiyonunun matematiksel ifadesi (3.4)'de verilmiştir.

$$f(NG) = \frac{1}{1+e^{-NG}} \quad (3.4)$$

Softmax aktivasyonu, sigmoid aktivasyonuna oldukça benzer özellikler taşımaktadır. NG değerine karşılık sıfır ve bir aralığında değerler döndürmektedir. Sınıflandırma çalışmalarında oldukça popüler bir yaklaşım olan softmax aktivasyon fonksiyonu, ikiden fazla sınıflamanın gerçekleştirilmesi gereken senaryolarda sigmoid yerine tercih edilmektedir. Tahminin ilgili sınıfa ait olma olasılığını sıfır ve bir aralığında değerlerle belirterek olasılıksal tahminleme yapmaktadır. Softmax aktivasyon fonksiyonunun matematiksel ifadesi (3.5)'de verilmiştir.

$$f(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3.5)$$

Softmax aktivasyon fonksiyonu denkleminde $(\vec{z})_i$ giriş vektörünü, z_i giriş vektörü elemanlarını, K çok sınıflı sınıflandırıcıdaki sınıf sayısını temsil etmektedir. Sigmoid fonksiyonu ve softmax fonksiyonun koordinat düzleminde -20 ve +20 aralığında NG ve z_i değerlerine karşılık üretmiş oldukları çıkış değerleri Şekil 3.4'de verilmiştir.



Şekil 3.4. Sigmoid ve Softmax Aktivasyon Fonksiyonu Değer Grafikleri


ReLU aktivasyon fonksiyonu ağda bulunan tüm hücreleri aynı anda aktive etmemesi özelliğine sahiptir ve bu özelliğe sahip olması nedeniyle ara katmanlarda sıkça yer almaktadır. ReLU aktivasyon fonksiyonu sayesinde bir hücre negatif değer üretirse o hücre aktive edilmeyecektir. Bundan dolayı sigmoid benzeri aktivasyon fonksiyonlarına kıyasla daha hızlı çalışmaktadır. ReLU aktivasyon fonksiyonu referans alınarak türetilen çeşitli aktivasyon fonksiyonları bulunmaktadır. Sigmoid aktivasyon fonksiyonunda yaşanan sıfıra yakınsama durumu ReLU aktivasyon fonksiyonunda yaşanmamaktadır. ReLU aktivasyon fonksiyonunun matematiksel ifadesi (3.6)'da verilmiştir.

$$f(NG) = \begin{cases} 0, & NG < 0 \\ NG, & NG \geq 0 \end{cases} \quad (3.6)$$

HT aktivasyon fonksiyonu, sigmoid aktivasyonuna benzer bir kurguya sahiptir. Ancak HT fonksiyonu eksi bir ve artı bir aralığında değerler üretmektedir. Bu sayede sigmoid fonksiyonuna göre daha fazla değer alabilmesi en büyük avantajlarından. Fazla değer alabilmesinin getirdiği faydalar arasında hızlı ve verimli öğrenme gibi özellikler yer almaktadır. Sıfıra yakınsama durumu HT aktivasyon fonksiyonunda da görülebilmektedir. HT aktivasyon fonksiyonun matematiksel ifadesi (3.7)'de verilmiştir.

$$f(NG) = \frac{e^{NG} + e^{-NG}}{e^{NG} - e^{-NG}} \quad (3.7)$$

ReLU aktivasyon fonksiyonu ve HT aktivasyon fonksiyonun koordinat düzleminde -20 ve +20 aralığında NG değerlerine karşılık üretmiş oldukları çıkış değerleri Şekil 3.5'de verilmiştir.




Şekil 3.5. ReLU ve HT Aktivasyon Fonksiyonu Değer Grafikleri

YSA'lar, yapay sinir hücrelerinin birbirlerine çeşitli yöntemlerle bağlanması sonucunda oluşmaktadır. Çıktılar ağırlık değerlerinin yardımıyla diğer yapay sinir hücrelerine veya kendi giriş katmanına bağlanabilmektedir. Yapay sinir hücrelerinin birbirlerine bağlanma türlerinin farklılığı ve kullanılan aktivasyon fonksiyonlarının çeşitliliği sayesinde çokça sayıda yapay sinir ağı modeli geliştirilmiştir. YSA'lar katman yapısına göre tek katmanlı ve çok katmanlı olmak üzere iki farklı türdedir.

3.1.1. Tek Katmanlı Algılayıcılar

Tek katmanlı algılayıcılar sadece girdi ve çıktı katmanından oluşmaktadır. Bu yapıda gizli katman bulunmamaktadır. Birden çok girdiye ve çıktıya sahip olabilen tek katmanlı yapıda değeri daima bire eşit olan bir eşik değer yer almaktadır. Eşik değeri sayesinde süreçteki hücrelerin

değerinin sıfır olmasının önüne geçilir. Tek katmanlı algılayıcıların ilk örneği 1958 yılında Rosenblatt tarafından önerilmiştir. “Perceptron” olarak adlandırılan bu yapı YSA’ların geliştirilmesi süreçlerinde referans alınan en önemli çalışmalardan biridir [64]. Şekil 3.6’da tek katmanlı algılayıcıların görsel kurgusu verilmiştir.




Şekil 3.6. Tek Katmanlı Algılayıcı

Doğrusal olmayan verilerdeki yetersizlik ve karmaşık problemlere karşı çözüm üretilmemesi gibi dezavantajlardan dolayı tek katmanlı YSA’lar yerine çok katmanlı yapılar geliştirilmiştir.

3.1.2. Çok Katmanlı Algılayıcılar

YSA’ların günümüzde en yaygın olarak kullanılan türü çok katmanlı algılayıcılardır. Çok katmanlı algılayıcılar Özel Veya (XOR) probleminin çözümü için gerçekleştirilen çalışmalar neticesinde ortaya çıkmıştır [65]. Çok katmanlı algılayıcılar girdi katmanı, ara katmanlar ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. Şekil 3.7’de çok katmanlı algılayıcı modelinin görsel kurgusu verilmiştir.



Şekil 3.7. Çok Katmanlı Algılayıcı


3.2. Derin Öğrenme

Derin öğrenme, insanın öğrenme yapısını referans almaktadır. İnsanlarda bulunan biyolojik sinir hücreleri ve bu hücreler arasındaki iletişim bağıntı sentetik hale getirilerek makinelerin gerçek bir insan gibi öğrenme süreci yaşamasını amaçlamaktadır. Makine öğrenmesi disiplinin bir alt kümesi olan derin öğrenmede veriler birbirini takip eden katmanlarda işlenir. Derin öğrenme modellerinin derinliği katman sayısı ile doğru orantılıdır. Derin öğrenme modellerinde kurgulanan katmanlı ağ yapıları YSA'lar sayesinde öğrenme eylemini gerçekleştirmektedir. Ancak derin öğrenme algoritmaları karmaşıklık seviyesi incelendiğinde YSA'lara göre daha kompleks bir yapıdadır. Bu algoritmalar hafıza depolaması, veriler arasında iletişimin sağlanması ve öğrenme süreçlerinde avantajlar sağlamaktadır. Derin öğrenme kurgusuyla hazırlanmış bir ağın giriş katmanına girdi olarak verilen veriler çeşitli katmanlarda işlem görmektedir. Bu katmanlarda uygulanan işlemler esnasında verilerden bilgiler öğrenilir, öğrenilen bu bilgiler referans alınarak tahminleme yapılmaktadır. Veriler katmanlarda ilgili katmanın ağırlıklarıyla değişime uğramaktadır. Model ağının çıkışındaki değerlerin takibi için gerçek sonuç ile çıkış katmanında verilen sonuç kıyaslanmaktadır. Kıyaslanan iki değer arasında oluşan fark kayıp fonksiyonu olarak adlandırılmaktadır. Gerçek beklenen sonuç ile ağın çıkış katmanında elde edilen sonuç arasındaki farka paralel olarak kayıp fonksiyonu tarafından derin öğrenme modelinin doğruluk yüzdesi hesaplanmaktadır. Kayıp fonksiyonunun gerçekleştirmiş olduğu bu işlem sayesinde gerçek beklenen sonuçlar ile modelin tahmini arasındaki kayıpların azaltılması için ağırlık matrislerinin değerleri güncellenir. Belirtilen matris değerlerinin güncellenmesi işlemine geriye yayılım yöntemi adı verilmektedir. Klasik makine öğrenmesi metodlarında giriş verilerinden özelliklerin çıkarımı manuel olarak yapılırken derin öğrenme modellerinde manuel özellik çıkarımı işlemine gerek kalmamaktadır. İlgili özellikler otomatik olarak çıkarılmaktadır. Temel makine öğrenmesi algoritmaları daha az katmanlı ve basit bir ağ yapısına sahipken derin öğrenmede daha karmaşık ağ yapıları kullanılmaktadır. Bunun sebebi derin öğrenme çalışmalarında yüksek miktarda verinin işlenmesi için gereken ihtiyaçlardır. Bu ihtiyaçlara yanıt verebilmek için işlem kapasitesi fazla olan donanımların kullanılması gerekmektedir. Donanım teknolojisindeki gelişmelerle birlikte derin öğrenme, görüntülerin ve sinyallerin işlenmesinde, doğal dil işlemede ve daha birçok alanda yaygın olarak kullanılmaktadır. YSA tabanlı çeşitli derin öğrenme mimarileri araştırmacılar tarafından oluşturulmuştur. Bu mimarilere ESA, uzun ve kısa hafızaya sahip sinir ağları, tekrarlayan sinir ağları ve derin inanç ağları örnek verilebilir.

3.2.1. Evrişimli Sinir Ağları

ESA çok katmanlı algılayıcılar sınıfında yer alan bir derin öğrenme mimarisidir. Görüntü verilerini girdi olarak kullanan ESA, görüntülerde yer alan özellikleri kullanarak görüntüler

arasında sınıflandırma işlemi gerçekleştirmektedir. ESA'ya verilen girdiler için uygulanan ön işlemler diğer sınıflandırma algoritmalarına kıyasla daha azdır. Bunun en temel sebebi ESA'nın sahip olduğu filtreleri öğrenme yeteneğidir. ESA mimarisi genel olarak üç katmandan oluşmaktadır. Bu katmanlar sırasıyla evrişimli katman, havuzlama katmanı ve tam bağlantılı katmandır. ESA mimarileri öznetelik çıkarımı ve sınıflandırma olmak üzere iki farklı alt taban içermektedir. Öznetelik çıkarımı tabanında evrişimli katman ve havuzlama katmanı bulunmaktadır. Sınıflandırma tabanında tam bağlı katman ve çıkış bulunmaktadır. ESA mimarisinin görsel kurgusu Şekil 3.8'de verilmiştir.



Şekil 3.8. ESA Mimarisi

Evrişimli katmanlar giriş görüntüsüne işlem uygulayan ilk katmandır. Bu katmanlar giriş görüntüsünden özellik haritaları üretmekten sorumludur. Özellik haritalarını üretirken giriş görüntüsü içerisinde yer alan düşük veya yüksek seviyeli özellikleri algılamak için çeşitli filtreler uygulamaktadır. Görüntüler, sayısal değer taşıyan matrislerdir. Evrişimli katmanlarda bu matrisler üzerinde küçük boyutlu filtre matrisleriyle dolaşarak özellikler elde etmektedir. Şekil 3.9'da örnek bir özellik çıkarımı gösterilmiştir.

7	2	3	3	8
4	5	3	8	4
3	3	2	8	4
2	8	7	2	7
5	4	4	5	4

Giriş Matrisi

$$\begin{matrix}
 1 & 0 & -1 \\
 1 & 0 & -1 \\
 1 & 0 & -1
 \end{matrix}
 \begin{matrix}
 * \\
 \\
 =
 \end{matrix}
 \begin{matrix}
 6 & -9 & -8 \\
 -3 & -2 & -3 \\
 -3 & 0 & -2
 \end{matrix}$$

Filtre Matrisi Çıktı Matrisi

Şekil 3.9. Özellik Çıkarımı Örneği


Görüntü matrisine filtre uygulanırken, filtre matrisi görüntü matrisinin sol üst köşesine yerleştirilir. Yerleştirme işleminden sonra her iki matrisin indisleri çarpılır ve bu değerlerin tamamı toplanarak çıktı matrisinin ilk elemanı oluşturulur. Daha sonra filtre matrisinin yerleştirildiği alan bir piksel sağa kaydırılarak çarpma ve toplama işlemleri tekrarlanır. Sağa kaydırma işlemi genellikle bir piksel olarak gerçekleştirilmekte ve bu işleme, adım adı verilmektedir. Ancak ESA modellerinde adım değeri parametrik olarak değiştirilebilmektedir. Sayısal bir değer olan adım değeri görüntü matrisi üzerinde filtre matrisi gezdirilirken kaç piksel boyunca kayacağını belirlemektedir. Adım değerinin artırılması oluşturulan özellik haritasının daha küçük boyutlu olmasına sebep olmaktadır. Uygun adım değeri belirlendikten sonra ilk satırın tamamına ilgili çarpma ve toplama işlemleri uygulanır ve diğer satırlardan devam edilir. Giriş matrisinde yer alan tüm elemanları kapsayacak şekilde işlem tamamlandıktan sonra filtre matrisinin boyutu kadar bir çıktı matrisi oluşturulur. Bu sebeple oluşturulan çıktı matrisi giriş matrisinden daha küçük boyutta olacaktır. Bunu önlemek için dolgulama adı verilen yöntem sıkça kullanılmaktadır. Dolgulama yönteminde görüntü matrisini çerçeveye alacak şekilde sıfır değerleri eklenmektedir. Şekil 3.10'da örnek bir dolgulama yöntemi çıktısı verilmiştir.

0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0
0	0	7	2	3	3	8	0	0
0	0	4	5	3	8	4	0	0
0	0	3	3	2	8	4	0	0
0	0	2	8	7	2	7	0	0
0	0	5	4	4	5	4	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

Şekil 3.10. Dolgulama Yöntemi Çıktısı

Evrişimli katmandan iletilen matrislerde bilgi kaybının yaşanmaması verimlilik açısından oldukça önemlidir. Görüntü matrisleri üzerinde özellik çıkarımı yapılırken dolgulama işlemi kullanılmadığında diğer katmana iletilecek çıktı matrisinin boyutunun küçük olması sebebiyle bilgi kaybı yaşanması kaçınılmazdır. Bu sebeple çıktı matrislerini oluştururken dolgulama yöntemi kullanılması gerekmektedir. Çıktı matrisinin oluşturulması sayesinde görüntü üzerindeki özellikler tespit edilmektedir. ESA mimarisinde filtrelerdeki değerler modellerin öğrendiği parametrelere karşılık gelmektedir. Model tarafından özelliklerin daha iyi tespit edilebilmesi için sürekli olarak değerler güncellenmektedir. Görüntü üzerinde sadece bir adet özellik olmayacağından dolayı birden fazla filtre işleme uygulanmalıdır. Birden fazla filtre işleminin uygulanabilmesi için de evrişimli katman sayısının artırılması gerekmektedir. Evrişimli katmanlar havuzlama katmanlarıyla birleştirilir ve bu katmanların çıktıları tam bağlı katmanları beslemektedir. ESA


mimarisinde bir biri ardına gelen evrişimli katmanlar arasında havuzlama katmanları yer almaktadır. Havuzlama katmanlarının temel görevi, evrişimli katmandan iletilen matrislerin boyutlarının çok büyük olduğu durumlarda ilgili parametre sayısını düşürerek matris boyutunu küçültmektir. Bu işlem gerçekleştirilirken önemli bilgiler korunmakta ve yalnızca matrislerin boyutsallığı azaltılmaktadır. Havuzlama katmanında kullanılan iki farklı havuzlama yöntemi mevcuttur. Bunlar maksimum ve ortalama havuzlama yöntemleridir. ESA mimarilerinde genel olarak maksimum havuzlama yöntemi tercih edilmektedir. Şekil 3.11’de maksimum havuzlama yöntemi uygulanmış bir örnek verilmiştir.



Şekil 3.11. Maksimum Havuzlama Yöntemi

ESA’ların son işlemleri tam bağlı katmanda gerçekleştirilmektedir. Bu katman, önceki katmanlarda yer alan yapay sinir hücrelerinin bir sonraki katmanda bulunan yapay sinir hücrelerine bağlanmasından dolayı tam bağlı katman olarak isimlendirilmektedir. Tam bağlı katmanın temel görevi bir önceki katmandan gelen matrisi girdi olarak kullanarak çıkışta sınıf tahmininin yapılmasını sağlamaktır. Ancak tam bağlı katmanlarda bulunan yapay sinir hücreleri tek boyutlu dizilerle işlem yapabilme yeteneğine sahiptir. Bu sebeple bir önceki katmandan gelen matrisler üzerinde düzeltme işlemi yapılması gerekmektedir. Düzeltme işlemi uygulanmış verileri


işleyen yapay sinir hücreleri sayesinde öğrenme işlemi gerçekleşmektedir. Şekil 3.12’de düzleştirme işlemi uygulanmış bir örnek verilmiştir.



Şekil 3.12. Düzleştirme Yöntemi

3.2.2. Transfer Öğrenme

Transfer öğrenme, ESA modellerinde eğitim aşamasında başlangıç ağırlıkları olarak önceden eğitilmiş bir modelin ağırlıklarının yeniden kullanıldığı bir makine öğrenimi yöntemidir. Daha önceden bir görev üzerinde eğitilmiş model, hızlı ilerlemeye imkan sağlayarak farklı görevlerde yeniden kullanılabilir. Transfer öğrenmeyi kullanarak az miktarda veriyle gerçekleştirilen eğitimden önemli ölçüde yüksek performans elde edilebilir. Günümüzde transfer öğrenme yöntemi oldukça popüler bir yöntem haline gelmiştir. Bu sebeple görüntü veya doğal dil işleme ile ilgili görevler için sıfırdan bir model eğitime rastlamak oldukça nadirdir. Sıfırdan model eğitmek yerine araştırmacılar tarafından, nasıl sınıflandıracağını zaten bilen ve görüntülerdeki kenarlar, şekiller gibi genel özellikleri öğrenmiş önceden eğitilmiş bir model tercih edilmektedir. AlexNet, Inception, EfficientNet ve DenseNet gibi ImageNet veri tabanı yardımıyla eğitilmiş modeller transfer öğrenmenin temelini oluşturan tipik örneklerdir. Şekil 3.13’de transfer öğrenme yönteminin işleme mantığı verilmiştir.



Şekil 3.13. Transfer Öğrenme Yönteminin İşleme Mantığı


4. AKCİĞER GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Göğüs BT görüntülerinin ikili sınıflandırma metoduna uygun biçimde derin öğrenme modeli tarafından COVID-19 pozitif veya COVID-19 negatif olarak tahmin edilebilmesi için sınıflandırıcı bir sistem tasarlanmıştır. Bu kapsamda tasarlanan sistem giriş görüntüsü, sınıflandırıcı derin öğrenme modeli ve tahmin edilen sınıf etiketi olmak üzere üç bileşenden oluşmaktadır. Tasarlanan sınıflandırıcı sistemin görsel kurgusu Şekil 4.1’de verilmiştir.




Şekil 4.1. Tasarlanan Sınıflandırıcı Sistem

Sınıflandırıcı derin öğrenme modelinin giriş katmanına verilen görüntü, çıkış katmanında COVID-19 hastalığı açısından pozitif veya negatif olarak sınıflandırılmaktadır. Bu sınıflandırma sürecinin en önemli parametrelerinden biri başarılı eğitilmiş derin öğrenme modelinin varlığıdır. Başarı oranı yüksek bir sınıflandırıcı derin öğrenme modeline sahip olmak için de eğitim aşamasında kullanılan veri seti oldukça önemlidir. Halka açık bir veri seti kullanarak model eğitmek kaynak ve zaman açısından en maliyetsiz yöntemdir. Angelov P. ve ark. [66] tarafından gerçekleştirilen çalışmada “SARS-CoV-2 CT-scan” adlı halka açık bir veri seti paylaşılmıştır. İlgili veri setinde bir göğüs BT görüntüsünden tespiti yapılabilecek COVID-19 bulgularından herhangi birini içermeyen ve yanlış etiketlenilmiş örnekler bulunmaktadır. Belirtilen örnekler, veri setindeki adlandırılmalarıyla birlikte Şekil 4.2’de verilmiştir.



Şekil 4.2. ‘SARS-CoV-2 CT-scan’ Veri Setinde Yanlış Etiketlendirilmiş Örnekler

Xingyi Y. ve ark. [67] tarafından yapılan çalışma sonucunda halka açık bir veri seti paylaşılmıştır. Paylaşılan veri seti içerisinde göğüs BT görüntülerinin standartta bulunmamaktadır. Belirtilen örnekler ve veri setindeki isimlendirilmeleri Şekil 4.3’de verilmiştir.



Şekil 4.3. Halka Açık Veri Setindeki Farklı Standartta Sahip Örnekler

Halka açık veri setlerinde dengesiz sınıf dağılımının olması, yanlış etiketlenmiş görüntülerin yer alması, örneklerin kapsamının darlığı ve farklı radyolojik çekim türlerinin kullanılması model eğitiminde başarının istenilen düzeye çıkamamasına sebep olabilir. Bu sebeple sınıflandırıcı derin öğrenme modelinin eğitiminde kullanılmak üzere EFSCH-19 adındaki veri seti tarafımızca oluşturulmuştur. Bu veri seti literatürdeki çalışmalarda çokça kullanılan halka açık veri setlerinden herhangi bir örnek içermemektedir.

4.1. EFSCH-19 Veri Seti

2021/04-40 oturum sayılı Fırat Üniversitesi Girişimsel Olmayan Etik Kurul kararı, Elazığ Fethi Sekin Şehir Hastanesi Başhekimliği tarafından verilen çalışma yürütme izni ve T.C Sağlık Bakanlığı’ndan alınan bilimsel araştırma onayı sayesinde EFSCH-19 veri seti oluşturulmuştur. İkili sınıflandırma yöntemine uygun olarak hazırlanan EFSCH-19 veri seti COVID-19 pozitif ve COVID-19 negatif olarak adlandırılan iki sınıfa sahiptir. Her bir sınıfı 2000 adet örnek içeren EFSCH-19 veri setinde toplamda 4000 adet göğüs BT görüntüsü yer almaktadır. Bu görüntülerin tamamı 768×768px çözünürlüğünde ve Tıpta Dijital Görüntüleme ve İletişim (DICOM) veri formatındadır. Hasta mahremiyetini korumak için hasta bilgilerinin yer aldığı katmanlar, tarafımıza iletilmeden önce ilgili görüntülerden çıkarılmıştır. Veri setinin detayları Tablo 4.1’de verilmiştir.


Tablo 4.1. EFSCH-19 Veri Seti Detayları

Sınıf Etiketi	Veri Formatı	Adet	Çözünürlük	Hasta Bilgisi
COVID-19 Pozitif	DICOM	2000	768×768px	Yok
COVID-19 Negatif	DICOM	2000	768×768px	Yok

4.1.1. Radyolojik Altyapı


Cömert, S. Ş. ve ark. [68] tarafından yapılan çalışmada, COVID-19 enfeksiyonunda görülen radyolojik bulgular detaylıca belirtilmiştir. Bu bulgular tipik ve atipik olmak üzere iki ana başlık üzerinde toplanmaktadır. Tipik bulgular arasında buzlu cam opasitesi, konsolidasyon, kaldırım taşı görünümü ve hava kabarcıkları vardır. Belirtilen tipik bulguları içeren gerçek hastaların göğüs BT görüntüleri, EFSCH-19 veri setinde COVID-19 pozitif etiketiyle yer almaktadır. İlgili örnekler ve içerdiği bulguların doğruluğu radyoloji uzmanı tarafından onaylanmıştır. EFSCH-19 veri setindeki örnekler ve temsil ettiği bulgular hakkındaki bilgiler aşağıdaki gibidir.

Buzlu cam opasitesi, COVID-19 olgularında en sık rastlanan bulgudur. Vasküler ve bronşial damarsal yapıları silmeden akciğer dansitesindeki yoğunluk artışları olarak belirtilmekte ve COVID-19 hastalığının erken dönemlerinde sıklıkla görülmektedir. Konsolidasyon ve kaldırım taşı görünümü gibi diğer bulgularla birlikte görülebileceği gibi tek başına da görülebilir. Buzlu cam opasitesi bulgusunu içerdiği için COVID-19 pozitif etiketine sahip olan EFSCH-19 veri seti örnekleri ve isimlendirilmeleri Şekil 4.4’de verilmiştir.




Şekil 4.4. EFSCH-19’un Buzlu Cam Opasitesi Örnekleri

Konsolidasyon, akciğer yoğunluğundaki artış sebebinin alveollerdeki havanın yerini kan, patolojik sıvı veya dokuların almasına bağlı olduğu durumlardır. Damar ve hava yolları çizgilerinin silindiği konsolidasyon bulguları, bu sayede buzlu cam opasitesi bulgularından ayırt edilebilmektedir. Konsolidasyon bulgusunu içerdiği için COVID-19 pozitif etiketine sahip olan EFSCH-19 veri seti örnekleri ve isimlendirilmeleri Şekil 4.5’de verilmiştir.




Şekil 4.5. EFSCH-19’un Konsolidasyon Örnekleri

Kaldırım taşı görünümü, kalınlaşan interlobüler ve intralobüler septaların buzlu cam opasiteleriyle birlikte yer alması olarak tanımlanmaktadır. COVID-19 hastalığı açısından buzlu cam opasiteleri ve konsolidasyon bulguları kadar sık görülmeyen kaldırım taşı görünümü bulguları, hastalığın ilerlediğine dair bir işaret olarak yorumlanabilmektedir. Kaldırım taşı görünümü bulgusunu içerdiği için COVID-19 pozitif etiketine sahip olan EFSCH-19 veri seti örnekleri ve isimlendirilmeleri Şekil 4.6'da verilmiştir.



Şekil 4.6. EFSCH-19'un Kaldırım Taşı Görünümü Örnekleri


Hava kabarcıkları, akciğer bronş dokularının hava yerine yumuşak hücre ve dokularla dolması sonucunda görüntü üzerinde siyah renkte görülmektedir. Görüntüsü itibariyle kiste benzediği için hekimler tarafından yanlış yorumlanabilmektedir. COVID-19 hastalığının diğer bulgularına kıyasla görülme sıklığı daha azdır. Hava kabarcığı bulgusunu içerdiği için COVID-19 pozitif etiketine sahip olan EFSCH-19 veri seti örnekleri ve isimlendirilmeleri Şekil 4.7'de verilmiştir.



Şekil 4.7. EFSCH-19'un Hava Kabarcığı Örnekleri


EFSCH-19 veri seti örneklerinin ait oldukları sınıfların belirlenmesi ve etiketlenilmesi süreçlerinde radyoloji uzmanının görüşlerinden faydalanılmıştır. COVID-19 pozitif sınıfı içerisinde yer alan örneklerin dağılımında, buzlu cam opasitesi bulgusunu içeren görüntü sayısı diğer bulguları içeren görüntülerin sayısına kıyasla daha fazladır. Ancak bu durumun sınıflar arasında da yaşanmaması için eşit sayıda örnek kullanılmasına özen gösterilmiştir. EFSCH-19 veri setinde COVID-19 negatif etiketiyle yer alan görüntülerde sadece sağlıklı kişilerin göğüs BT

görüntüleri bulunmaktadır. COVID-19 negatif etiketine sahip olan EFSCH-19 veri seti örnekleri ve isimlendirilmeleri Şekil 4.8’de verilmiştir.



Şekil 4.8. EFSCH-19’un COVID-19 Negatif Örnekleri

EFSCH-19 veri setinde yer alan 2000 adet COVID-19 pozitif ve 2000 adet COVID-19 negatif etiketine sahip görüntülerin dağılımını daha iyi ifade edebilmek için, 3-boyutlu t-dağıtılmış Stokastik Komşu Yerleştirme (t-SNE) grafiği Şekil.4.9’da verilmiştir.



Şekil 4.9. EFSCH-19’un 3-Boyutlu t-SNE Grafiği

4.1.2. Raporlama Standartlarına Uygunluk

Pandemi koşulları göz önüne alındığında hasta yönetiminin hızlı yapılabilmesi gereklidir ve bunun için radyologların radyolojik görüntülerden COVID-19 enfeksiyonu bulgularını tespit etmesi beklenmektedir. Belirtilen süreç için standartlaşmış raporlama örnekleri ve sınıflamalar mevcuttur. Verilerin analizinin kolaylaşması ve ortak terimlerin kullanılması standartlaştırılmış

raporlamanın en büyük faydalarındandır. CO-RADS belirtilen sınıflamalar arasında yer almakta ve ülkemizde radyologlar tarafından süreçlerde kullanılmaktadır. CO-RADS çalışmasına göre COVID-19 tespiti için göğüs BT görüntülerinin radyolojik bulguları yedi farklı kategoriye ayrılmaktadır [69]. Şüpheli seviyesi ve açıklamaları Tablo 4.2’de verilen CO-RADS kategorilerinin temsil ettiği durumların detayı aşağıdaki gibidir.

- CO-RADS-0 kategorisi, eksik veya kalitesiz BT taramaları için kullanılmaktadır.
- CO-RADS-1 kategorisi, COVID-19’un akciğer tutumu için çok düşük şüpheli durumlarında kullanılmaktadır.
- CO-RADS-2 kategorisi, COVID-19 ile uyumlu olmayan bulguların yer aldığı düşük şüpheli için kullanılmaktadır.
- CO-RADS-3 kategorisi, COVID-19 enfeksiyonunda içinde yer aldığı akciğer için şüpheli bulguların olduğu durumlarda kullanılır.
- CO-RADS-4 kategorisi, COVID-19 enfeksiyonun tipik bulguları ve aynı zamanda diğer enfeksiyonlara biraz benzeyen oldukça şüpheli durumlar için kullanılmaktadır.
- CO-RADS-5 kategorisi, COVID-19 enfeksiyonunun akciğer tutulumu için çok yüksek şüpheli durumlarında kullanılmaktadır.
- CO-RADS-6 kategorisi, PT-PCR test sonuçları tarafından kanıtlanmış COVID-19’u belirtmek için kullanılmaktadır.

Tablo 4.2. CO-RADS Kategorileri


CO-RADS Kategorisi	COVID-19 Şüpheli Seviyesi	Açıklama
0	Yorumlanamaz	Teknik olarak yetersiz tarama
1	Çok düşük	Normal veya enfekte olmayan
2	Düşük	COVID-19 için tipik değil
3	Belirsiz	COVID-19 ve diğerleriyle uyumlu
4	Yüksek	COVID-19 için şüpheli
5	Çok yüksek	COVID-19 için tipik
6	Kanıtlanmış	SARS-CoV-2 için pozitif test

EFSCH-19’da COVID-19 pozitif etiketine sahip görüntüler CO-RADS-5 kategorisinde yer alırken, COVID-19 negatif etiketine sahip görüntülerse CO-RADS-1 kategorisinde yer almaktadır.

4.2. Sınıflandırıcı Derin Öğrenme Mimarisi

ESA’lar genellikle sabit bir kaynak maliyetiyle geliştirilir ve sonra daha fazla kaynak kullanıma sunulduğunda daha iyi doğruluk elde etmek için katman sayısı artırılır. Katman sayısının artırılmasının yanı sıra derinliği veya genişliğini artırmak, eğitim ve değerlendirme için

modellerde, giriş katmanı boyutu ve sahip olunan parametre sayısı farklılık göstermektedir. Bu farklılıkları meydana getiren ölçeklendirme yöntemleri Şekil 4.11’de verilmiştir.



Şekil 4.11. EfficientNet Ölçeklendirme Yöntemleri [70]


EfficientNet model ailesinde yer alan temel model ve diğer modellerin detayları Tablo 4.4’de belirtilmiştir.

Tablo 4.4. EfficientNet Model Ailesi Üyelerinin Detayları [72]

Model Adı	Çözünürlük	Bırakma Oranı	Derinlik Katsayısı	Genişlik Katsayısı
EfficientNet-B0	224×224	0.2	1.0	1.0
EfficientNet-B1	240×240	0.2	1.1	1.0
EfficientNet-B2	260×260	0.3	1.2	1.1
EfficientNet-B3	300×300	0.3	1.4	1.2
EfficientNet-B4	380×380	0.4	1.8	1.4
EfficientNet-B5	456×456	0.4	2.2	1.6
EfficientNet-B6	528×528	0.5	2.6	1.8
EfficientNet-B7	600×600	0.5	3.0	2.0

EfficientNet model ailesini literatürdeki diğer popüler modellerle kıyaslamak için araştırmacılar tarafından ImageNet veri seti kullanılarak sınıflandırma problemi çözülmüştür. Sınıflandırma işlemi sonucunda EfficientNet modellerinin diğer modellere nispeten daha az parametreyle daha fazla başarı oranına ulaştığı görülmektedir. Bu sebeple göğüs BT görüntülerinin COVID-19 pozitif veya COVID-19 negatif olarak sınıflandırılması görevinde EfficientNet model ailesi tercih edilmiştir. Şekil 4.12’de, ImageNet [73] veri seti yardımıyla gerçekleştirilen

sınıflandırma probleminin çözümünde popüler modellerin ortaya koyduğu performansların başarımlarını karşılaştıran bir grafik verilmiştir.



Şekil 4.12. ImageNet Doğruluk Karşılaştırılması [70]


4.3. Sınıflandırıcı Derin Öğrenme Model Eğitimi

Sınıflandırıcı derin öğrenme modelinin eğitiminde EfficientNet model ailesinin üyelerinden yararlanılmıştır. Sekiz farklı giriş boyutuna ve katman sayısına sahip modeller Python programlama diliyle oluşturulan Keras kütüphanesi sayesinde eğitime dahil edilmiştir. Eğitime dahil edilen modellerde rastgele başlangıç ağırlıkları yerine ImageNet ağırlıklarının kullanılması tercih edilmiştir. İlgili modellerin son katmanları sadece sıfır ve bir aralığında çıktı üretilmesine uygun olacak şekilde revize edilmiştir. Revize edilen son katmanlarda aktivasyon fonksiyonu olarak softmax aktivasyon fonksiyonu kullanılmıştır. Model eğitim aşamaları sonucunda en yüksek doğruluk oranına ulaşan model tercih edileceğinden tüm eğitim süreçleri; Adam optimizasyonu, çapraz entropi kaybı, 16 parti boyutu ve öğrenme oranı 0.001 değerinde sabit tutularak 50 tur sayısı boyunca erken sonlandırma fonksiyonu aktif olacak şekilde yürütülmüştür. Bu süreçlerin tamamı Google Colab ortamında gerçekleştirilmiştir. Eğitim esnasında takip edilen değer doğrulanan doğruluk oranıdır. Doğrulanan doğruluk oranı art arda beş tur sayısı boyunca en yüksek değeri aşmadığında erken durdurma fonksiyonu devreye girerek en yüksek değere sahip adımla 'hd5' formatında kaydetmesi sağlanmıştır. Bu sayede en başarılı sınıflandırma yeteneğine sahip adımla ulaşmak hedeflenmiştir.

4.3.1. Önerilen Eğitim Kurgusu

EFSCH-19 veri setinde yer alan göğüs BT görüntüleri çözünürlüklerinden ve formatlarından dolayı doğrudan EfficientNet model ailesinde yer alan modellerin eğitiminde kullanılamaz. Bu


sebeple EFSCH-19 veri seti elemanlarına ön işlem adımları uygulanmalıdır. Ön işlem adımlarından sonra çalışmamıza en uygun modeli belirlemek için sırasıyla EfficientNet-B0'dan başlayarak EfficientNet-B7'ye kadar tüm modeller parametreler sabit tutularak eğitilmelidir. Eğitim aşamaları tamamlandıktan sonra çeşitli performans metrikleri incelenerek kullanılacak en uygun EfficientNet modeli belirlenir. Sınıflandırıcı derin öğrenme modelinin eğitiminde kullanılan yöntemin görsel kurgusu Şekil 4.13'de verilmiştir.



Şekil 4.13. Önerilen Sınıflandırıcı Model Eğitim Kurgusu


4.3.2. Ön İşlem Adımları

EFSCH-19 veri setinde DICOM veri formatına sahip olan tüm görüntüler ImageJ uygulaması yardımıyla Birleşik Fotoğraf Uzmanları Grubu (JPEG) formatına dönüştürülmüştür. Bu dönüştürme işlemi kayıpsız yakın bir biçimde gerçekleştirilmiştir. Şekil 4.14’de dönüştürme işleminin öncesi ve sonrasında elde edilen sonuç dört kat yakınlaştırma ile birlikte verilmiştir.




Şekil 4.14. DICOM-JPEG Dönüşümü

Tüm örnekler JPEG veri formatına dönüştürüldükten sonra yeniden boyutlandırma işlemi gerçekleştirilmiştir. 768×768px çözünürlüğüne sahip görüntüler eğitimlerine dahil edilecekleri modelin giriş boyutuna uygun olarak yeniden boyutlandırılmıştır. Şekil 4.15’de yeniden boyutlandırma işlemi gösterilmiştir.



Şekil 4.15. Yeniden Boyutlandırma İşlemi

İlgili modellerin eğitimine başlamadan önce yeniden boyutlandırılmış EFSCH-19 veri seti örneklerinin %70'i eğitim, %20'si doğrulama ve %10'u test aşamalarında kullanılmak üzere ve sınıf dağılımı korunarak rastgele bölünmüştür. Şekil 4.16'da veri bölme işlemi gösterilmiştir.



Şekil 4.16. Veri Bölme İşlemi

EFSCH-19 veri seti örneklerinin veri bölme işlemi sonrasındaki sayısal dağılımları hakkında detaylı bilgi Tablo 4.5'de verilmiştir. Bu sayısal bilgiler eğitilen modelin isminden bağımsız olup sekiz model için de geçerlidir.

Tablo 4.5. EFSCH-19'un Veri Bölme Sonrası Sayısal Dağılımı

Aşama	COVID-19 Pozitif Örnek Sayısı	COVID-19 Negatif Örnek Sayısı
Eğitim	1400	1400
Doğrulama	400	400
Test	200	200

4.4. Değerlendirme Metrikleri

Sınıflandırma çalışmalarında derin öğrenme modelinin performansının değerlendirilmesinde karışıklık matrisi tabanlı performans ölçümleri kullanılmaktadır. Karışıklık matrisi, giriş görüntüsü için derin öğrenme modelinin çıkış katmanında tahmin ettiği sınıf etiketiyle giriş görüntüsünün bilinen gerçek sınıf etiketi arasındaki ilişki hakkında bilgi sağlamaktadır. İkili sınıflandırma metoduna uygun derin öğrenme modelleri çıkışlarında sadece iki farklı sınıf tahmin edebilir. Bundan dolayı sınıf tahmininde en fazla dört farklı durum ortaya çıkabilir. Bu durumların detayları aşağıdaki gibidir.

- Doğru Pozitif (DP) olarak adlandırılan ilk durum COVID-19 pozitif etiketine sahip bir görüntünün sınıflandırıcı derin öğrenme modeli tarafından COVID-19 pozitif olarak tahmin edilmesidir.

- Yanlış Pozitif (YP) olarak adlandırılan ikinci durum COVID-19 negatif etiketine sahip bir görüntünün sınıflandırıcı derin öğrenme modeli tarafından COVID-19 pozitif olarak tahmin edilmesidir.
- Yanlış Negatif (YN) olarak adlandırılan üçüncü durum COVID-19 pozitif etiketine sahip olduğu bilinen bir görüntünün sınıflandırıcı derin öğrenme modeli tarafından COVID-19 negatif olarak tahmin edilmesidir.
- Doğru Negatif (DN) olarak adlandırılan dördüncü durum COVID-19 negatif etiketine sahip olduğu bilinen bir görüntünün sınıflandırıcı derin öğrenme modeli tarafından COVID-19 negatif olarak tahmin edilmesidir.

DP, YP, YN ve DN değerlerinin 2×2 boyutundaki bir matrise yerleştirilmesi sonucunda karışıklık matrisi görsel olarak ifade edilebilmektedir. Şekil 4.17’de karışıklık matrisinin görsel yapısı ve ilgili değerlerin yerleştirilme sırası gösterilmiştir.

		Doğru Sınıf	
		Pozitif	Negatif
Tahmin Edilen Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Şekil 4.17. Karışıklık Matrisi Yapısı

DP ve DN durumuna ait örneklerinin sayısı fazla olduğunda derin öğrenme modelinin sınıflandırma yeteneğinin gelişmiş olduğu anlamına gelecektir. Sınıflandırma yeteneğinin ölçülebilmesi için DP, YP, YN ve DN değerlerini kullanarak çeşitli performans metrikleri standartlaştırılmıştır. Bu metrikler ve matematiksel denklemleri aşağıda yer almaktadır.

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+YN+DN} \quad (4.1)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (4.2)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (4.3)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (4.4)$$

$$\text{Negatif Tahmin} = \frac{DN}{DN+YN} \quad (4.5)$$


$$\text{F1 Skoru} = \frac{2 * (\text{Kesinlik} * \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})} \quad (4.6)$$

$$\text{Matthews Korelasyon Katsayısı (MCC)} = \frac{(DP * DN) - (YP * YN)}{\sqrt{(DP + YP)(DP + YN)(DN + YP)(DN + YN)}} \quad (4.7)$$

Standartlaşmış istatistiksel değerlendirme metriklerinin yanı sıra derin öğrenme modelinin tahminlerinde görsel üzerinde odaklandığı alanların karşılaştırılması da oldukça önemlidir.

4.5. Gradyan Ağırlıklı Sınıf Aktivasyon Eşleşmesi


Grad-CAM [74] algoritması, sınıflandırıcı derin öğrenme modeline giriş olarak verilen görüntü için sınıf tahmini yapıldığında görüntü üzerinde hangi alanlara dikkat edildiğini sıcaklık haritası tekniğini kullanarak görselleştirmektedir. Bu sayede sınıfı doğru tahmin edilen görüntülerde sınıflandırıcı derin öğrenme modelinin odaklandığı alanların gerçekten de sınıfın belirlenmesinde etkin rol oynayan alanlar olup olmadığının tespiti yapılabilmektedir. Grad-CAM algoritmasının önerilen yaklaşımı Şekil 4.18’de verilmiştir.



Şekil 4.18. Grad-CAM Algoritması Yaklaşımı [74]


Grad-CAM algoritması bir ESA'nın son evrişim katmanı tarafından üretilen özellik haritalarını referans alarak işlemlerini gerçekleştirmektedir. Bu sebeple sınıflandırıcı derin

öğrenme modelinin son evrişim katmanı Grad-CAM algoritmasına sahip olduğu isimlendirmeyle birlikte referans gösterilmelidir. EfficientNet-B0 modelinin çıkıştan önceki son evrişim katmanı ve sahip olduğu isimlendirme kırmızı çerçeve içerisinde belirtilerek Şekil 4.19’da verilmiştir.



Şekil 4.19. EfficientNet-B0 Modeli Son Evrişimli Katmanı

Son evrişim katmanının referans olarak alınmasının ardından görüntü üzerinde sınıf etiketine ait önemli noktaları vurgulamak için gradyanlar yardımıyla ısı haritası oluşturulmaktadır. Oluşturulan ısı haritalarında sarı ve kırmızı renkteki alanlar sınıflandırıcı derin öğrenme modelinin tahmin yaparken dikkat ettiği piksel alanlarını belirtmektedir. Şekil 4.20’de Grad-CAM algoritması kullanılarak, giriş görüntülerine karşılık üretilen örnek çıktılar verilmiştir.




Şekil 4.20. Örnek Grad-CAM Çıktıları

4.6. Test Aşamasında Elde Edilen Bulgular


4.6.1. EfficientNet-B0 Modeli Bulguları

EfficientNet model ailesinin temel modeli olarak adlandırılan EfficientNet-B0, EFSCH-19 veri seti örnekleri kullanılarak ve erken sonlandırma fonksiyonun yardımıyla maksimum 50 tur sayısı sürece şekilde eğitilmiştir. EfficientNet-B0 modeli en yüksek doğrulama doğruluk oranına 10. tur sayısında elde ettiği 0.9975 değeriyle ulaşmıştır. Her biri 175 adım süren 10 tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve doğruluk grafikleri Şekil 4.21’de verilmiştir.




Şekil 4.21. EfficientNet-B0’ın Kayıp ve Doğruluk Grafiği

Sadece test aşamasında kullanılması için ayrılan görüntüler EfficientNet-B0 modeline girdi olarak verilmiştir. Modelin bu test görüntüleri için gerçekleştirmiş olduğu tahminler referans alınarak oluşturulan karışıklık matrisi Şekil 4.22’de verilmiştir.




Şekil 4.22. EfficientNet-B0’ın Karışıklık Matrisi

EfficientNet-B0 modeli 400 adet test görüntüsünde yer alan 200 adet COVID-19 pozitif göğüs BT görüntüsünün 196 adetini, 200 adet COVID-19 negatif göğüs BT görüntüsününse 199 adetini doğru bir şekilde sınıflandırmıştır. EfficientNet-B0 modelinin başarılı tahminleri arasından rastgele seçilen örnekler Şekil 4.23’de verilmiştir.



Şekil 4.23. EfficientNet-B0'nın Başarılı Tahmin Örnekleri

EfficientNet-B0 modeli 400 adet test görüntüsü içerisinde yer alan beş adet göğüs BT görüntüsünün sınıfını yanlış tahmin etmiştir. Şekil 4.24’de EfficientNet-B0 modeli tarafından sınıfı yanlış tahmin edilen örnekler verilmiştir.




Şekil 4.24. EfficientNet-B0'nın Başarısız Tahmin Örnekleri

EfficientNet-B0 modelinin, göğüs BT görüntülerini içerdiği bulgulara göre COVID-19 pozitif veya COVID-19 negatif olarak sınıflandırılabilme yeteneğini kazanabildiği görülmektedir. Tablo 4.6’da ilgili modelin test aşamasında ulaştığı performans metriklerinin değerleri verilmiştir.

Tablo 4.6. EfficientNet-B0'nın Performans Değerleri

Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Skoru	MCC
0.9875	0.9800	0.9949	0.9950	0.9874	0.9751


EfficientNet-B0 modelinin tahminlerinde göğüs BT görüntüsü üzerinde hangi alanlara odaklandığını gösteren Grad-CAM çıktıları oluşturulmuştur. 224×224 px çözünürlüğüne sahip giriş görüntüleri için EfficientNet-B0 modelinin son evrişim katmanında bulunan özellik değerleri sayesinde üretilen ısı haritaları ve Grad-CAM çıktıları Şekil 4.25’de birlikte verilmiştir.



Şekil 4.25. EfficientNet-B0’ın Grad-CAM Çıktıları


4.6.2. EfficientNet-B1 Modeli Bulguları

EfficientNet model ailesinde yer alan EfficientNet-B1, EFSCCH-19 veri seti örnekleri kullanılarak ve erken sonlandırma fonksiyonun yardımıyla maksimum 50 tur sayısı sürecektir şekilde eğitilmiştir. EfficientNet-B1 modeli en yüksek doğrulama doğruluk oranına 8. tur sayısında elde ettiği 1.00 değeriyle ulaşmıştır. Her biri 175 adım süren sekiz tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve doğruluk grafikleri Şekil 4.26’da verilmiştir.




Şekil 4.26. EfficientNet-B1’in Kayıp ve Doğruluk Grafiği

Sadece test aşamasında kullanılması için ayrılan görüntüler EfficientNet-B1 modeline girdi olarak verilmiştir. Modelin bu test görüntüleri için gerçekleştirmiş olduğu tahminler referans alınarak oluşturulan karışıklık matrisi Şekil 4.27’de verilmiştir.




Şekil 4.27. EfficientNet-B1’in Karışıklık Matrisi

EfficientNet-B1 modeli 400 adet test görüntüsünde yer alan 200 adet COVID-19 pozitif göğüs BT görüntüsünün 198 adetini, 200 adet COVID-19 negatif göğüs BT görüntüsününse 198 adetini doğru bir şekilde sınıflandırmıştır. EfficientNet-B1 modelinin başarılı tahminleri arasından rastgele seçilen örnekler Şekil 4.28’de verilmiştir.



Şekil 4.28. EfficientNet-B1’in Başarılı Tahmin Örnekleri

EfficientNet-B1 modeli 400 adet test görüntüsü içerisinde yer alan dört adet göğüs BT görüntüsünün sınıfını yanlış tahmin etmiştir. Şekil 4.29’da EfficientNet-B1 modeli tarafından sınıfı yanlış tahmin edilen örnekler verilmiştir.




Şekil 4.29. EfficientNet-B1’in Başarısız Tahmin Örnekleri

EfficientNet-B1 modelinin, göğüs BT görüntülerini içerdiği bulgulara göre COVID-19 pozitif veya COVID-19 negatif olarak sınıflandırılma yeteneğini kazanabildiği görülmektedir. Tablo 4.7’de ilgili modelin test aşamasında ulaştığı performans metriklerinin değerleri verilmiştir.

Tablo 4.7. EfficientNet-B1’in Performans Değerleri

Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Skoru	MCC
0.9900	0.9900	0.9900	0.9900	0.9900	0.9800


EfficientNet-B1 modelinin tahminlerinde göğüs BT görüntüsü üzerinde hangi alanlara odaklandığını gösteren Grad-CAM çıktıları oluşturulmuştur. 240×240px çözünürlüğüne sahip giriş görüntüleri için EfficientNet-B1 modelinin son evrişim katmanında bulunan özellik değerleri sayesinde üretilen ısı haritaları ve Grad-CAM çıktıları Şekil 4.30’da birlikte verilmiştir.



Şekil 4.30. EfficientNet-B1’in Grad-CAM Çıktıları


4.6.3. EfficientNet-B2 Modeli Bulguları

EfficientNet model ailesinde yer alan EfficientNet-B2, EFSCCH-19 veri seti örnekleri kullanılarak ve erken sonlandırma fonksiyonun yardımıyla maksimum 50 tur sayısı sürecektir şekilde eğitilmiştir. EfficientNet-B2 modeli en yüksek doğrulama doğruluk oranına 8. tur sayısında elde ettiği 1.00 değeriyle ulaşmıştır. Her biri 175 adım süren sekiz tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve doğruluk grafikleri Şekil 4.31’de verilmiştir.




Şekil 4.31. EfficientNet-B2'nin Kayıp ve Doğruluk Grafiği

Sadece test aşamasında kullanılması için ayrılan görüntüler EfficientNet-B2 modeline girdi olarak verilmiştir. Modelin bu test görüntüleri için gerçekleştirmiş olduğu tahminler referans alınarak oluşturulan karışıklık matrisi Şekil 4.32’de verilmiştir.




Şekil 4.32. EfficientNet-B2'nin Karışıklık Matrisi

EfficientNet-B2 modeli 400 adet test görüntüsünde yer alan 200 adet COVID-19 pozitif göğüs BT görüntüsünün 199 adetini, 200 adet COVID-19 negatif göğüs BT görüntüsününse 200 adetini doğru bir şekilde sınıflandırmıştır. EfficientNet-B2 modelinin başarılı tahminleri arasından rastgele seçilen örnekler Şekil 4.33’de verilmiştir.



Şekil 4.33. EfficientNet-B2’nin Başarılı Tahmin Örnekleri

EfficientNet-B2 modeli 400 adet test görüntüsü içerisinde yer alan bir adet göğüs BT görüntüsünün sınıfını yanlış tahmin etmiştir. Şekil 4.34’de EfficientNet-B2 modeli tarafından sınıfı yanlış tahmin edilen örnekler verilmiştir.




Şekil 4.34. EfficientNet-B2’nin Başarısız Tahmin Örnekleri

EfficientNet-B2 modelinin, göğüs BT görüntülerini içerdiği bulgulara göre COVID-19 pozitif veya COVID-19 negatif olarak sınıflandırabilme yeteneğini kazanabildiği görülmektedir. Tablo 4.8’de ilgili modelin test aşamasında ulaştığı performans metriklerinin değerleri verilmiştir.

Tablo 4.8. EfficientNet-B2’nin Performans Değerleri

Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Skoru	MCC
0.9975	0.9950	1.00	1.00	0.9975	0.9950


EfficientNet-B2 modelinin tahminlerinde göğüs BT görüntüsü üzerinde hangi alanlara odaklandığını gösteren Grad-CAM çıktıları oluşturulmuştur. 260×260px çözünürlüğüne sahip giriş görüntüleri için EfficientNet-B2 modelinin son evrişim katmanında bulunan özellik değerleri sayesinde üretilen ısı haritaları ve Grad-CAM çıktıları Şekil 4.35’de birlikte verilmiştir.



Şekil 4.35. EfficientNet-B2'nin Grad-CAM Çıktıları


4.6.4. EfficientNet-B3 Modeli Bulguları

EfficientNet model ailesinde yer alan EfficientNet-B3, EFSCCH-19 veri seti örnekleri kullanılarak ve erken sonlandırma fonksiyonun yardımıyla maksimum 50 tur sayısı sürecektir şekilde eğitilmiştir. EfficientNet-B3 modeli en yüksek doğrulama doğruluk oranına 12. tur sayısında elde ettiği 1.00 değeriyle ulaşmıştır. Her biri 175 adım süren 12 tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve doğruluk grafikleri Şekil 4.36’da verilmiştir.




Şekil 4.36. EfficientNet-B3’ün Kayıp ve Doğruluk Grafiği

Sadece test aşamasında kullanılması için ayrılan görüntüler EfficientNet-B3 modeline girdi olarak verilmiştir. Modelin bu test görüntüleri için gerçekleştirmiş olduğu tahminler referans alınarak oluşturulan karışıklık matrisi Şekil 4.37’de verilmiştir.




Şekil 4.37. EfficientNet-B3’ün Karışıklık Matrisi

EfficientNet-B3 modeli 400 adet test görüntüsünde yer alan 200 adet COVID-19 pozitif göğüs BT görüntüsünün 197 adetini, 200 adet COVID-19 negatif göğüs BT görüntüsününse 198 adetini doğru bir şekilde sınıflandırmıştır. EfficientNet-B3 modelinin başarılı tahminleri arasından rastgele seçilen örnekler Şekil 4.38’de verilmiştir.



Şekil 4.38. EfficientNet-B3’ün Başarılı Tahmin Örnekleri

EfficientNet-B3 modeli 400 adet test görüntüsü içerisinde yer alan beş adet göğüs BT görüntüsünün sınıfını yanlış tahmin etmiştir. Şekil 4.39’da EfficientNet-B3 modeli tarafından sınıfı yanlış tahmin edilen örnekler verilmiştir.




Şekil 4.39. EfficientNet-B3’ün Başarısız Tahmin Örnekleri

EfficientNet-B3 modelinin, göğüs BT görüntülerini içerdiği bulgulara göre COVID-19 pozitif veya COVID-19 negatif olarak sınıflandırılabilme yeteneğini kazanabildiği görülmektedir. Tablo 4.9’da ilgili modelin test aşamasında ulaştığı performans metriklerinin değerleri verilmiştir.

Tablo 4.9. EfficientNet-B3’ün Performans Değerleri

Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Skoru	MCC
0.9875	0.9850	0.9899	0.9900	0.9875	0.9750


EfficientNet-B3 modelinin tahminlerinde göğüs BT görüntüsü üzerinde hangi alanlara odaklandığını gösteren Grad-CAM çıktıları oluşturulmuştur. 300×300px çözünürlüğüne sahip giriş görüntüleri için EfficientNet-B3 modelinin son evrişim katmanında bulunan özellik değerleri sayesinde üretilen ısı haritaları ve Grad-CAM çıktıları Şekil 4.40’da birlikte verilmiştir.



Şekil 4.40. EfficientNet-B3’ün Grad-CAM Çıktıları


4.6.5. EfficientNet-B4 Modeli Bulguları

EfficientNet model ailesinde yer alan EfficientNet-B4, EFSCCH-19 veri seti örnekleri kullanılarak ve erken sonlandırma fonksiyonun yardımıyla maksimum 50 tur sayısı sürecektir şekilde eğitilmiştir. EfficientNet-B4 modeli en yüksek doğrulama doğruluk oranına 10. tur sayısında elde ettiği 0.9975 değeriyle ulaşmıştır. Her biri 175 adım süren 10 tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve doğruluk grafikleri Şekil 4.41’de verilmiştir.




Şekil 4.41. EfficientNet-B4’ün Kayıp ve Doğruluk Grafiği

Sadece test aşamasında kullanılması için ayrılan görüntüler EfficientNet-B4 modeline girdi olarak verilmiştir. Modelin bu test görüntüleri için gerçekleştirmiş olduğu tahminler referans alınarak oluşturulan karışıklık matrisi Şekil 4.42’de verilmiştir.




Şekil 4.42. EfficientNet-B4’ün Karışıklık Matrisi

EfficientNet-B4 modeli 400 adet test görüntüsünde yer alan 200 adet COVID-19 pozitif göğüs BT görüntüsünün 195 adetini, 200 adet COVID-19 negatif göğüs BT görüntüsününse 200 adetini doğru bir şekilde sınıflandırmıştır. EfficientNet-B4 modelinin başarılı tahminleri arasından rastgele seçilen örnekler Şekil 4.43’de verilmiştir.



Şekil 4.43. EfficientNet-B4’ün Başarılı Tahmin Örnekleri

EfficientNet-B4 modeli 400 adet test görüntüsü içerisinde yer alan beş adet göğüs BT görüntüsünün sınıfını yanlış tahmin etmiştir. Şekil 4.44’de EfficientNet-B4 modeli tarafından sınıfı yanlış tahmin edilen örnekler verilmiştir.




Şekil 4.44. EfficientNet-B4’ün Başarısız Tahmin Örnekleri

EfficientNet-B4 modelinin, göğüs BT görüntülerini içerdiği bulgulara göre COVID-19 pozitif veya COVID-19 negatif olarak sınıflandırabilme yeteneğini kazanabildiği görülmektedir. Tablo 4.10’da ilgili modelin test aşamasında ulaştığı performans metriklerinin değerleri verilmiştir.

Tablo 4.10. EfficientNet-B4’ün Performans Değerleri

Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Skoru	MCC
0.9875	0.9750	1.00	1.00	0.9873	0.9753


EfficientNet-B4 modelinin tahminlerinde göğüs BT görüntüsü üzerinde hangi alanlara odaklandığını gösteren Grad-CAM çıktıları oluşturulmuştur. 380×380px çözünürlüğüne sahip giriş görüntüleri için EfficientNet-B4 modelinin son evrişim katmanında bulunan özellik değerleri sayesinde üretilen ısı haritaları ve Grad-CAM çıktıları Şekil 4.45’de birlikte verilmiştir.



Şekil 4.45. EfficientNet-B4’ün Grad-CAM Çıktıları


4.6.6. EfficientNet-B5 Modeli Bulguları

EfficientNet model ailesinde yer alan EfficientNet-B5, EFSCCH-19 veri seti örnekleri kullanılarak ve erken sonlandırma fonksiyonun yardımıyla maksimum 50 tur sayısı sürecektir şekilde eğitilmiştir. EfficientNet-B5 modeli en yüksek doğrulama doğruluk oranına 10. tur sayısında elde ettiği 0.9975 değeriyle ulaşmıştır. Her biri 175 adım süren 10 tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve doğruluk grafikleri Şekil 4.46’da verilmiştir.




Şekil 4.46. EfficientNet-B5’in Kayıp ve Doğruluk Grafiği

Sadece test aşamasında kullanılması için ayrılan görüntüler EfficientNet-B5 modeline girdi olarak verilmiştir. Modelin bu test görüntüleri için gerçekleştirmiş olduğu tahminler referans alınarak oluşturulan karışıklık matrisi Şekil 4.47’de verilmiştir.




Şekil 4.47. EfficientNet-B5’in Karışıklık Matrisi

EfficientNet-B5 modeli 400 adet test görüntüsünde yer alan 200 adet COVID-19 pozitif göğüs BT görüntüsünün 198 adetini, 200 adet COVID-19 negatif göğüs BT görüntüsününse 199 adetini doğru bir şekilde sınıflandırmıştır. EfficientNet-B5 modelinin başarılı tahminleri arasından rastgele seçilen örnekler Şekil 4.48’de verilmiştir.



Şekil 4.48. EfficientNet-B5’in Başarılı Tahmin Örnekleri

EfficientNet-B5 modeli 400 adet test görüntüsü içerisinde yer alan üç adet göğüs BT görüntüsünün sınıfını yanlış tahmin etmiştir. Şekil 4.49’da EfficientNet-B5 modeli tarafından sınıfı yanlış tahmin edilen örnekler verilmiştir.




Şekil 4.49. EfficientNet-B5’in Başarısız Tahmin Örnekleri

EfficientNet-B5 modelinin, göğüs BT görüntülerini içerdiği bulgulara göre COVID-19 pozitif veya COVID-19 negatif olarak sınıflandırılma yeteneğini kazanabildiği görülmektedir. Tablo 4.11’de ilgili modelin test aşamasında ulaştığı performans metriklerinin değerleri verilmiştir.

Tablo 4.11. EfficientNet-B5’in Performans Değerleri

Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Skoru	MCC
0.9925	0.9900	0.9950	0.9950	0.9925	0.9850


EfficientNet-B5 modelinin tahminlerinde göğüs BT görüntüsü üzerinde hangi alanlara odaklandığını gösteren Grad-CAM çıktıları oluşturulmuştur. 456×456px çözünürlüğüne sahip giriş görüntüleri için EfficientNet-B5 modelinin son evrişim katmanında bulunan özellik değerleri sayesinde üretilen ısı haritaları ve Grad-CAM çıktıları Şekil 4.50’de birlikte verilmiştir.



Şekil 4.50. EfficientNet-B5’in Grad-CAM Çıktıları


4.6.7. EfficientNet-B6 Modeli Bulguları

EfficientNet model ailesinde yer alan EfficientNet-B6, EFSCCH-19 veri seti örnekleri kullanılarak ve erken sonlandırma fonksiyonun yardımıyla maksimum 50 tur sayısı sürecektir şekilde eğitilmiştir. EfficientNet-B6 modeli en yüksek doğrulama doğruluk oranına 7. tur sayısında elde ettiği 0.9950 değeriyle ulaşmıştır. Her biri 175 adım süren yedi tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve doğruluk grafikleri Şekil 4.51’de verilmiştir.




Şekil 4.51. EfficientNet-B6'nın Kayıp ve Doğruluk Grafiği

Sadece test aşamasında kullanılması için ayrılan görüntüler EfficientNet-B6 modeline girdi olarak verilmiştir. Modelin bu test görüntüleri için gerçekleştirmiş olduğu tahminler referans alınarak oluşturulan karışıklık matrisi Şekil 4.52’de verilmiştir.




Şekil 4.52. EfficientNet-B6'nın Karışıklık Matrisi

EfficientNet-B6 modeli 400 adet test görüntüsünde yer alan 200 adet COVID-19 pozitif göğüs BT görüntüsünün 197 adetini, 200 adet COVID-19 negatif göğüs BT görüntüsününse 199 adetini doğru bir şekilde sınıflandırmıştır. EfficientNet-B6 modelinin başarılı tahminleri arasından rastgele seçilen örnekler Şekil 4.53’de verilmiştir.



Şekil 4.53. EfficientNet-B6’nın Başarılı Tahmin Örnekleri

EfficientNet-B6 modeli 400 adet test görüntüsü içerisinde yer alan dört adet göğüs BT görüntüsünün sınıfını yanlış tahmin etmiştir. Şekil 4.54’de EfficientNet-B6 modeli tarafından sınıfı yanlış tahmin edilen örnekler verilmiştir.




Şekil 4.54. EfficientNet-B6’nın Başarısız Tahmin Örnekleri

EfficientNet-B6 modelinin, göğüs BT görüntülerini içerdiği bulgulara göre COVID-19 pozitif veya COVID-19 negatif olarak sınıflandırabilme yeteneğini kazanabildiği görülmektedir. Tablo 4.12’de ilgili modelin test aşamasında ulaştığı performans metriklerinin değerleri verilmiştir.

Tablo 4.12. EfficientNet-B6’nın Performans Değerleri

Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Skoru	MCC
0.9900	0.9850	0.9949	0.9950	0.9899	0.9800


EfficientNet-B6 modelinin tahminlerinde göğüs BT görüntüsü üzerinde hangi alanlara odaklandığını gösteren Grad-CAM çıktıları oluşturulmuştur. 528×528px çözünürlüğüne sahip giriş görüntüleri için EfficientNet-B6 modelinin son evrişim katmanında bulunan özellik değerleri sayesinde üretilen ısı haritaları ve Grad-CAM çıktıları Şekil 4.55’de birlikte verilmiştir.



Şekil 4.55. EfficientNet-B6'nın Grad-CAM Çıktıları


4.6.8. EfficientNet-B7 Modeli Bulguları

EfficientNet model ailesinde yer alan EfficientNet-B7, EFSCCH-19 veri seti örnekleri kullanılarak ve erken sonlandırma fonksiyonun yardımıyla maksimum 50 tur sayısı sürecektir şekilde eğitilmiştir. EfficientNet-B7 modeli en yüksek doğrulama doğruluk oranına 9. tur sayısında elde ettiği 1.00 değeriyle ulaşmıştır. Her biri 175 adım süren dokuz tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve doğruluk grafikleri Şekil 4.56’da verilmiştir.




Şekil 4.56. EfficientNet-B7'nin Kayıp ve Doğruluk Grafiği

Sadece test aşamasında kullanılması için ayrılan görüntüler EfficientNet-B7 modeline girdi olarak verilmiştir. Modelin bu test görüntüleri için gerçekleştirmiş olduğu tahminler referans alınarak oluşturulan karışıklık matrisi Şekil 4.57’de verilmiştir.




Şekil 4.57. EfficientNet-B7'nin Karışıklık Matrisi

EfficientNet-B7 modeli 400 adet test görüntüsünde yer alan 200 adet COVID-19 pozitif göğüs BT görüntüsünün 195 adetini, 200 adet COVID-19 negatif göğüs BT görüntüsününse 200 adetini doğru bir şekilde sınıflandırmıştır. EfficientNet-B7 modelinin başarılı tahminleri arasından rastgele seçilen örnekler Şekil 4.58’de verilmiştir.



Şekil 4.58. EfficientNet-B7’nin Başarılı Tahmin Örnekleri

EfficientNet-B7 modeli 400 adet test görüntüsü içerisinde yer alan beş adet göğüs BT görüntüsünün sınıfını yanlış tahmin etmiştir. Şekil 4.59’da EfficientNet-B7 modeli tarafından sınıfı yanlış tahmin edilen örnekler verilmiştir.




Şekil 4.59. EfficientNet-B7’nin Başarısız Tahmin Örnekleri

EfficientNet-B7 modelinin, göğüs BT görüntülerini içerdiği bulgulara göre COVID-19 pozitif veya COVID-19 negatif olarak sınıflandırabilme yeteneğini kazanabildiği görülmektedir. Tablo 4.13’de ilgili modelin test aşamasında ulaştığı performans metriklerinin değerleri verilmiştir.

Tablo 4.13. EfficientNet-B7’nin Performans Değerleri

Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1-Skoru	MCC
0.9875	0.9750	1.00	1.00	0.9873	0.9753


EfficientNet-B7 modelinin tahminlerinde göğüs BT görüntüsü üzerinde hangi alanlara odaklandığını gösteren Grad-CAM çıktıları oluşturulmuştur. 600×600px çözünürlüğüne sahip giriş görüntüleri için EfficientNet-B7 modelinin son evrişim katmanında bulunan özellik değerleri sayesinde üretilen ısı haritaları ve Grad-CAM çıktıları Şekil 4.60’da birlikte verilmiştir.



Şekil 4.60. EfficientNet-B7'nin Grad-CAM Çıktıları

5. ENFEKSİYON VE AKCİĞER ALANLARININ BÖLÜTLENMESİ

Göğüs BT görüntülerinde çok sınıflı anlamsal bölütleme metoduna uygun biçimde derin öğrenme modeli tarafından akciğer ve enfeksiyon alanlarının tespit edilmesi için bölütleyici bir sistem tasarlanmıştır. Bu kapsamda tasarlanan sistemin görsel kurgusu detaylı olarak Şekil 5.1’de verilmiştir.




Şekil 5.1. Tasarlanan Bölütleyici Sistem

Anlamsal bölütleyici derin öğrenme modelinin giriş katmanına verilen görüntü, çıkış katmanında akciğer alanları, enfekte alanlar ve arka plan olmak üzere piksel bazlı sınıflandırılmaktadır. Bu sayede hastalığın ilerleme süreci veya ilk tespiti kolaylıkla gözlemlenebilmektedir. Tüm bu süreçler doğrudan insan hayatını ele aldığı için yüksek başarı oranlarına sahip derin öğrenme modellerine ihtiyaç duyulmaktadır. Anlamsal bölütleyici derin öğrenme modellerinde en önemli parametrelerden biri orijinal görüntüler referans alınarak oluşturulan maske görüntüleridir. Piksel bazlı olarak oluşturulan bu maske görüntülerinde hassaslık ön planda tutulmalıdır. Çünkü anlamsal bölütleyici derin öğrenme modelleri, oluşturulan maske görüntülerini saf doğru olarak kabul etmektedir. Piksel bazlı maske görüntülerini oluşturma süreçleri zaman ve kaynak açısından maliyetli olduğu için halka açık veri seti sayısı sınırlıdır. Bu sebeple anlamsal bölütleyici derin öğrenme modelinin eğitiminde kullanılmak üzere EFSCH-19-Seg adını verdiğimiz veri seti tarafımızca oluşturulmuştur. Bu veri seti literatürdeki çalışmalarda kullanılan halka açık veri setlerinden herhangi bir örnek veya maske görüntüsü içermemektedir.

5.1. EFSCH-19-Seg Veri Seti

EFSCH-19-Seg veri seti, EFSCH-19 veri setinde COVID-19 pozitif etiketiyle yer alan örnekler arasından rastgele seçilen 200 adet göğüs BT görüntüsüyle oluşturulmuştur. Anlamsal bölütleme görevini gerçekleştirecek modelin eğitim aşamasında kullanılacağı için göğüs BT görüntüleri tek başına yeterli değildir. Bu sebeple EFSCH-19-Seg veri setinde her bir göğüs BT görüntüsü için maske görüntülerinin oluşturulması gerekmektedir. Maske görüntülerinin oluşturulmasında gerekli tıbbi bilgiye sahip olmamamız sebebiyle tüm süreç, Elazığ Fethi Sekin Şehir Hastanesi Başhekimliği tarafından verilen çalışma izni yardımıyla hastane bünyesinde aktif olarak çalışan radyoloji uzmanı tarafından yürütülmüştür. Radyoloji uzmanı tarafından ilgili alanların piksel bazlı işaretlenmesi zaman alıcı olsa bile geçerliliği ve yüksek hassasiyeti sebebiyle bu çalışmada tercih edilen yöntem, manuel işaretleme yöntemidir. Şekil 5.2’de maske görüntülerinin oluşturulması için radyoloji uzmanı tarafından uygulanan adımlar sıralı bir şekilde verilmiştir.



Şekil 5.2. Maske Görüntüsü Oluşturma Adımları

ITK-SNAP [75] adlı uygulama sayesinde siyah, yeşil ve kırmızı olmak üzere üç farklı renkle belirtilen üç farklı sınıf tanımlanmıştır. Bu sınıflar akciğerler, enfeksiyonlar ve arka plan alanlarını temsil etmektedir. Şekil 5.3’de radyoloji uzmanı tarafından oluşturulmuş maske görüntüsü ve her bir sınıf için kullanılan renklendirme yapısı verilmiştir.



Şekil 5.3. Maske Görüntülerinde Kullanılan Renklendirme Yapısı


Her bir orijinal görüntü için anlamsal bölütleyici derin öğrenme modelinin eğitiminde kullanılacak maske görüntüleri oluşturulmuştur. Bu maske görüntüleri Taşınabilir Ağ Grafiği

(PNG) veri formatına ve 768×768px çözünürlüğe sahiptir. EFSCCH-19-Seg veri setinin detayları Tablo 5.1’de yer almaktadır.

Tablo 5.1. EFSCCH-19-Seg Veri Seti Detayları

Görüntü Tipi	Veri Formatı	Adet	Çözünürlük	Renk Derinliği
Orijinal Görüntü	JPG	200	768×768px	24 bit
Maske Görüntüsü	PNG	200	768×768px	24 bit

Anlamsal bölütleyici modeller eğitim aşamasında maske görüntülerini saf doğru olarak kabul ettiği için işaretleme süreci büyük bir doğrulukla yürütülmelidir. Ek olarak; bir BT görüntüsündeki anlamlı bilgileri içeren piksel sayısının, toplam piksel sayısına oranı göz önüne alındığında dengesiz dağılımın oluşması kaçınılmazdır. Tüm bu özelliklerinden dolayı yüksek çözünürlüklü görüntüler için maske görüntüleri oluşturmak oldukça zorlu bir görevdir. EFSCCH-19-Seg veri seti içerisinde rastgele seçilen görüntüler ve maskeleri Şekil 5.4’de verilmiştir.



Şekil 5.4. EFSCCH-19-Seg Veri Seti Örneği


Maske görüntüsü oluşturma süreci sonrasında EFSCCH-19-Seg veri seti anlamsal bölütleme çalışmalarında kullanılabilir hale getirilmiştir. Oluşturulan maske görüntülerinde yer alan sınıf etiketleri, piksel değerleri ve toplam piksel sayısı içerisindeki dağılımları Tablo 5.2’de verilmiştir.

Tablo 5.2. EFSCCH-19-Seg Sınıflarının Değerleri ve Dağılımları

Piksel Sınıf Etiketi	Piksel Değeri (RGB)	Piksel Dağılımı (%)
Enfeksiyon	(255,0,0)	1.46
Akciğer	(0,255,0)	14.17
Arka Plan	(0,0,0)	84.37

5.2. Anlamsal Bölütleyici Derin Öğrenme Mimarisi

Anlamsal bölütleyici derin mimarisi olarak U-Net [76] mimarisi tercih edilmiştir. U-Net, görüntü bölütleme görevini yerine getirmek için bir dizi evrişimli katman ve evrişimsiz katman içeren bir tür YSA'dır. Günümüzde herhangi bir anlamsal bölütleme görevinde popüler olarak kullanılan yaklaşımlar arasında yer almaktadır. U-Net, adını Şekil 5.5'de görüldüğü gibi 'U' harfine benzer yapısından almaktadır.



Şekil 5.5. U-Net Mimarisi

U-Net, köprü aracılığıyla bağlanan dört kodlayıcı bloğu ve dört kod çözücü bloğundan oluşan bir kodlayıcı-kod çözücü ağ mimarisidir.

5.2.1. Kodlayıcı Ağı

Kodlayıcı ağı, özellik çıkarıcı görevi görür ve kodlayıcı bloklarının bir dizisi aracılığıyla giriş görüntüsünün soyut bir temsili öğrenir. Her kodlayıcı bloğu, her bir evrişimin bir ReLU aktivasyon fonksiyonu tarafından takip edildiği iki adet 3x3 evrişimden oluşur. ReLU etkinleştirme işlevi, eğitim verilerinin daha iyi genelleştirilmesine yardımcı olan ağa doğrusal olmama özelliği getirir. ReLU'nun çıkışı, karşılık gelen kod çözücü bloğu için bir atlama bağlantısı görevi görür. Ardından, özellik haritalarının yükseklik ve genişliklerinin yarı yarıya azaltıldığı 2x2 maksimum havuzlama gelir. Bu işlem, eğitilebilir parametre sayısını azaltarak hesaplama maliyetini azaltır.

5.2.2. Kod Çözücü Ağı

Kod çözücü ağı, soyut temsili almak ve anlamsal bir bölütleme maskesi oluşturmak için kullanılır. Kod çözücü bloğu 2x2 devrik evrişim ile başlar. Ardından, kodlayıcı bloğundan ilgili

atlamalı bağlantı özellik haritasıyla birleştirilir. Bu atlama bağlantıları, bazen ağın derinliği nedeniyle kaybolan önceki katmanlardan özellikler sağlar. Bundan sonra, her bir evrişimin bir ReLU aktivasyon fonksiyonu tarafından takip edildiği iki adet 3×3 evrişim kullanılır. Son kod çözücünün çıkışında softmax aktivasyon fonksiyonu kullanılmaktadır. Ancak ikili anlamsal bölütleme çalışmalarında sigmoid aktivasyon fonksiyonunun kullanıldığı örnek çalışmalar da bulunmaktadır.


5.3. Anlamsal Bölütleyici Derin Öğrenme Model Eğitimi

U-Net mimarisinde kodlayıcı ağında varsayılan katmanlar yerine ESA tabanlı modeller entegre edilebilmektedir. Bu sayede özellik haritalarının çıkarılmasında daha iyi sonuçlar üretilmektedir. Anlamsal bölütleyici derin öğrenme modelimiz olan U-Net'in kodlayıcı ağıları ResNet-18, ResNet-34, ResNet50, ResNet-101 ve ResNet-152 modelleriyle değiştirilerek beş farklı eğitim süreci oluşturulmuştur. 256×256 px giriş boyutuna sahip modeller 'Segmentation Models' kütüphanesi sayesinde eğitime dahil edilmiştir. U-Net modellerinin çıkışında piksel bazlı üç farklı sınıfı tahmin edilebilecek yapı kurgulanmıştır. Aktivasyon fonksiyonu olarak softmax aktivasyon fonksiyonu tercih edilmiştir. Tensorflow kütüphanesi yardımıyla Adam optimizasyonu 0.0001 öğrenme oranıyla tanımlanmıştır. Dice kaybı ve 16 parti boyutu parametreleriyle U-Net modelleri maksimum 200 tur sayısı boyunca eğitilmiştir. Bu süreçlerin tamamı Google Colab ortamında gerçekleştirilmiştir. Eğitim esnasında takip edilen değer Jaccard indeksi skorudur. Jaccard indeksi skoru art arda 25 tur sayısı boyunca en yüksek değeri aşmadığında erken durdurma fonksiyonu devreye girerek en yüksek değere sahip adımı '.hdf5' formatında kaydetmesi sağlanmıştır. Bu sayede en başarılı bölütleme yeteneğine sahip adıma ulaşmak hedeflenmiştir.

5.3.1. Önerilen Eğitim Kurgusu

EFSCCH-19-Seg veri setinde yer alan göğüs BT örnekleri ve maske görüntüleri çözünürlüklerinden ve veri tiplerinden dolayı doğrudan U-Net modellerinin eğitiminde kullanılamaz. U-Net mimarisinin varsayılan giriş boyutu 256×256 px'dir. Ancak EFSCCH-19-Seg veri seti örnekleri 768×768 px çözünürlüğüne sahiptir. Bu sebeple EFSCCH-19-Seg veri seti örneklerine çeşitli ön işlem adımları uygulanmalıdır. Ön işlem adımları uygulanarak yeniden düzenlenen örnekler sayesinde anlamsal bölütleme görevini yerine getirecek U-Net modellerinin eğitim süreci başlatılmalıdır. Eğitim süreçleri, beş farklı kodlayıcı ağına sahip modeller için eşit koşullar ve parametreler kullanılarak gerçekleştirilmelidir. Çünkü anlamsal bölütleyici derin öğrenme modeli olarak seçilecek modelin en başarılı sonuçlara sahip model olması beklenmektedir. En başarılı modelin belirlenmesinde de eğitim aşaması tamamlandıktan sonra çeşitli performans


metriklerinin incelenmesi gerekmektedir. Anlamsal bölütleyici derin öğrenme modelinin eğitiminde kullanılan yöntem Şekil 5.6’da verilmiştir.



Şekil 5.6. Önerilen Bölütleyici Model Eğitim Kurgusu

5.4. Ön İşlem Adımları

Radyoloji uzmanı tarafından hazırlanan maske görüntüleri Kırmızı-Yeşil-Mavi (RGB) renk moduna sahiptir. Her bir piksel değeri 24 bit değer kaplayan maske görüntülerini model eğitimi aşamasında kullanmak kaynakların verimsiz kullanılmasına sebep olacaktır. Bu sebeple maske görüntüleri, RGB renk modundan 8 bit tek kanallı veri formatına dönüştürülmüştür. Maske görüntülerinin tamamı 8 bit tek kanallı veri formatına dönüştürüldükten sonra piksel bazlı değer değiştirme işlemi gerçekleştirilmiştir. Arka plan alanlarının yer aldığı piksellere '0', akciğer alanlarının yer aldığı piksellere '1' ve enfeksiyon alanlarının yer aldığı piksellere '2' değeri atanmıştır. Bu sayede üç farklı sınıflı temsil eden pikseller, hafızayı minimum yer kaplayacak düzeye getirilmiştir. İlgili dönüştürme ve değer değiştirme işlemi sonucu Şekil 5.7'de verilmiştir.




Şekil 5.7. Renk Modu ve Piksel Bazlı Değer Değiştirme İşlemi

RGB renk modundaki maske görüntülerini 8 bit tek kanallı veri formatına dönüştürmek kaynakları verimli kullanabilmek için tek başına yeterli değildir. EFSCH-19-Seg veri setinde yer alan görüntüler ve maskeleri 768×768 px boyutundadır. Bu kadar büyük çözünürlükteki görselleri doğrudan modele girdi olarak vermek donanımsal özelliklerimiz göz önüne alındığında mantıklı bir yaklaşım değildir. Anlamsal bölütleyici derin öğrenme modelinin varsayılan giriş boyutu 256×256 px olduğu için eğitim aşamasında kullanılacak görüntülerin çözünürlüğü de bu değere eşit olmalıdır. Bu sebeple veri seti örnekleri üzerinde, yeniden boyutlandırma veya parçalara ayırma olmak üzere iki farklı yöntem uygulanabilir. İlk alternatif olan yeniden boyutlandırma işlemi belirtilen soruna çözüm üretebilir ancak bölütleme çalışmalarında büyük miktarda bilgi kaybına sebep olacağından dolayı önerilmemektedir. Bu çalışmada bilgi kaybının yaşanmaması için görüntüler 256×256 px boyutunda parçalara ayrılmıştır. Parçalara ayırma işleminde kullanılan algoritmanın adımları aşağıdaki gibidir.

1. Parçalara ayrılacak orijinal görüntü ve maske görüntüsü belirlenmelidir.
2. 768×768 px çözünürlüğünde olan bu görüntülerin ilk pikseli başlangıç noktası olarak seçilmelidir.

3. Başlangıç noktasından başlanarak 256px x ekseninde ve 256px y ekseninde karşılıklı kenarlarla kare biçiminde kırılmalıdır.
4. Başlangıç noktası 256px kaydırılarak 3. adımda gerçekleştirilen işlem görüntülerin çözünürlük değerini kapsayacak duruma gelene kadar tekrarlanmalıdır.


Detayları belirtilen algoritma 768×768px çözünürlüğüne sahip bir görüntü için uygulandığında, dokuz adet 256×256px çözünürlüğünde benzersiz görüntü oluşturulabilir. Oluşturulan her bir benzersiz görüntü sıralı olarak numaralandırılmalıdır. Çünkü göğüs BT görüntüsü ve maske görüntüsünün birlikteliğinin korunması gerekmektedir. Aksi halde model eğitilirken eşleşmeyen orijinal görüntü ve maske görüntüleri sebebiyle düşük başarımlar elde edilecektir. Şekil 5.8’de parçalara ayırma algoritmasının görsel kurgusu verilmiştir.



Şekil 5.8. Görüntü Parçalama İşlemi

EFSCH-19-Seg veri setinde yer alan tüm orijinal görüntüler ve maskeleri 256×256px’lik parçalara ayrıldıktan sonra toplamda 1800 adet göğüs BT ve 1800 adet maske görüntüsü elde edilmiştir. 1800 adet orijinal görüntünün ve maske görüntüsünün %70’i eğitim, %20’si doğrulama ve %10’u test aşamalarında kullanılmak üzere bölünmüştür. İlgili veri bölme işleminde göğüs BT

görüntüsünün ve maske görüntüsünün birlikteliği gözetilmiştir. Veri bölme işlemi Şekil 5.9’da gösterilmiştir.



Şekil 5.9. Veri Bölme İşlemi

EFSCCH-19-Seg veri seti örneklerinin veri bölme işlemi sonrasındaki sayısal dağılımları hakkında detaylı bilgi Tablo 5.3’de verilmiştir. Bu sayısal bilgiler eğitilen modelin kodlayıcı ağında kullanılan ResNet modelinden bağımsız olup beş model için de geçerlidir.

Tablo 5.3. EFSCCH-19-Seg’in Veri Bölme Sonrası Sayısal Dağılımı

Aşama	Orijinal Görüntü Sayısı	Maske Görüntüsü Sayısı
Eğitim	1260	1260
Doğrulama	360	360
Test	180	180

5.5. Değerlendirme Metrikleri

Yapay zeka çalışmalarında tahminler genel olarak dört kategoride değerlendirilmektedir. Bu kategoriler DP, YP, DN ve YN’dir. Sınıflandırma çalışmalarında oldukça etkin kullanılan kategoriler anlamsal bölütleme çalışmalarında da kullanılmaktadır. Anlamsal bölütleme çalışmalarında en önemli başarı kriteri, model tarafından tahmin edilen maske görüntüsü ile gerçek maskesinin karşılaştırılmasıyla ortaya çıkan benzerlik oranıdır. Model tahmin başarısını hesaplamak için kullanılan yöntemler piksel tabanlı karşılaştırmaya dayanmaktadır. Bu yöntemler, piksel doğruluğu, Jaccard indeksi ve DS gibi metrikleri içermektedir.


5.5.1. Piksel Doğruluğu

Piksel Doğruluğu (PD), model tarafından tahmin edilen maske görüntüsü ile gerçek maskenin karşılaştırılması sonucunda örtüşen ve doğru tahmin edilen piksel sayısının toplam piksel

sayısına bölünmesiyle hesaplanmaktadır. PD değeri (5.1)'de verilen matematiksel denklem ile hesaplanmaktadır.

$$PD = \frac{DP+DN}{DP+DN+YP+YN} \quad (5.1)$$

Rastgele seçilen test görüntüsü için piksel doğruluğu bileşenleri ve anlamsal bölütleyici derin öğrenme modeli tarafından tahmin edilen maske görüntüsü Şekil 5.10'da verilmiştir.



Şekil 5.10. PD Değeri Bileşenleri

PD, kolay hesaplanması ve karmaşıklığı nedeniyle kullanışlı görünmekte ancak yanıltıcı sonuçlar üretebilir. Örneğin 768×768px boyutundaki bir görüntüde anlamlı bilgi içeren piksellerin oranı sadece %10'luk bir paya sahip olduğu varsayıldığında, sınıf dağılımının son derece düzensiz olduğu bir durum oluşmaktadır. Bu tür durumlar için anlamsal bölütleyici derin öğrenme modeli herhangi bir sınıf ayrımı dahi yapamadan sadece tüm değerleri sıfır olan bir görüntüyü çıktı olarak verse bile PD değeri %90 olacaktır. Bu nedenle, dengesiz sınıf dağılımına sahip görüntüler yerine dengeli dağılıma sahip görüntüler için PD değerlendirmesi kullanılmalıdır. Belirtilen tüm bu özelliklerinden dolayı PD metriği, anlamsal bölütleme çalışmalarında modelin performansını belirlemek için tek başına kullanılmamaktadır. PD'nin olumsuzluklarından etkilenmemek için jaccard indeksi ve DS gibi metrikler tercih edilmektedir.


5.5.2. Jaccard İndeksi ve Dice Skoru

Verilen iki görüntü arasındaki benzerliği gösteren jaccard indeksi, Birleşim Üzerinden Kesişme (IoU) olarak da adlandırılır. Gerçek maske görüntüsü ile tahmin edilen maske görüntüsü

arasındaki örtüşme yüzdesini ölçmek için bir yöntemdir. Bu metrik, model eğitim esnasında genellikle bir referans değeri olarak izlenmektedir. IoU değeri (5.2)'de verilen matematiksel denklem ile hesaplanmaktadır.

$$IoU = \frac{\text{Maske Görüntüsü} \cap \text{Tahmin Maskesi}}{\text{Maske Görüntüsü} \cup \text{Tahmin Maskesi}} \quad (5.2)$$

IoU, PD'ye göre daha güvenilir sonuçlar vermektedir. Bu nedenle anlamsal bölütleme çalışmalarında dikkate alınan en önemli performans ölçütleri arasında yer almaktadır. IoU değerinin hesaplanması için maske görüntüsüyle tahmin maskesinin karşılaştırılması sonucunda elde edilmiş kesişim ve birleşim bileşenleri Şekil 5.11'de verilmiştir.



Şekil 5.11. IoU ve DS Değeri Bileşenleri

Dice Skoru (DS), IoU'ya çok benzer ve pozitif olarak ilişkili bir performans metriğidir. (5.3)'de verilen matematiksel denklemle DS hesaplanmaktadır.


$$DS = \frac{2 * |\text{Maske Görüntüsü} \cap \text{Tahmin Maskesi}|}{|\text{Maske Görüntüsü}| + |\text{Tahmin Maskesi}|} \quad (5.3)$$

Örnek olarak 'A' modeli IoU performans metriğine göre 'B' modelinden daha iyiye aynı şekilde DS performans metriği referans alındığında da sonuç değişmeyecektir. Genel olarak iki metriğin işlevsel olarak eşdeğer olduğu, dolayısıyla aralarındaki seçimin keyfi olduğu düşünülse de bir dizi çıkarım üzerinden ortalama puanı alırken IoU metriği DS'e göre daha fazla cezalandırma eğilimindedir. Dolayısıyla, DS ortalama performansa daha yakın bir ölçüme yatkınken, IoU puanı en kötü durum performansına daha yakın bir ölçüm yapmaktadır. DS bu özelliğinden dolayı model eğitiminde kayıp parametresi olarak etkin bir biçimde kullanılmaktadır.

5.6. Test Aşamasında Elde Edilen Bulgular


5.6.1. ResNet-18 Tabanlı U-Net Modeli Bulguları

U-Net modelinin kodlayıcı ağında klasik yapı yerine ResNet-18 mimarisinin entegre edilmesiyle oluşturulan anlamsal bölütleyici derin öğrenme modeli, erken sonlandırma fonksiyonun da yardımıyla maksimum 200 tur sayısı süreçte eğitilmiştir. ResNet-18 tabanlı U-Net modeli en yüksek doğrulama IoU değerine 134. tur sayısında elde ettiği 0.9054 değeriyle ulaşmıştır. Her biri ortalama 78 adım süren 134 tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve IoU grafikleri Şekil 5.12’de verilmiştir.




Şekil 5.12. ResNet-18 Tabanlı U-Net’in Kayıp ve Doğruluk Grafiği

Model eğitime başlanmadan önce %10’luk bir payla ayrılan ve sadece test aşamasında kullanılması planlanan görüntüler ResNet-18 tabanlı U-Net modeline girdi olarak verilmiştir. İlgili girdilere karşı tahmin edilen örnek maske görüntüleri Şekil 5.13’de verilmiştir.



Şekil 5.13. ResNet-18 Tabanlı U-Net Tahminleri

ResNet-18 tabanlı U-Net modelinin Şekil 5.13’de belirtilen tahminleriyle, EFSCH-19-Seg veri setinde ilgili orijinal görüntü için hazırlanmış maske görüntülerinin kıyaslanmasında ortaya çıkan YP ve YN bulguları Şekil 5.14’de verilmiştir.




Şekil 5.14. ResNet-18 Tabanlı U-Net Tahminlerinde Oluşan YP ve YN Bulgular

ResNet-18 tabanlı U-Net modelinin Şekil 5.13’de belirtilen sıra numarasına sahip görüntüler için üretmiş olduğu maske görüntülerinin, EFSCH-19-Seg veri setinde yer alan gerçek maske görüntüleriyle karşılaştırılması sonucunda elde edilen performans metrik bileşenlerinin sayısal değerleri ve bu değerler kullanılarak hesaplanan PD değeri Tablo 5.4’de verilmiştir.

Tablo 5.4. ResNet-18 Tabanlı U-Net Tahminlerinde PD Bileşenleri

Sıra Numarası	YP Piksel Sayısı	YN Piksel Sayısı	DP Piksel Sayısı	DN Piksel Sayısı	PD Değeri
1	1574	1579	21833	40550	0.9518
2	225	241	23548	41522	0.9928
3	471	510	19208	45347	0.9850
4	122	88	9070	56256	0.9967
5	2636	2614	15171	45115	0.9198
6	1182	134	37156	27064	0.9799

ResNet-18 tabanlı U-Net modelinin Şekil 5.13’de belirtilen tahminleriyle, EFSCH-19-Seg veri setinde ilgili orijinal görüntü için hazırlanmış maske görüntülerinin kıyaslanmasında ortaya çıkan kesişen piksellerin ve piksellerin birleşimleri sonucunda oluşturulan görüntüler Şekil 5.15’de verilmiştir.



Şekil 5.15. ResNet-18 Tabanlı U-Net Tahminlerinde Oluşan Kesişimler ve Birleşimler


ResNet-18 tabanlı U-Net modelinin Şekil 5.15’de belirtilen kesişim ve birleşim alanlarının ilgili görsel içerisinde kapladığı piksel sayıları ve bu değerler kullanılarak hesaplanan IoU ve DS değerleri Tablo 5.5’de verilmiştir.

Tablo 5.5. ResNet-18 Tabanlı U-Net Tahminlerinde IoU ve DS Bileşenleri

Sıra Numarası	Kesişim Piksel Sayısı	Birleşim Piksel Sayısı	IoU Değeri	DS Değeri
1	21833	24986	0.8738	0.9326
2	23548	24014	0.9805	0.9902
3	19208	20189	0.9514	0.9751
4	9070	9280	0.9773	0.9885
5	15171	20421	0.7429	0.8524
6	37156	38472	0.9657	0.9826


5.6.2. ResNet-34 Tabanlı U-Net Modeli Bulguları

U-Net modelinin kodlayıcı ağında klasik yapı yerine ResNet-34 mimarisinin entegre edilmesiyle oluşturulan anlamsal bölütleyici derin öğrenme modeli, erken sonlandırma fonksiyonun da yardımıyla maksimum 200 tur sayısı sürecektir şekilde eğitilmiştir. ResNet-34 tabanlı U-Net modeli en yüksek doğrulama IoU değerine 170. tur sayısında elde ettiği 0.9069 değeriyle ulaşmıştır. Her biri ortalama 78 adım süren 170 tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve IoU grafikleri Şekil 5.16’da verilmiştir.




Şekil 5.16. ResNet-34 Tabanlı U-Net’in Kayıp ve Doğruluk Grafikleri

Model eğitime başlanmadan önce %10’luk bir payla ayrılan ve sadece test aşamasında kullanılması planlanan görüntüler ResNet-34 tabanlı U-Net modeline girdi olarak verilmiştir. İlgili girdilere karşı tahmin edilen örnek maske görüntüleri Şekil 5.17’de verilmiştir.



Şekil 5.17. ResNet-34 Tabanlı U-Net Tahminleri

ResNet-34 tabanlı U-Net modelinin Şekil 5.17’de belirtilen tahminleriyle, EFSCH-19-Seg veri setinde ilgili orijinal görüntü için hazırlanmış maske görüntülerinin kıyaslanmasında ortaya çıkan YP ve YN bulguları Şekil 5.18’de verilmiştir.




Şekil 5.18. ResNet-34 Tabanlı U-Net Tahminlerinde Oluşan YP ve YN Bulgular

ResNet-34 tabanlı U-Net modelinin Şekil 5.17’de belirtilen sıra numarasına sahip görüntüler için üretmiş olduğu maske görüntülerinin, EFSCH-19-Seg veri setinde yer alan gerçek maske görüntüleriyle karşılaştırılması sonucunda elde edilen performans metrik bileşenlerinin sayısal değerleri ve bu değerler kullanılarak hesaplanan PD değeri Tablo 5.6’da verilmiştir.

Tablo 5.6. ResNet-34 Tabanlı U-Net Tahminlerinde PD Bileşenleri

Sıra Numarası	YP Piksel Sayısı	YN Piksel Sayısı	DP Piksel Sayısı	DN Piksel Sayısı	PD Değeri
1	1440	1442	22032	40622	0.9560
2	214	184	23643	41495	0.9939
3	472	427	19292	45345	0.9554
4	73	73	9088	56302	0.9977
5	2313	2308	15455	45460	0.9294
6	277	191	36940	28128	0.9928

ResNet-34 tabanlı U-Net modelinin Şekil 5.17’de belirtilen tahminleriyle, EFSCH-19-Seg veri setinde ilgili orijinal görüntü için hazırlanmış maske görüntülerinin kıyaslanmasında ortaya çıkan kesişen piksellerin ve piksellerin birleşimleri sonucunda oluşturulan görüntüler Şekil 5.19’da verilmiştir.



Şekil 5.19. ResNet-34 Tabanlı U-Net Tahminlerinde Oluşan Kesişimler ve Birleşimler


ResNet-34 tabanlı U-Net modelinin Şekil 5.19’da belirtilen kesişim ve birleşim alanlarının ilgili görsel içerisinde kapladığı piksel sayıları ve bu değerler kullanılarak hesaplanan IoU ve DS değerleri Tablo 5.7’de verilmiştir.

Tablo 5.7. ResNet-34 Tabanlı U-Net Tahminlerinde IoU ve DS Bileşenleri

Sıra Numarası	Kesişim Piksel Sayısı	Birleşim Piksel Sayısı	IoU Değeri	DS Değeri
1	22032	24914	0.8843	0.9386
2	23643	24041	0.9834	0.9916
3	19292	20191	0.9554	0.9772
4	9088	9234	0.9841	0.9920
5	15455	20076	0.7698	0.8699
6	36940	37408	0.9874	0.9937


5.6.3. ResNet-50 Tabanlı U-Net Modeli Bulguları

U-Net modelinin kodlayıcı ağında klasik yapı yerine ResNet-50 mimarisinin entegre edilmesiyle oluşturulan anlamsal bölütleyici derin öğrenme modeli, erken sonlandırma fonksiyonun da yardımıyla maksimum 200 tur sayısı sürecektir şekilde eğitilmiştir. ResNet-50 tabanlı U-Net modeli en yüksek doğrulama IoU değerine 144. tur sayısında elde ettiği 0.9078 değeriyle ulaşmıştır. Her biri ortalama 78 adım süren 144 tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve IoU grafikleri Şekil 5.20’de verilmiştir.




Şekil 5.20. ResNet-50 Tabanlı U-Net’in Kayıp ve Doğruluk Grafikleri

Model eğitime başlanmadan önce %10’luk bir payla ayrılan ve sadece test aşamasında kullanılması planlanan görüntüler ResNet-50 tabanlı U-Net modeline girdi olarak verilmiştir. İlgili girdilere karşı tahmin edilen örnek maske görüntüleri Şekil 5.21’de verilmiştir.



Şekil 5.21. ResNet-50 Tabanlı U-Net Tahminleri

ResNet-50 tabanlı U-Net modelinin Şekil 5.21’de belirtilen tahminleriyle, EFSCH-19-Seg veri setinde ilgili orijinal görüntü için hazırlanmış maske görüntülerinin kıyaslanmasında ortaya çıkan YP ve YN bulguları Şekil 5.22’de verilmiştir.




Şekil 5.22. ResNet-50 Tabanlı U-Net Tahminlerinde Oluşan YP ve YN Bulgular

ResNet-50 tabanlı U-Net modelinin Şekil 5.21’de belirtilen sıra numarasına sahip görüntüler için üretmiş olduğu maske görüntülerinin, EFSCH-19-Seg veri setinde yer alan gerçek maske görüntüleriyle karşılaştırılması sonucunda elde edilen performans metrik bileşenlerinin sayısal değerleri ve bu değerler kullanılarak hesaplanan PD değeri Tablo 5.8’de verilmiştir.

Tablo 5.8. ResNet-50 Tabanlı U-Net Tahminlerinde PD Bileşenleri

Sıra Numarası	YP Piksel Sayısı	YN Piksel Sayısı	DP Piksel Sayısı	DN Piksel Sayısı	PD Değeri
1	1106	1114	22336	40980	0.9661
2	152	154	23642	41588	0.9953
3	278	240	19468	45550	0.9920
4	57	60	9120	56299	0.9982
5	2222	2201	15568	45545	0.9325
6	218	186	37146	27986	0.9938

ResNet-50 tabanlı U-Net modelinin Şekil 5.21’de belirtilen tahminleriyle, EFSCH-19-Seg veri setinde ilgili orijinal görüntü için hazırlanmış maske görüntülerinin kıyaslanmasında ortaya çıkan kesişen piksellerin ve piksellerin birleşimleri sonucunda oluşturulan görüntüler Şekil 5.23’de verilmiştir.



Şekil 5.23. ResNet-50 Tabanlı U-Net Tahminlerinde Oluşan Kesişimler ve Birleşimler


ResNet-50 tabanlı U-Net modelinin Şekil 5.23’de belirtilen kesişim ve birleşim alanlarının ilgili görsel içerisinde kapladığı piksel sayıları ve bu değerler kullanılarak hesaplanan IoU ve DS değerleri Tablo 5.9’da verilmiştir.

Tablo 5.9. ResNet-50 Tabanlı U-Net Tahminlerinde IoU ve DS Bileşenleri

Sıra Numarası	Kesişim Piksel Sayısı	Birleşim Piksel Sayısı	IoU Değeri	DS Değeri
1	22336	24556	0.9095	0.9526
2	23642	23948	0.9872	0.9935
3	19468	19986	0.9740	0.9868
4	9120	9237	0.9873	0.9936
5	15568	19991	0.7787	0.8756
6	37146	37550	0.9892	0.9945


5.6.4. ResNet-101 Tabanlı U-Net Modeli Bulguları

U-Net modelinin kodlayıcı ağındaki klasik yapı yerine ResNet-101 mimarisinin entegre edilmesiyle oluşturulan anlamsal bölütleyici derin öğrenme modeli, erken sonlandırma fonksiyonunun da yardımıyla maksimum 200 tur sayısı sürecektir şekilde eğitilmiştir. ResNet-101 tabanlı U-Net modeli en yüksek doğrulama IoU değerine 133. tur sayısında elde ettiği 0.9061 değeriyle ulaşmıştır. Her biri ortalama 78 adım süren 133 tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve IoU grafikleri Şekil 5.24’de verilmiştir.




Şekil 5.24. ResNet-101 Tabanlı U-Net’in Kayıp ve Doğruluk Grafiği

Model eğitimine başlanmadan önce %10’luk bir payla ayrılan ve sadece test aşamasında kullanılması planlanan görüntüler ResNet-101 tabanlı U-Net modeline girdi olarak verilmiştir. İlgili girdilere karşı tahmin edilen örnek maske görüntüleri Şekil 5.25’de verilmiştir.



Şekil 5.25. ResNet-101 Tabanlı U-Net Tahminleri

ResNet-101 tabanlı U-Net modelinin Şekil 5.25’de belirtilen tahminleriyle, EFSCH-19-Seg veri setinde ilgili orijinal görüntü için hazırlanmış maske görüntülerinin kıyaslanmasında ortaya çıkan YP ve YN bulguları Şekil 5.26’da verilmiştir.




Şekil 5.26. ResNet-101 Tabanlı U-Net Tahminlerinde Oluşan YP ve YN Bulgular

ResNet-101 tabanlı U-Net modelinin Şekil 5.25’de belirtilen sıra numarasına sahip görüntüler için üretmiş olduğu maske görüntülerinin, EFSCH-19-Seg veri setinde yer alan gerçek maske görüntüleriyle karşılaştırılması sonucunda elde edilen performans metrik bileşenlerinin sayısal değerleri ve bu değerler kullanılarak hesaplanan PD değeri Tablo 5.10’da verilmiştir.

Tablo 5.10. ResNet-101 Tabanlı U-Net Tahminlerinde PD Bileşenleri

Sıra Numarası	YP Piksel Sayısı	YN Piksel Sayısı	DP Piksel Sayısı	DN Piksel Sayısı	PD Değeri
1	1458	1471	21907	40700	0.9553
2	228	205	23584	41519	0.9933
3	414	507	19215	45400	0.9859
4	77	71	9145	56243	0.9977
5	2599	2567	15223	45147	0.9211
6	320	360	36697	28159	0.9896

ResNet-101 tabanlı U-Net modelinin Şekil 5.25’de belirtilen tahminleriyle, EFSCH-19-Seg veri setinde ilgili orijinal görüntü için hazırlanmış maske görüntülerinin kıyaslanmasında ortaya çıkan kesişen piksellerin ve piksellerin birleşimleri sonucunda oluşturulan görüntüler Şekil 5.27’de verilmiştir.



Şekil 5.27. ResNet-101 Tabanlı U-Net Tahminlerinde Oluşan Kesişimler ve Birleşimler


ResNet-101 tabanlı U-Net modelinin Şekil 5.27’de belirtilen kesişim ve birleşim alanlarının ilgili görsel içerisinde kapladığı piksel sayıları ve bu değerler kullanılarak hesaplanan IoU ve DS değerleri Tablo 5.11’de verilmiştir.

Tablo 5.11. ResNet-101 Tabanlı U-Net Tahminlerinde IoU ve DS Bileşenleri

Sıra Numarası	Kesişim Piksel Sayısı	Birleşim Piksel Sayısı	IoU Değeri	DS Değeri
1	21907	24836	0.8820	0.9373
2	23584	24017	0.9819	0.9909
3	19215	20136	0.9542	0.9766
4	9145	9293	0.9840	0.9919
5	15223	20389	0.7466	0.8549
6	36697	37377	0.9818	0.9908


5.6.5. ResNet-152 Tabanlı U-Net Modeli Bulguları

U-Net modelinin kodlayıcı ağındaki klasik yapı yerine ResNet-152 mimarisinin entegre edilmesiyle oluşturulan anlamsal bölütleyici derin öğrenme modeli, erken sonlandırma fonksiyonunun da yardımıyla maksimum 200 tur sayısı sürecekte şekilde eğitilmiştir. ResNet-152 tabanlı U-Net modeli en yüksek doğrulama IoU değerine 105. tur sayısında elde ettiği 0.9074 değeriyle ulaşmıştır. Her biri ortalama 78 adım süren 105 tur sonucundaki ağırlıklar kaydedilerek ortaya çıkan kayıp ve IoU grafikleri Şekil 5.28’de verilmiştir.




Şekil 5.28. ResNet-152 Tabanlı U-Net’in Kayıp ve Doğruluk Grafiği

Model eğitime başlanmadan önce %10’luk bir payla ayrılan ve sadece test aşamasında kullanılması planlanan görüntüler ResNet-152 tabanlı U-Net modeline girdi olarak verilmiştir. İlgili girdilere karşı tahmin edilen örnek maske görüntüleri Şekil 5.29’da verilmiştir.



Şekil 5.29. ResNet-152 Tabanlı U-Net Tahminleri

ResNet-152 tabanlı U-Net modelinin Şekil 5.29’da belirtilen tahminleriyle, EFSCH-19-Seg veri setinde ilgili orijinal görüntü için hazırlanmış maske görüntülerinin kıyaslanmasında ortaya çıkan YP ve YN bulguları Şekil 5.30’da verilmiştir.




Şekil 5.30. ResNet-152 Tabanlı U-Net Tahminlerinde Oluşan YP ve YN Bulgular

ResNet-152 tabanlı U-Net modelinin Şekil 5.29’da belirtilen sıra numarasına sahip görüntüler için üretmiş olduğu maske görüntülerinin, EFSCH-19-Seg veri setinde yer alan gerçek maske görüntüleriyle karşılaştırılması sonucunda elde edilen performans metrik bileşenlerinin sayısal değerleri ve bu değerler kullanılarak hesaplanan PD değeri Tablo 5.12’de verilmiştir.

Tablo 5.12. ResNet-152 Tabanlı U-Net Tahminlerinde PD Bileşenleri

Sıra Numarası	YP Piksel Sayısı	YN Piksel Sayısı	DP Piksel Sayısı	DN Piksel Sayısı	PD Değeri
1	1302	1285	22128	40821	0.9605
2	214	148	23660	41514	0.9944
3	361	304	19531	45340	0.9898
4	62	64	9102	56308	0.9980
5	2240	2227	15565	45504	0.9318
6	211	204	36932	28189	0.9936

ResNet-152 tabanlı U-Net modelinin Şekil 5.29’da belirtilen tahminleriyle, EFSCH-19-Seg veri setinde ilgili orijinal görüntü için hazırlanmış maske görüntülerinin kıyaslanmasında ortaya çıkan kesişen piksellerin ve piksellerin birleşimleri sonucunda oluşturulan görüntüler Şekil 5.31’de verilmiştir.



Şekil 5.31. ResNet-152 Tabanlı U-Net Tahminlerinde Oluşan Kesişimler ve Birleşimler


ResNet-152 tabanlı U-Net modelinin Şekil 5.31’de belirtilen kesişim ve birleşim alanlarının ilgili görsel içerisinde kapladığı piksel sayıları ve bu değerler kullanılarak hesaplanan IoU ve DS değerleri Tablo 5.13’de verilmiştir.

Tablo 5.13. ResNet-152 Tabanlı U-Net Tahminlerinde IoU ve DS Bileşenleri

Sıra Numarası	Kesişim Piksel Sayısı	Birleşim Piksel Sayısı	IoU Değeri	DS Değeri
1	22128	24715	0.8953	0.9447
2	23660	24022	0.9849	0.9924
3	19531	20196	0.9670	0.9832
4	9102	9228	0.9863	0.9931
5	15565	20032	0.7770	0.8745
6	36932	37347	0.9888	0.9944

5.7. Görüntü Birleştirme Yöntemi


Anlamsal bölütleyici derin öğrenme modellerinin giriş katman çözünürlükleri sabit bir değer olmak zorundadır. Bu sebeple ilgili modellere farklı çözünürlükte bir görüntüyü girdi olarak vermek mümkün değildir. Ancak günlük hayatta kullanılan farklı teknolojilerin, cihazların ve standartların varlığı göz önüne alındığında sadece önceden tanımlı sabit değer girdi olarak beklenmesi mantıklı bir yaklaşım değildir. Belirtilen tüm bu zorlukları aşmak için görüntülerin 256×256 px'lik parçalara bölünmesi ve satır sütun yapısına uygun isimlendirmeleriyle modele girdi olarak verilmesi gerekmektedir. Anlamsal bölütleyici derin öğrenme modelinin çıkışında elde edilen 256×256 px'lik görüntüler sahip oldukları isimlendirmeler referans alınarak sıralı bir şekilde birleştirilmelidir. Şekil 5.32'de görüntü birleştirme yönteminin görsel kurgusu verilmiştir.



Şekil 5.32. Önerilen Görüntü Birleştirme Yöntemi


5.7.1. Birleştirilmiş Görüntü Tahminleri

Görüntülerin parçalara bölünmesinin ardından ortaya çıkan 256×256 px'lik alt görüntülerdeki akciğer ve enfekte alanların tahmin edilmesinde ResNet tabanlı U-Net modelleri tercih edilmiştir. Anlamsal bölütleyici derin öğrenme modeli olarak belirlenen ResNet-50 tabanlı U-Net modelinin, birleştirilmiş görüntülerdeki tahminleri Şekil 5.33'de verilmiştir.




Şekil 5.33. ResNet-50 Tabanlı U-Net'in Birleştirilmiş Görüntü Tahminleri

EFSCCH-19-Seg veri setinde yer almayan ve EFSCCH-19 veri setinde COVID-19 negatif sınıfında bulunan göğüs BT görüntüleri arasından rastgele seçilen örnekler ResNet-50 tabanlı U-Net modeline girdi olarak verilmiştir. Bu örneklerle karşılık ResNet-50 tabanlı U-Net modelinin tahmin ettiği maske görüntüleri Şekil 5.34’de verilmiştir.



Şekil 5.34. ResNet-50 Tabanlı U-Net'in COVID-19 İçermeyen Görüntülerde Tahminleri

ResNet-50 tabanlı U-Net modeli literatürde sıkça kullanılan halka açık veri setlerinde yer alan örnekler için de oldukça başarılı sonuçlar üretmektedir. Ma ve ark. [77] tarafından paylaşılan halka açık veri setinde 512×512px çözünürlüğüne sahip göğüs BT görüntüleri için tahmin edilen maske görüntüleri Şekil 5.35’de verilmiştir.



Şekil 5.35. ResNet-50 Tabanlı U-Net'in Halka Açık Veri Seti Örneklerinde Tahminleri

6. SONUÇ

Bu tez çalışmasında göğüs BT görüntüleriyle COVID-19 hastalığının otomatik olarak sınıflandırılması ve bölütlenmesi için derin öğrenme tabanlı bir hekim karar destek sistemi önerilmiştir. Tez kapsamında öncelikle COVID-19 hastalığının tespit edilmesine yönelik yapılan çalışmalar incelenmiş ve kullanılan yöntemler detaylıca irdelenmiştir. Yapay zeka, YSA ve derin öğrenme kavramları hakkında bilgiler verilmiştir. Literatürde yer alan çalışmaların çoğunda kullanılan halka açık veri setlerinin zayıf noktaları belirtilmiş ve veri setinin derin öğrenme çalışmalarındaki önemi vurgulanmıştır. Veri setinin eğitilen derin öğrenme modellerinde çok önemli bir unsur olması sebebiyle ilk kez bu tez çalışmasında kullanılacak özel bir veri seti oluşturularak daha sonrasında araştırmacıların kullanımına sunulması hedeflenmiştir. EFSCCH-19 adında 4000 adet göğüs BT görüntüsünden oluşan ve her bir örneği 768×768px çözünürlüğüne sahip bir veri seti oluşturulmuştur. Gerçek hasta görüntülerini içeren veri setinde hastalara ait kişisel veriler yer almamaktadır. Gerçek hasta görüntülerinin ait olduğu COVID-19 sınıfı belirlenmesinde radyoloji uzmanı görüşlerine başvurulmuştur. Ayrıca, oluşturulan veri setinin sağlık sektöründe aktif olarak kullanılan raporlama standartlarına uygunluğu detaylıca açıklanmıştır. Sınıflandırma görevini gerçekleştirecek derin öğrenme modellerinde, oluşturulan veri setinin örnekleri sadece birkaç adımdan oluşan ön işlem aşaması ardından doğrudan kullanılabilir. Önerilen sistem EfficientNet modellerini kullanarak göğüs BT görüntülerini yüksek doğruluk oranlarıyla sınıflandırmıştır. EfficientNet model ailesinin sekiz üyesinden yararlanılarak test aşaması gerçekleştirilmiş ve deneysel sonuçlar elde edilmiştir. Elde edilen deneysel sonuçlar neticesinde, EfficientNet-B2 modelinin %99.75 doğruluk, %99.50 duyarlılık, %100 kesinlik, %100 özgüllük, %99.75 F1-Skoru ve %99.50 MCC oranlarıyla test aşamasını en başarılı tamamlayan model olduğu belirlenmiştir. EfficientNet modellerinin COVID-19 negatif sınıfına ait örnekleri COVID-19 pozitif sınıfı örneklerine kıyasla daha yüksek doğrulukla sınıflandırabildiği görülmektedir. Test görüntüleri arasında yer alan 70. görsel, EfficientNet modellerinin sınıf tahmininde en fazla hata yaptıkları örnek olduğu tespit edilmiştir. EfficientNet-B2 modeli, test aşamasında yer alan 400 adet görüntüyü Google Colab ortamında 45 saniyede sınıflandırmıştır. Yüksek doğruluk oranıyla ve hızlı bir şekilde sınıflandırmanın yanı sıra EfficientNet-B2 modelinin ilgili görsel üzerinde gerçekleştirdiği tahmin için odaklandığı alanların enfeksiyon alanları olduğu Grad-CAM yöntemiyle ispatlanmıştır.

Bölütleme görevini gerçekleştirecek derin öğrenme modeli için veri seti örnekleri tek başına yeterli olmayacağından maske görüntülerinin radyoloji uzmanı tarafından oluşturulması sağlanmıştır. Bu sayede, gerçek hastalara ait 200 farklı göğüs BT taramalarında yer alan akciğer ve enfeksiyon alanları elle işaretlenmiştir. Maske görüntülerinin oluşturulması ve düzenlenmesi süreçlerinde açık kaynak kodlu ücretsiz uygulamalar kullanılmıştır. ResNet tabanlı U-Net

modelleri radyoloji uzmanının işaretlemelerini saf doğru olarak kabul edip öğrenme süreçlerini tamamlamıştır. Eğitim aşamasında büyük çözünürlükteki resimlerin kullanılmasına yönelik görüntü parçalama yöntemi detaylıca açıklanmıştır. Eğitim aşamasının tamamlanmasının ardından deneysel sonuçlar elde edilmiştir. Elde edilen deneysel sonuçlar neticesinde, ResNet-50 tabanlı U-Net modelinin ortalama %93.76 IoU ve %96.61 DS oranlarıyla test aşamasını en başarılı tamamlayan model olduğu belirlenmiştir. Görüntü parçalama yönteminin tamamlayıcısı olan görüntü birleştirme metodu hakkında bilgiler ve önerilen görsel kurgu paylaşılmıştır. ResNet-50 tabanlı U-Net modelinin halka açık veri setleri arasından rastgele seçilen çeşitli çözünürlükteki örnekler için gerçekleştirmiş olduğu tahminler paylaşılarak ilgili modelin bölütleme yeteneği gözlemlenmiştir. İlgili modelin 768×768px'lik bir görüntüyü Google Colab ortamında 6 saniyede bölütleyebildiği görülmektedir.

Derin öğrenme çalışmalarında kullanılan veri setinin kalitesi ve içerdiği örnek sayısı büyük önem taşımaktadır. Çok sayıdaki bu kaliteli örnekleri uygulamaya dahil edebilmek için gelişmiş donanımlara ihtiyaç duyulmaktadır. Ancak transfer öğrenme gibi yöntemler kullanılmasıyla gereksinimlerin maliyeti düşürülebilir. Bu tez çalışması sonucunda ele edilen bulgular, COVID-19 hastalığının teşhisinde ve hastalığın yayılımının incelenmesinde hekimlere destek olabilecek düşük maliyetli ve hızlı bir sistem gerçekleştirilebileceğini göstermektedir.

ÖNERİLER

1. Çalışmada radyolojik görüntüleme türü olarak göğüs BT taramaları tercih edilmiştir. Göğüs BT taramaları yerine x-ışını gibi farklı radyolojik görüntüleme yöntemleri kullanılarak sonuçlar gözlemlenebilir.
2. Göğüs BT görüntüleri üzerinde veri çoklama teknikleri kullanılarak veri setinde yer alan örnek sayısı arttırılabilir.
3. Sınıflandırıcı derin öğrenme modeli olarak EfficientNet model ailesi üyeleri kullanılmıştır. EfficientNet model ailesi üyeleri yerine farklı ön eğitilmiş modeller tercih edilerek sonuçlar incelenebilir.
4. Model eğitiminde kullanılan parametreler değiştirilerek farklı eğitim süreçleri kurgulanabilir.
5. Anlamsal bölütleyici derin öğrenme modeli olarak U-Net mimarisi kullanılmıştır. U-Net mimarisi yerine farklı derin öğrenme modelleri kullanılabilir.
6. U-Net mimarisinin kodlayıcı ağında varsayılan katmanlar yerine ResNet modelleri entegre edilmiştir. U-Net mimarisinin kodlayıcı ağında ResNet modelleri yerine farklı modeller kullanılarak U-Net modelinin yeni bölütleme performansı incelenebilir.
7. 5-kat çapraz doğrulama yöntemi kullanılarak test aşamasında ulaşılan değerlerin geçerliliği ispatlanabilir.

KAYNAKLAR

- [1] Tekin, A. (2021). Tarihten Günümüze Epidemiler, Pandemiler ve Ekonomik Sonuçları, *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (40), 330-355.
- [2] İşsever, H., İşsever, T. ve Öztan, G. (2020). COVID-19 epidemiyolojisi, *Sağlık Bilimlerinde İleri Araştırmalar Dergisi*, 3(S1), 1-13.
- [3] Ahmad, T., Khan, M., Haroon, T. H. M., Nasir, S., Hui, J., Bonilla-Aldana, D. K. Ve Rodriguez-Morales, A. J. (2020). COVID-19: Zoonotic aspects, *Travel medicine and infectious disease*, 36, 101607. doi: 10.1016/j.tmaid.2020.101607
- [4] Hua, J. ve Shaw, R. (2020). Corona virus (Covid-19)“infodemic” and emerging issues through a data lens: The case of china, *International journal of environmental research and public health*, 17(7), 2309. doi: 10.3390/ijerph17072309
- [5] <http://www.arcgis.com/apps/dashboards/bda7594740fd40299423467b48e9ecf6> COVID-19 Dashboard, Johns Hopkins University (Erişim Tarihi: Mayıs 2022)
- [6] Madabhavi, I., Sarkar, M. ve Kadakol, N. (2020). COVID-19: a review, *Monaldi Archives for Chest Disease*, 90(2). doi: 10.4081/monaldi.2020.1298
- [7] Wadman, M. (2021). SARS-CoV-2 infection confers greater immunity than shots, *Science*, 373(6559), 1067-1068. doi: 10.1126/science.acx8993
- [8] Giri, B., Pandey, S., Shrestha, R., Pokharel, K., Ligler, F. S. ve Neupane, B. B. (2021). Review of analytical performance of COVID-19 detection methods, *Analytical and bioanalytical chemistry*, 413(1), 35-48. doi: 10.1007/s00216-020-02889-x
- [9] Corman, V. M., Landt, O., Kaiser, M., Molenkamp, R., Meijer, A., Chu, D. K. ve Drosten, C. (2020). Detection of 2019 novel coronavirus (2019-nCoV) by real-time RT-PCR, *Eurosurveillance*, 25(3), 2000045. doi: 10.2807/1560-7917.ES.2020.25.3.2000045
- [10] Wu, F., Zhao, S., Yu, B., Chen, Y. M., Wang, W., Song, Z. G. ve Zhang, Y. Z. (2020). A new coronavirus associated with human respiratory disease in China, *Nature*, 579(7798), 265-269. doi: 10.1038/s41586-020-2008-3
- [11] Zali, A., Sohrabi, M. R., Mahdavi, A., Khalili, N., Taheri, M. S., Maher, A. ve Hanani, K. (2021). Correlation between low-dose chest computed tomography and RT-PCR results for the diagnosis of COVID-19: A report of 27,824 cases in tehran, Iran, *Academic Radiology*, 28(12), 1654-1661. doi: 10.1016/j.acra.2020.09.003
- [12] http://hastane.harran.edu.tr/covid/pdf_onizleme.aspx?fileName=algoritma/179202014300759.pdf T.C Sağlık Bakanlığı, COVID-19 Erişkin Tedavi Algoritması (Erişim Tarihi: Mayıs 2022)
- [13] Kommos, F. K., Schwab, C., Tavernar, L., Schreck, J., Wagner, W. L., Merle, U. ve Longerich, T. (2020). The Pathology of Severe COVID-19-Related Lung Damage: Mechanistic and Therapeutic Implications, *Deutsches Ärzteblatt International*, 117(29-30), 500. doi: 10.3238/arztebl.2020.0500
- [14] Ghaderzadeh, M. ve Asadi, F. (2021). Deep learning in the detection and diagnosis of COVID-19 using radiology modalities: a systematic review, *Journal of healthcare engineering*, 2021. doi: 10.1155/2021/6677314
- [15] Ng, M. Y., Lee, E. Y., Yang, J., Yang, F., Li, X., Wang, H. ve Kuo, M. D. (2020). Imaging profile of the COVID-19 infection: radiologic findings and literature review, *Radiology: Cardiothoracic Imaging*, 2(1), e200034. doi: 10.1148/ryct.2020200034

- [16] Fields, B. K., Demirjian, N. L., Dadgar, H. ve Gholamrezanezhad, A. (2021). Imaging of COVID-19: CT, MRI, and PET. *Seminars in Nuclear Medicine*, 51(4), 312-320. doi: 10.1053/j.semnuclmed.2020.11.003
- [17] Gündel, S., Setio, A. A., Ghesu, F. C., Grbic, S., Georgescu, B., Maier, A. ve Comaniciu, D. (2021). Robust classification from noisy labels: Integrating additional knowledge for chest radiography abnormality assessment, *Medical Image Analysis*, 72, 102087. doi: 10.1016/j.media.2021.102087
- [18] Chartrand, G., Cheng, P. M., Vorontsov, E., Drozdal, M., Turcotte, S., Pal, C. J. ve Tang, A. (2017). Deep learning: a primer for radiologists, *Radiographics*, 37(7), 2113-2131. doi: 10.1148/rg.2017170077
- [19] Arsalan, M., Owais, M., Mahmood, T., Choi, J. ve Park, K. R. (2020). Artificial intelligence-based diagnosis of cardiac and related diseases, *Journal of Clinical Medicine*, 9(3), 871. doi: 10.3390/jcm9030871
- [20] Owais, M., Arsalan, M., Choi, J., Mahmood, T. ve Park, K. R. (2019). Artificial intelligence-based classification of multiple gastrointestinal diseases using endoscopy videos for clinical diagnosis, *Journal of clinical medicine*, 8(7), 986. doi: 10.3390/jcm8070986
- [21] Biswas, M., Kuppili, V., Saba, L., Edla, D. R., Suri, H. S., Cuadrado-Godia, E. ve Suri, J. S. (2019). State-of-the-art review on deep learning in medical imaging. *Front Biosci (Landmark Ed)*, 24, 392-426. doi: 10.1016/j.ejrad.2019.02.038
- [22] Chin, C. L., Lin, B. J., Wu, G. R., Weng, T. C., Yang, C. S., Su, R. C. ve Pan, Y. J. (2017). An automated early ischemic stroke detection system using CNN deep learning algorithm, *8th International conference on awareness science and technology (iCAST)*, 368-372.
- [23] Yildirim, K., Bozdog, P. G., Talo, M., Yildirim, O., Karabatak, M. ve Acharya, U. R. (2021). Deep learning model for automated kidney stone detection using coronal CT images, *Computers in biology and medicine*, 135, 104569. doi: 10.1016/j.combiomed.2021.104569
- [24] Khan, S., Islam, N., Jan, Z., Din, I. U. ve Rodrigues, J. J. C. (2019). A novel deep learning based framework for the detection and classification of breast cancer using transfer learning, *Pattern Recognition Letters*, 125, 1-6. doi: 10.1016/j.patrec.2019.03.022
- [25] Bogu, G. K. ve Snyder, M. P. (2021). Deep learning-based detection of COVID-19 using wearables data, *MedRxiv*.
- [26] Pahar, M., Klopper, M., Warren, R. ve Niesler, T. (2021). COVID-19 cough classification using machine learning and global smartphone recordings, *Computers in Biology and Medicine*, 135, 104572. doi: 10.1016/j.combiomed.2021.104572
- [27] Hemdan, E. E. D., Shouman, M. A. ve Karar, M. E. (2020). Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images, *arXiv preprint arXiv:2003.11055*.
- [28] Wang, L., Lin, Z. Q. ve Wong, A. (2020). Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images, *Scientific Reports*, 10(1), 1-12. doi: 10.1038/s41598-020-76550-z
- [29] Narin, A., Kaya, C. ve Pamuk, Z. (2021). Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks, *Pattern Analysis and Applications*, 24(3), 1207-1220. doi: 10.1007/s10044-021-00984-y
- [30] Hussain, E., Hasan, M., Rahman, M. A., Lee, I., Tamanna, T. ve Parvez, M. Z. (2021). CoroDet: A deep learning based classification for COVID-19 detection using chest X-ray images, *Chaos, Solitons & Fractals*, 142, 110495. doi: 10.1016/j.chaos.2020.110495

- [31] Luz, E., Silva, P., Silva, R., Silva, L., Guimarães, J., Miozzo, G. ve Menotti, D. (2021). Towards an effective and efficient deep learning model for COVID-19 patterns detection in X-ray images, *Research on Biomedical Engineering*, 1-14. doi: 10.1007/s42600-021-00151-6
- [32] Apostolopoulos, I. D. Ve Mpesiana, T. A. (2020). Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks, *Physical and engineering sciences in medicine*, 43(2), 635-640. doi: 10.1007/s13246-020-00865-4
- [33] Shah, V., Keniya, R., Shridharani, A., Punjabi, M., Shah, J. ve Mehendale, N. (2021). Diagnosis of COVID-19 using CT scan images and deep learning techniques, *Emergency radiology*, 28(3), 497-505. doi: 10.1007/s10140-020-01886-y
- [34] Shalbaf, A. ve Vafaezadeh, M. (2021). Automated detection of COVID-19 using ensemble of transfer learning with deep convolutional neural network based on CT scans, *International journal of computer assisted radiology and surgery*, 16(1), 115-123. doi: 10.1007/s11548-020-02286-w
- [35] Loey, M., Manogaran, G. ve Khalifa, N. E. M. (2020). A deep transfer learning model with classical data augmentation and CGAN to detect COVID-19 from chest CT radiography digital images, *Neural Computing and Applications*, 1-13. doi: 10.1007/s00521-020-05437-x
- [36] Song, Y., Zheng, S., Li, L., Zhang, X., Zhang, X., Huang, Z. ve Yang, Y. (2021). Deep learning enables accurate diagnosis of novel coronavirus (COVID-19) with CT images, *IEEE/ACM transactions on computational biology and bioinformatics*, 18(6), 2775-2780. doi: 10.1109/TCBB.2021.3065361
- [37] Wang, S., Kang, B., Ma, J., Zeng, X., Xiao, M., Guo, J. ve Xu, B. (2021). A deep learning algorithm using CT images to screen for Corona Virus Disease (COVID-19), *European radiology*, 31(8), 6096-6104. doi: 10.1007/s00330-021-07715-1
- [38] Zhou, T., Canu, S. ve Ruan, S. (2021). Automatic COVID-19 CT segmentation using U-Net integrated spatial and channel attention mechanism, *International Journal of Imaging Systems and Technology*, 31(1), 16-27. doi: 10.1002/ima.22527
- [39] Amer, A., Ye, X. ve Janan, F. (2021). Residual Dilated U-Net for the Segmentation of COVID-19 Infection From CT Images, *International Conference on Computer Vision*, 462-470.
- [40] Yan, Q., Wang, B., Gong, D., Luo, C., Zhao, W., Shen, J. Ve You, Z. (2020). COVID-19 chest CT image segmentation--A deep convolutional neural network solution, *arXiv preprint arXiv:2004.10987*.
- [41] Chen, X., Yao, L. ve Zhang, Y. (2020). Residual attention u-net for automated multi-class segmentation of covid-19 chest ct images, *arXiv preprint arXiv:2004.05645*.
- [42] Yanarateş, E. (2020). An overall evaluation of the covid-19 pandemic, *Social Scientific Centered Issues*, 2(1), 24-33.
- [43] Liu, D. X., Liang, J. Q. ve Fung, T. S. (2021). Human coronavirus-229e,-oc43,-nl63, and-hku1 (coronaviridae), *Encyclopedia of virology*, 428. doi: 10.1016/B978-0-12-809633-8.21501-X
- [44] Xu, J., Zhao, S., Teng, T., Abdalla, A. E., Zhu, W., Xie, L. ve Guo, X. (2020). Systematic comparison of two animal-to-human transmitted human coronaviruses: SARS-CoV-2 and SARS-CoV, *Viruses*, 12(2), 244. doi: 10.3390/v12020244
- [45] Meo, S. A., Alhowikan, A. M., Al-Khlaiwi, T., Meo, I. M., Halepoto, D. M., Iqbal, M. ve Ahmed, N. (2020). Novel coronavirus 2019-nCoV: prevalence, biological and clinical characteristics comparison with SARS-CoV and MERS-CoV, *Eur Rev Med Pharmacol Sci*, 24(4), 2012-2019.
- [46] Uzunian, A. (2020). Coronavirus SARS-CoV-2 and Covid-19, *Jornal Brasileiro de Patologia e Medicina Laboratorial*, 56. doi: 10.5935/1676-2444.20200053

- [47] Laue, M., Kauter, A., Hoffmann, T., Möller, L., Michel, J. ve Nitsche, A. (2021). Morphometry of SARS-CoV and SARS-CoV-2 particles in ultrathin plastic sections of infected Vero cell cultures, *Scientific reports*, 11(1), 1-11. doi: 10.1038/s41598-021-82852-7
- [48] Lam, T. T. Y., Jia, N., Zhang, Y. W., Shum, M. H. H., Jiang, J. F., Zhu, H. C. ve Cao, W. C. (2020). Identifying SARS-CoV-2-related coronaviruses in Malayan pangolins, *Nature*, 583(7815), 282-285. doi: 10.1038/s41586-020-2169-0
- [49] Ali, I. ve Alharbi, O. M. (2020). COVID-19: Disease, management, treatment, and social impact, *Science of the total Environment*, 728, 138861. doi: 10.1016/j.scitotenv.2020.138861
- [50] Abebe, E. C., Dejenie, T. A., Shiferaw, M. Y. ve Malik, T. (2020). The newly emerged COVID-19 disease: a systemic review, *Virology journal*, 17(1), 1-8. doi: 10.1186/s12985-020-01363-5
- [51] Zheng, S., Fan, J., Yu, F., Feng, B., Lou, B., Zou, Q. ve Liang, T. (2020). Viral load dynamics and disease severity in patients infected with SARS-CoV-2 in Zhejiang province, China, January-March 2020: retrospective cohort study, *bmj*, 369. doi: 10.1136/bmj.m1443
- [52] Nuertey, B. D., Ekremet, K., Haidallah, A. R., Mumuni, K., Addai, J., Attibu, R. I. E. ve Phillips, R. O. (2021). Performance of COVID-19 associated symptoms and temperature checking as a screening tool for SARS-CoV-2 infection, *PloS one*, 16(9). doi: 10.1371/journal.pone.0257450
- [53] Tsai, P. H., Lai, W. Y., Lin, Y. Y., Luo, Y. H., Lin, Y. T., Chen, H. K. ve Yang, Y. P. (2021). Clinical manifestation and disease progression in COVID-19 infection, *Journal of the Chinese Medical Association*, 84(1), 3-8. doi: 10.1097/JCMA.0000000000000463
- [54] Axell-House, D. B., Lavingia, R., Rafferty, M., Clark, E., Amirian, E. S. ve Chiao, E. Y. (2020). The estimation of diagnostic accuracy of tests for COVID-19: A scoping review, *Journal of Infection*, 81(5), 681-697. doi: 10.1016/j.jinf.2020.08.043
- [55] Khalaf, K., Papp, N., Chou, J. T. T., Hana, D., Mackiewicz, A. ve Kaczmarek, M. (2020). SARS-CoV-2: pathogenesis, and advancements in diagnostics and treatment, *Frontiers in Immunology*, 2462. doi: 10.3389/fimmu.2020.570927
- [56] Chau, C. H., Strobe, J. D. ve Figg, W. D. (2020). COVID-19 clinical diagnostics and testing technology, *Pharmacotherapy: The Journal of Human Pharmacology and Drug Therapy*, 40(8), 857-868. doi: 10.1002/phar.2439
- [57] <https://www.cdc.gov/coronavirus/2019-ncov/lab/guidelines-clinical-specimens.html> COVID-19 Testi için Klinik Örneklerin Toplanması ve İşlenmesine İlişkin Geçici Kılavuz (Erişim: Mayıs 2022)
- [58] Tahamtan, A. ve Ardebili, A. (2020). Real-time RT-PCR in COVID-19 detection: issues affecting the results, *Expert review of molecular diagnostics*, 20(5), 453-454. doi: 10.1080/14737159.2020.1757437
- [59] Seibert, J. A. (2004). X-ray imaging physics for nuclear medicine technologists. Part 1: Basic principles of x-ray production, *Journal of nuclear medicine technology*, 32(3), 139-147.
- [60] Mijwel, M. M. (2015). History of Artificial Intelligence, *Comput. Sci*, (3).
- [61] González García, C., Núñez Valdéz, E. R., García Díaz, V., Pelayo García-Bustelo, B. C. ve Cueva Lovelle, J. M. (2019). A review of artificial intelligence in the internet of things, *International Journal Of Interactive Multimedia And Artificial Intelligence*, 5. doi: 10.9781/ijimai.2018.03.004
- [62] Jha, K., Doshi, A., Patel, P. ve Shah, M. (2019). A comprehensive review on automation in agriculture using artificial intelligence, *Artificial Intelligence in Agriculture*, 2, 1-12. doi:10.1016/j.aiia.2019.05.004
- [63] McCulloch, W. S. ve Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics*, 5(4), 115-133.

- [64] Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological review*, 65(6), 386.
- [65] Belue, L. M. ve Bauer Jr, K. W. (1995). Determining input features for multilayer perceptrons, *Neurocomputing*, 7(2), 111-121.
- [66] Angelov, P. ve Almeida Soares, E. (2020). SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification, *MedRxiv*. doi: 10.1101/2020.04.24.20078584
- [67] Yang, X., He, X., Zhao, J., Zhang, Y., Zhang, S. ve Xie, P. (2020). COVID-CT-dataset: a CT scan dataset about COVID-19, *arXiv preprint arXiv:2003.13865*.
- [68] Cömert, S. Ş. ve Kırıl, N. (2020). COVID-19 Pnömonisinin Radyolojik Bulguları, *Southern Clinics of Istanbul Eurasia*, 16-22. doi: 10.14744/scie.2020.96158
- [69] Prokop, M., Van Everdingen, W., van Rees Vellinga, T., Quarles van Ufford, H., Stöger, L. ve Beenen, L. (2020). CO-RADS: a categorical CT assessment scheme for patients suspected of having COVID-19—definition and evaluation, *Radiology*, 296(2), E97-E104. doi: 10.1148/radiol.2020201473
- [70] Tan, M. ve Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks, *International conference on machine learning*, 6105-6114.
- [71] Montalbo, F. J. P. ve Alon, A. S. (2021). Empirical Analysis of a Fine-Tuned Deep Convolutional Model in Classifying and Detecting Malaria Parasites from Blood Smears, *Transactions on Internet and Information Systems (TIIS)*, 15(1), 147-165. doi: 10.3837/tiis.2021.01.009
- [72] https://keras.io/examples/vision/image_classification_efficientnet_fine_tuning/ EfficientNet ile İnce Ayarla Görüntü Sınıflandırması. (Erişim: Mayıs 2022)
- [73] Deng, J., Dong, W., Socher, R., Li, L. J., Li, K. ve Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database, *Computer vision and pattern recognition*, 248-255
- [74] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D. ve Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization, *International conference on computer vision*, 618-626.
- [75] Yushkevich, P. A., Gao, Y. ve Gerig, G. (2016). ITK-SNAP: An interactive tool for semi-automatic segmentation of multi-modality biomedical images, *Engineering in Medicine and Biology Society (EMBC)*, 3342-3345.
- [76] Ronneberger, O., Fischer, P. ve Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation, *Medical image computing and computer-assisted intervention*, 234-241. doi: 10.1007/978-3-319-24574-4_28
- [77] Ma, J., Ge, C., Wang, Y., An, X., Gao, J., Yu, Z., Zhang, M., Liu, X., Deng, X. ve Cao, S. (2020). COVID-19 CT Lung and Infection Segmentation Dataset, *Zenodo*. doi: 10.5281/zenodo.3757476

EKLER

EK- 1: ETİK KURUL ONAYI



T.C.
FIRAT ÜNİVERSİTESİ
GİRİŞİMSSEL OLMAYAN ARAŞTIRMALAR
ETİK KURULU
GİRİŞİMSSEL OLMAYAN ARAŞTIRMALAR
ETİK KURULU KARARLARI

Oturum Tarihi
18.03.2021

Oturum Saati
14:00

Oturum Sayısı
2021/04 - 40

Girişimsel Olmayan Araştırmalar Etik Kurulu 18.03.2021 tarihinde saat 14:00'da Kurul Başkanı Prof. Dr. Mustafa KAPLAN başkanlığında, aşağıda imzaları bulunan kurul üyelerinin katılımlarıyla toplanarak gündemdeki konuları görüşmüş ve aşağıdaki kararları almıştır.

Sorumlu Araştırmacı : Dr. Öğr. Üyesi Erkan DUMAN
Diğer Araştırmacılar : Yük. Lis. Öğr. Oğuzhan KATAR

"X-Ray Görüntülerinden Covid-19 Teşhisine Yönelik Derin Öğrenme Tabanlı Hekim Karar Destek Sistemi Tasarımı" konulu yüksek lisans tez çalışması kurulumuzda görüşülmüş olup; çalışmanın etik kurallara uygun olduğuna oy birliğiyle karar verilmiştir.

(Araştırmamızın tüm süreçlerinde kurum ve kuruluşlardan gereken izinlerin alınmasından araştırmacı/lar sorumludur.)

Kurul Üyeleri:

Prof. Dr. Mustafa KAPLAN, Prof. Dr. Engin ŞAHNA (Bulunmadı), Prof. Dr. Demet ÇİÇEK, Prof. Dr. Erdal TAŞKIN (Bulunmadı), Prof. Dr. Seval YILMAZ, Doç. Dr. Nevzat GÖZEL, Doç. Dr. Fazilet ERMAN, Doç. Dr. Burcu GÜL BAYKALIR , Dr. Öğr. Üyesi Turgay BÖRK, Dr. Öğr. Üyesi Adem GÖK

Prof. Dr. Mustafa KAPLAN
Kurul Başkanı

Prof. Dr. Demet ÇİÇEK

Prof. Dr. Seval YILMAZ

Doç. Dr. Nevzat GÖZEL

Doç. Dr. Fazilet ERMAN

Doç. Dr. Burcu GÜL BAYKALIR

Dr. Öğr. Üyesi Turgay BÖRK

Dr. Öğr. Üyesi Adem GÖK

Şekil E1.1. Etik Kurul İzni

EK- 2: ELAZIĞ FETHİ SEKİN ŞEHİR HASTANESİ BAŞHEKİM ONAYI



T.C.
ELAZIĞ VALİLİĞİ
İL SAĞLIK MÜDÜRLÜĞÜ
ELAZIĞ FETHİ SEKİN ŞEHİR HASTANESİ

ELAZIĞ FETHİ SEKİN ŞEHİR HASTANESİ
BAŞHEKİMLİĞİ - ELAZIĞ FETHİ SEKİN ŞEHİR
HASTANESİ BİLGİ İŞLEM BİRİMİ
02/04/2021 20:31 - E-13281952 - 719 - 137



Sayı : E-13281952-719
Konu : Oğuzhan KATAR

Sayın Oğuzhan KATAR
Fırat Üniversitesi Teknoloji Fakültesi Kat :3/Elazığ

İlgi : 01/04/2021 tarihli ve 3655 sayılı dilekçeniz.

İlgi tarih ve sayılı dilekçenize istinaden Hastanemizde yapmayı planlandığınız "X-Ray Görüntülerinden Covid-19 Teşhisine Yönelik Derin Öğrenme Tabanlı Hekim Karar Destek Sistemi Tasarımı" adlı çalışmayı yürüteniz Başhekimliğimizce uygun görülmüştür.

Bilgilerinize rica ederim.

Prof. Dr. Erol KELEŞ
Başhekim

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu: fe51d0d3-d7f4-4019-a9aa-88144bcb6cc0 Belge Doğrulama Adresi: <https://www.turkiye.gov.tr/saglik-bakanligi-cbys>

Elazığ Fethi Sekin Şehir Hastanesi

Bilgi için: Emine YILMAZ

Telefon: Faks No:

TIBBİ SEKRETER

e-Posta: emine.yilmaz17@saglik.gov.tr İnternet Adresi: emineyilma-z@hotmail.com

Telefon No: (0 424) 606 60 00



Şekil E1.2. Başhekimlik Çalışma Onayı

EK- 3: T.C SAĞLIK BAKANLIĞI BİLİMSEL ARAŞTIRMA ONAYI

07.04.2021

Fırat Üniversitesi Posta - Bilimsel Araştırma Başvurusu



OĞUZHAN KATAR <okatar@firat.edu.tr>

Bilimsel Araştırma Başvurusu

1 mesaj

Bilimsel Araştırma Başvurusu <portal@saglik.gov.tr>

4 Nisan 2021 11:44

Yanıtlatma Adresi: noreply@portal.saglik.gov.tr

Alıcı: okatar@firat.edu.tr

Sayın İlgili,

Bilimsel Araştırma Platformuna yapmış olduğunuz başvuru incelenmiştir.

Bu çalışmayı yapmanız Bakanlığımızca uygun olarak değerlendirilmiştir. Araştırmanızın gerektirdiği diğer tüm süreçlerin (etik kurul, etik komisyon, faz çalışması, diğer izinler vb.) tamamlanması konusunda araştırmacı/ lar sorumludur.

Açıklama :

Form Adı : Oğuzhan KATAR-2021-04-02T11_51_31

Başvuru Formu için [tıklayınız](#).

Başvuru Formunuzu <https://bilimselarastirma.saglik.gov.tr/> adresinden görüntüleyebilirsiniz.

İlginiz ve katkılarınızdan dolayı teşekkür ederiz.

T.C. Sağlık Bakanlığı

Sağlık Hizmetleri Genel Müdürlüğü

Not: Bu ileti Bilimsel Araştırmanızın Değerlendirilmesinin tamamlanması nedeniyle sistem tarafından otomatik gönderilmiştir. Lütfen bu iletiyi cevaplamayınız.

YASAL UYARI:

Bu e-postanın içerdiği bilgiler (ekleri de dahil olmak üzere) gizlidir. T.C. Sağlık Bakanlığı onayı olmaksızın içeriği kopyalanamaz, üçüncü kişilere açıklanamaz veya iletilemez. Bu mesajın gönderilmek istendiği kişi değilseniz (ya da bu e-postayı yanlışlıkla aldıysanız), lütfen yollayan kişiyi haberdar ediniz ve mesajı sisteminizden derhal siliniz. T.C. Sağlık Bakanlığı bu mesajın içerdiği bilgilerin doğruluğu veya eksiksiz olduğu konusunda bir garanti vermemektedir. Bu nedenle, bilgilerin ne şekilde olursa olsun içeriğinden, iletilmesinden, alınmasından ve saklanmasından T.C. Sağlık Bakanlığı sorumlu değildir. Bu mesajın içeriği yazarına ait olup, T.C. Sağlık Bakanlığı görüşlerini içermeyebilir.

Bu e-posta bizce bilinen tüm bilgisayar virüslerine karşı taranmıştır.

DISCLAIMER:

This e-mail (including any attachments) may contain confidential and/or privileged information. Copying, disclosure or distribution of the material in this e-mail without the permission of Ministry of Health of Turkey is strictly forbidden. If you are not the intended recipient (or have received this e-mail in error), please notify the sender and delete email from your system immediately. Ministry of Health of Turkey makes no warranty as to the accuracy or completeness of any information contained in this message and hereby excludes any liability of any kind for the information contained therein or for the information transmission, reception, storage or use of such in any way whatsoever. Any opinions expressed in this message are those of the author and may not necessarily reflect the opinions of Ministry of Health of Turkey.

This e-mail has been scanned for all computer viruses known to us.

<https://mail.google.com/mail/u/0?ik=554cc2c2ca&view=pt&search=all&permthid=thread-f%3A1696098766904752462&simpl=msg-f%3A1696098...> 1/1

Şekil E1.3. T.C Sağlık Bakanlığı Bilimsel Araştırma Onayı

ÖZGEÇMİŞ

Oğuzhan KATAR

[illegible]

© 2006 The Authors
Journal compilation © 2006 Blackwell Publishing Ltd

[REDACTED]
 [REDACTED]
 [REDACTED]
 [REDACTED]

- [REDACTED]
- [REDACTED]

[REDACTED] [REDACTED]
[REDACTED] [REDACTED]

Category	Value
Category 1	100%
Category 2	100%
Category 3	100%
Category 4	100%
Category 5	100%
Category 6	100%
Category 7	100%
Category 8	100%
Category 9	100%
Category 10	100%
Category 11	100%
Category 12	100%
Category 13	100%
Category 14	100%
Category 15	100%
Category 16	100%
Category 17	100%
Category 18	100%
Category 19	100%
Category 20	100%
Category 21	100%
Category 22	100%
Category 23	100%
Category 24	100%
Category 25	100%
Category 26	100%
Category 27	100%
Category 28	100%
Category 29	100%
Category 30	100%
Category 31	100%
Category 32	100%
Category 33	100%
Category 34	100%
Category 35	100%
Category 36	100%
Category 37	100%
Category 38	100%
Category 39	100%
Category 40	100%
Category 41	100%
Category 42	100%
Category 43	100%
Category 44	100%
Category 45	100%
Category 46	100%
Category 47	100%
Category 48	100%
Category 49	100%
Category 50	100%
Category 51	100%
Category 52	100%
Category 53	100%
Category 54	100%
Category 55	100%
Category 56	100%
Category 57	100%
Category 58	100%
Category 59	100%
Category 60	100%
Category 61	100%
Category 62	100%
Category 63	100%
Category 64	100%
Category 65	100%
Category 66	100%
Category 67	100%
Category 68	100%
Category 69	100%
Category 70	100%
Category 71	100%
Category 72	100%
Category 73	100%
Category 74	100%
Category 75	100%
Category 76	100%
Category 77	100%
Category 78	100%
Category 79	100%
Category 80	100%
Category 81	100%
Category 82	100%
Category 83	100%
Category 84	100%
Category 85	100%
Category 86	100%
Category 87	100%
Category 88	100%
Category 89	100%
Category 90	100%
Category 91	100%
Category 92	100%
Category 93	100%
Category 94	100%
Category 95	100%
Category 96	100%
Category 97	100%
Category 98	100%
Category 99	100%
Category 100	100%