

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ÖKSÜRÜK AKUSTİK SINYALLERİNDE GELENEKSEL VE DERİN
ÖZNİTELİKLER YARDIMIYLA COVID-19 TESPİTİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

YUNUS EMRE ERDOĞAN

TEMMUZ 2022

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ÖKSÜRÜK AKUSTİK SINYALLERİNDE GELENEKSEL VE DERİN
ÖZNİTELİKLER YARDIMIYLA COVID-19 TESPİTİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Yunus Emre ERDOĞAN

DANIŞMAN: Dr. Öğr. Üyesi Ali NARİN

ZONGULDAK

Temmuz 2022

KABUL:

Yunus Emre ERDOĞAN tarafından hazırlanan “Öksürük Akustik Sinyallerinde Geleneksel ve Derin Öznitelikler Yardımıyla COVID-19 Tespiti” başlıklı bu çalışma jürimiz tarafından değerlendirilerek Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir. 22/07/2022

Danışman: Dr. Öğr. Üyesi Ali NARİN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü

Üye: Doç. Dr. Rukiye UZUN ARSLAN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü

Üye: Dr. Öğr. Üyesi Veli BAYSAL

Bartın Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylıyorum.

.../.../2022

Prof. Dr. Ahmet ÖZARSLAN
Fen Bilimleri Enstitüsü Müdürü



“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, Tezden kaynaklanmayan bütün atıfları yaptığımı beyan ederim.

Yunus Emre ERDOĞAN

ÖZET

Yüksek Lisans Tezi

ÖKSÜRÜK AKUSTİK SINYALLERİNDE GELENEKSEL VE DERİN ÖZNİTELİKLER YARDIMIYLA COVID-19 TESPİTİ

Yunus Emre ERDOĞAN

Zonguldak Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Ali NARİN

Temmuz 2022, 79 sayfa

Milyonlarca insanın muzdarip olduğu COVID-19 salgını kısa sürede tüm dünyayı etkisi altına aldı. Bulaşma oranı yüksek olan bu virüs, insanların solunum sistemini doğrudan etkiliyor. Nefes almada zorluk, öksürük, ateş gibi belirtiler sık görülürken, ileri durumlarda hastaneye yatış ve ölümcül sonuçlar görülebilir. Bu nedenle salgınla mücadelede en önemli konu COVID-19(+) erken tespit etmek ve COVID-19(+) olanları diğer insanlardan izole etmektir. RT-PCR testinin yanı sıra görüntüleme yöntemleri ile COVID-19(+) olanlar tespit edilebiliyor. Tezde önemli semptomlardan biri olan öksürük akustik verileri ile COVID-19(+) hastalarının tespit edilmesi amaçlandı. Bu verilere dayanarak, deneysel mod ayrıştırma (DMA) ve ayrık dalgacık dönüşümü (ADD) kullanılarak geleneksel öznelik çıkarma yöntemlerinden öznelikler elde edilmiştir. Önceden eğitilmiş ResNet50 ve önceden eğitilmiş MobileNet modelleri kullanılarak derin öznelikler elde edildi. Elde edilen tüm özneliklere ReliefF algoritması ile öznelik seçimi uygulanmıştır. Bu durumda en yüksek doğruluk değeri %98,4 ve F1-skoru değeri %98,6 olarak saptanmıştır. Derin özneliklerin kullanıldığı diğer çalışmada ise skalogram görüntüleri

ÖZET (devam ediyor)

kullanılarak ResNet50 ve MobileNet'ten elde edilen öznitelikler kullanılmıştır. Seçilen öznitelikler için ReliefF algoritması kullanılarak en yüksek performans %97,8 doğruluk ve %98,0 F1 skoru olarak destek vektör makineleri-küçük ile bulunmuştur. Geleneksel öznitelik yaklaşımları ile elde edilen özniteliklerin derin özniteliklere göre daha yüksek performans gösterdiği tespit edilmiştir. Lineer olmayan ölçümler arasında en fazla ayırt edici özelliğin yaklaşık entropi ölçümü olduğu belirlendi. Sonuçlara göre mobil ve bilgisayar tabanlı uygulamalardan kolaylıkla elde edilebilen öksürük akustik verileri ile oldukça başarılı bir çalışma sunulmaktadır. Bir kişinin bile doğru tespit edilmesinin önemli olduğu bu salgın döneminde bu çalışmanın bir karar destek sistemi olarak faydalı olacağını tahmin ediyoruz.

Anahtar Kelimeler: COVID-19, öksürük, derin öznitelikler, deneysel mod ayrıştırma, ayırık dalgacık dönüşümü, ReliefF.

Bilim Kodu: 608.03.0

ABSTRACT

Msc. Thesis

COVID-19 DETECTION WITH TRADITIONAL AND DEEP FEATURES ON COUGH ACOUSTIC SIGNALS

Yunus Emre ERDOĞAN

**Zonguldak Bülent Ecevit University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering**

Thesis Advisor: Assist. Prof. Dr. Ali NARİN

July 2022, 79 pages

The COVID-19 epidemic, in which millions of people suffer, has affected the whole world in a short time. This virus, which has a high rate of transmission, directly affects the respiratory system of people. While symptoms such as difficulty in breathing, cough, and fever are common, hospitalization and fatal consequences can be seen in progressive situations. For this reason, the most important issue in combating the epidemic is to detect COVID-19(+) early and isolate those with COVID-19(+) from other people. In addition to the RT-PCR test, those with COVID-19(+) can be detected with imaging methods. In this study, it was aimed to detect COVID-19(+) patients with cough acoustic data, which is one of the important symptoms. Based on these data, features were obtained from traditional feature extraction methods using empirical mode decomposition (EMD) and discrete wavelet transform (DWT). Deep features were also obtained using pre-trained ResNet50 and pre-trained MobileNet models. Feature selection was applied to all obtained features with the ReliefF algorithm. In this case, the highest 98.4% accuracy and 98.6% F1-score values were obtained by selecting the EMD + DWT

ABSTRACT (continued)

features using ReliefF. In another study in which deep features were used, features obtained from ResNet50 and MobileNet using scalogram images were used. For the features selected using the ReliefF algorithm, the highest performance was found with support vector machines-cubic as 97.8% accuracy and 98.0% F1-score. It has been determined that the features obtained by traditional feature approaches show higher performance than deep features. Among the chaotic measurements, the approximate entropy measurement was determined to be the highest distinguishing feature. According to the results, a highly successful study is presented with cough acoustic data that can easily be obtained from mobile and computer-based applications. We anticipate that this study will be useful as a decision support system in this epidemic period, when it is important to correctly identify even one person.

Keywords: COVID-19, Cough, Deep features, Empirical mode decomposition, Discrete wavelet transform, ReliefF.

Science Code: 608.03.00

TEŐEKKÜR

Tez alıŐmamn DanıŐmanı olan Dr. Öğr. Üyesi Ali NARİN hocama alıŐmamn her anında bana verdiĐi katkılardan ve desteklerden ötürü teŐekkür ederim.

Ayrıca beni yetiŐtiren, hayatımın her anında yanımda olan anneme ve babama teŐekkür ederim.





İÇİNDEKİLER

KABUL	ii
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ	xv
SİMGELER VE KISALTMALAR DİZİNİ.....	xvii
BÖLÜM 1 GİRİŞ	1
BÖLÜM 2 SOLUNUM SİSTEMİ	5
2.1 GİRTLAK VE SOLUNUM SİSTEMİ	5
2.2 ÖKSÜRÜĞÜN OLUŞUMU.....	7
2.3 COVID-19'UN ÖKSÜRÜĞE ETKİLERİ.....	8
BÖLÜM 3 LİTERATÜR	9
3.1 BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİ	9
3.2 X-RAY GÖRÜNTÜLERİ	12
3.3 ÖKSÜRÜK AKUSTİK SESLERİ.....	15
BÖLÜM 4 ÖRÜNTÜ TANIMA YÖNTEMLERİ.....	21
4.1 ÖKSÜRÜK AKUSTİK SESİ VERİLERİNİN ELDE EDİLİŞİ.....	22
4.2 ÖKSÜRÜK AKUSTİK SESİ VERİLERİNDE ÖNİŞLEMLER.....	23

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
4.2.1 Verilerin Normalize Edilmesi.....	24
4.2.1.1 Z-skor Normalizasyon.....	24
4.2.1.2 Min-Max Normalizasyon.....	24
4.3 ÖZİNİTELİK ÇIKARIMI.....	25
4.3.1 Deneysel Mod Ayrıştırma.....	25
4.3.2 Ayrık Dalgacık Dönüşümü.....	28
4.4 SKALOGRAM.....	31
4.4.1 Skalogram Görüntüleri Elde Etme.....	32
4.5 DERİN ÖZİNİTELİK ÇIKARIMI.....	33
4.5.1 Derin Öğrenme.....	33
4.5.2 Konvolüsyonel Sinir Ağları (KSA).....	34
4.5.3 Konvolüsyon Katmanı.....	34
4.5.4 Havuzlama Katmanı.....	37
4.5.5 Tam-Bağlı Katman.....	38
4.5.6 Hiper Parametre Ayarlamaları ve Seçimleri.....	38
4.5.7 Aktivasyon Fonksiyonları.....	39
4.5.8 Mini-Batch Boyutu.....	40
4.5.9 Eğitim Tur Sayısı.....	41
4.5.10 Öğrenme Hızı.....	41
4.6 DERİN ÖĞRENME MODELLERİ.....	42
4.6.1 ResNet50.....	42
4.6.2 MOBILENET.....	43
4.6.3 KSA'NIN EĞİTİLMESİ.....	45
4.7 ÖZİNİTELİK SEÇİMİ.....	46
4.7.1 ReliefF Algoritması ile Öznitelik Seçimi.....	46
4.8 SINIFLANDIRMA ALGORİTMALARI.....	47
4.8.1 K-En Yakın Komşu (K-nn).....	47
4.8.2 Destek Vektör Makinaları.....	48

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
4.8.3 Doğrusal Ayraç Analizi.....	49
4.8.4 Lojistik Regresyon.....	50
4.8.5 Toplu Torbalı Ağaçlar.....	50
BÖLÜM 5 PERFORMANS ÖLÇÜTLERİ.....	51
BÖLÜM 6 DENEYSEL SONUÇLAR	53
6.1 NORMALİZASYON YÖNTEMLERİNİN COVID-19 TAHMİN PERFORMANSLARININ ÖKSÜRÜK AKUSTİK SESLERİ ÜZERİNDE KARŞILAŞTIRILMASI	55
6.1.1 Veri Seti.....	55
6.1.2 Sonuçlar	56
6.2 ÖKSÜRÜK AKUSTİK SİNYALLERİNİ KULLANARAK COVID 19 TESPİTİ İÇİN SINIFLANDIRMA ALGORİTMALARININ KARŞILAŞTIRILMASI	57
6.2.1 Veri Seti	58
6.2.2 Sonuçlar	58
6.3 ÖKSÜRÜK AKUSTİK SİNYALLERİNDE GELENEKSEL VE DERİN ÖZELLİKLERLE COVID-19 TESPİTİ	61
6.3.1 Veri Seti.....	61
6.3.2 Sonuçlar	61
BÖLÜM 7 TARTIŞMA	67
KAYNAKLAR.....	69
ÖZGEÇMİŞ..	79



ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Şekil 2.1 Akciğerlerin yapısı ve solunum sistemi gösterimi.....	7
Şekil 4.1 Genel bir örüntü tanıma sistemi akış şeması.....	21
Şekil 4.2 COVID-19(-) kişilere ait öksürük sesi sinyali gösterimi	22
Şekil 4.3 COVID-19(-) kişilere ait öksürük sesi sinyali gösterimi.	23
Şekil 4.4 COVID-19(+) ve COVID-19(-) akustik öksürük verileri ve beş seviyeli İMF sinyalleri	27
Şekil 4.5 Beş seviyeli dalgacık dönüşümü gösterimi.....	29
Şekil 4.6 Coiflets dalgacık (ii) Daubechies dalgacık (iii) Meyer dalgacık (iv) Symlets dalgacık (v) Morlet dalgacık (vi) Mexican dalgacık.....	30
Şekil 4.7 COVID-19(+) ve COVID-19(-) öksürük verileri ve beş seviyeli ADD katsayıları.	31
Şekil 4.8 Bir boyutlu öksürük sinyalleri üzerinden elde edilen iki boyutlu skalogram görüntüleri a) COVID-19(+) için b) COVID-19(-) için.....	32
Şekil 4.9 Konvolüsyon İşlemi.....	36
Şekil 4.10 Konvolüsyon Katmanı.	37
Şekil 4.11 Havuzlama Örneği	38
Şekil 4.12 ReLU aktivasyon fonksiyonu gösterimi	39
Şekil 4.13 Sigmoid aktivasyon fonksiyonu gösterimi.....	40
Şekil 4.14 Ön Eğitimli ResNet50 Modelinin Gösterimi... ..	43
Şekil 4.15 Ön Eğitimli MobileNet Modelinin Gösterimi.....	44
Şekil 4.16 Bazı katmanlardaki girdi örnek görüntüsünün çıktıları.....	45
Şekil 4.17 K-nn sınıflandırıcısının k=3 en yakın değeri için örnek gösterimi.....	47
Şekil 4.18 DVM destek vektörleri ve optimum hiperdüzlem.....	49
Şekil 5.1 Beş Katlı Çapraz Doğrulama Yöntemin grafiksel gösterimi.....	52
Şekil 6.1 Min-maks normalizasyona dayalı en yüksek performanslı hata matrisi.....	56
Şekil 6.2 Z normalizasyona dayalı en yüksek performanslı hata matrisi.	57

ŞEKİLLER DİZİNİ (devam ediyor)

- Şekil 6.3 Sınıflandırma yöntemlerine ait hata matrisleri a) Orta K-nn b) Lojistik Regresyon c) Lineer DVM d) Lineer Diskriminant e) Torbalı Ağaçlar (0, COVID-19(-), 1, COVID-19(+))..... 60
- Şekil 6.4 DMA (üst) ve ADD (alt) için yüksek ayırt ediciliğe sahip özniteliklerin kutu grafiği gösterimi ($p < 0,001$). 63
- Şekil 6.5 En yüksek performanslara ait hata matrisleri a) geleneksel özniteliklerden b) derin özniteliklerden. (0, COVID-19(-), 1, COVID-19(+))..... 65



ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 3.1 Literatürde Bilgisayarlı Tömografi görüntüleri kullanılarak COVID-19 tespiti. (ACC,doğruluk, Spe, özgüllük, Rec, Hatırlama, F1, F1 skoru).....	11
Çizelge 3.2 Literatürde X-Ray görüntüleri kullanılarak COVID-19 tespiti (ACC, doğruluk, Spe, özgüllük, Rec, Hatırlama, F1, F1 skoru).....	14
Çizelge 3.3 Literatürde öksürük akustik sinyallerini kullanılarak COVID-19 tespiti (ACC, doğruluk, Spe, özgüllük, Rec, Hatırlama, F1, F1 skoru)..	17
Çizelge 4.1 Tezde yararlanılan veri sayıları.....	22
Çizelge 4.2 İMF sinyallerinden elde edilen özniteliklerin açıklaması.....	27
Çizelge 4.3 ADD sinyallerinden elde edilen özniteliklerin açıklaması.....	30
Çizelge 5.1 Hata Matrisi.....	51
Çizelge 6.1 Bildiride yararlanılan veri sayıları... ..	56
Çizelge 6.2 Çalışmada kullanılan veri sayıları.....	58
Çizelge 6.3 DMA tabanlı öznitelikler için sınıflandırma yöntemlerinin karşılaştırması.	59
Çizelge 6.4 Makalede kullanılan veri sayıları.....	61
Çizelge 6.5 Tüm DMA ve tüm ADD tabanlı özniteliklerin ve ReliefF algoritması ile seçilen özniteliklerin performans karşılaştırması. Sol sütundaki performanslar tüm özniteliklerden seçilen, sağ sütundaki performanslar ReliefF tarafından seçilen özniteliklerdir. (Acc, doğruluk, Rec, hatırlama, Spe, özgüllük, Pre, kesinlik, F1, F1-skoru).....	62
Çizelge 6.6 ReliefF algoritması ile seçilen derin öznitelikler ile derin özniteliklerin performans karşılaştırması. Sol sütundaki performansların tümü derin özniteliklerdir, sağ sütundaki performanslar ReliefF tarafından seçilen derin özniteliklerdir. (Acc, doğruluk, Rec, hatırlama, Spe, özgüllük, Ön, kesinlik, F1, F1-skor).....	64



SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

k	: Komşu sayısı
p	: İstatistiksel olasılık değeri
t_n	: n. zaman dilimi
w	: Ağırlık değeri
X_k	: k-inci öznitelik normalize edilecek girdi verisi
μ_k	: k-inci Ortalama
STD_k	: k-inci Standart Sapmasını

KISALTMALAR

ACC	: Genel başarıml
K-nn	: K-en yakın komşu
LDA	: Lineer ayraç analizi
PCA	: Temel Bileşen Analizi
RF	: Rastgele Orman
NEG	: Negatif seçicilik
POS	: Pozitif seçicilik
SEN	: Hassaslık
SPE	: Seçicilik
DVM	: Destek Vektör Makinaları
ADD	: Ayrık Dalgacık Dönüşümü
DMA	: Deneysel Mod Ayırıştırma
BT	: Bilgisayarlı Tömografi
DSÖ	: Dünya Sağlık Örgütü
RT-PCR	: Ters Transkripsiyon Polimeraz Zincir Reaksiyonu
1B	: 1 Boyutlu

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

2B	: 2 Boyutlu
3B	: 3 Boyutlu
F1	: F1 Skoru
MFCCs	: Mel frekansı sepstral katsayıları
KSA	: Konvolüsyonel Sinir Ağı
RQA	: Nüks nicemleme analizi
XGBoost	: Gradyan Artırıcı
DSA	: Derin Sinir Ağları
DA	: Derinlemesine Ayrıştırılabilir
X-Ray	: Göğüs Röntgeni
ACE-2	: Anjiyotensin Dönüştürücü Enzim 2
DL	: Derin Öğrenme
TL	: Transfer Öğrenmesi
IR(ME)R	: İyonize Radyasyon (Tıbbi Maruziyet) Yönetmelikleri
CXR	: Göğüs Radyografisi
İMF	: İç Mod Fonksiyonları
BN	: Batch Normalizasyonu
SDD	: Sürekli Dalgacık Dönüşümü
SC	: Spektral merkez
SR	: Spektral Yuvarlanma
ZCR	: Sıfır Geçiş Oranı
LTSM	: Uzun Kısa Süreli Bellek
HP	: Yüksek Değişken
MB	: Mini Batch
ÇKA	: Çok Katmanlı Ağ
DD	: Dalgacık Dönüşüm
ARDS	: Akut Solunum Sıkıntısı Sendromu

BÖLÜM 1

GİRİŞ

Koronavirüsler 1960'ların ortalarında tanımlandı ve insanları ve kuşlar ve memeliler dâhil diğer hayvanları enfekte ettiği biliniyordu. Solunum ve gastrointestinal sistemdeki epitel hücreleri koronavirüslerin birincil hedef hücrelerdir. Bu karakterlerinden dolayı viral bulaşma bu sistemler aracılığıyla gerçekleşebilir. Bugüne kadar, yedi tip koronavirüsün insanları enfekte ettiği ifade edilmiştir. Yaygın insan koronavirüsleri Betacoronavirus HCoV-OC43 ve HCoV-HKU1'in yanı sıra Alphacoronavirus HCoV-229E, bebeklerde ve yaşlılarda soğuk algınlığına ve ciddi alt solunum yolu enfeksiyonlarına neden olur, Alphacoronavirus HCoV-NL63 ise çocuklarda krup ve bronşiyolitinin önemli bir nedeni olarak bilinir [1]. Yeni zoonotik koronavirüsler ortaya çıkmış ve insanlarda salgınlara neden olmuştur; SARS-CoV (2002, Betacoronavirus, Sarbecovirus alt türü) ve MERS-CoV (2012, Betacoronavirus, Merbecovirus alt türü). 2019'un sonlarında, Çin'in Wuhan kentinde (2019-nCoV) bir dizi pnömoni vakasıyla ilgili yeni bir koronavirüs tespit edildi. Bundan sonra hastalık COVID-19 olarak tasarlandı. SARS-CoV-2, SARS-CoV ile yakından ilişkilidir ve genetik olarak Betacoronavirus alt türü Sarbecovirus içinde kümelenir [1]. Li ve meslektaşları tarafından yapılan erken bir çalışma, toplam 425 hastanın en yüksek vaka sayısının %55'inin Deniz Ürünleri Toptan Satış Pazarı öyküsü olduğunu bildirdi. Ayrıca hastaların %56'sı erkekti ve ortalama kuluçka süresi 5.2 gündü. Farklı türlerde vahşi (yılan ve dağ sıçanı) ve evcilleştirilmiş (kümes hayvanları ve yarasa) hayvanların yasa dışı olarak satıldığı Wuhan'da birçok deniz ürünleri pazarı bulunmaktadır. Böylece hastalığın hayvanlardan insanlara bulaşabileceği öne sürülmüştür. Şimdiye kadar, SARS-CoV-2'nin kaynağının ne olduğu ve rezervuarı henüz açıkça bulunamamıştır.

COVID-19 salgını sırasında, Deniz Ürünleri Toptancı Hali'nden dört kişinin COVID-19 şüphelisi olarak bildirilmesinden sonra daha önce bulaşmalar hayvanlardan olsa da, diğer tüm bulaşmaların insandan insana olduğuna inanılmaktadır. Bu iletim şekli o kadar aktifti ki birkaç gün içinde diğer ülkelere yayılmaya başladı. 19 Ocak 2020 ile 22 Ocak 2020 tarihleri arasında bir Çinli Almanya'yı ziyaret etmişti. Almanya'da kaldığı süre boyunca hiçbir COVID-19 belirti

ve semptomu göstermedi, ancak 26 Ocak 2020'de Çin'e döndükten sonra testi pozitif çıktı. 24 Ocak 2020'de 33 yaşında bir Alman işadamı hastalandı ve doktora başvurdu. Hasta öyküsü, 20 ve 21 Ocak 2020'de Çinli bir iş ortağıyla görüşmesi olduğunu gösterdi. Daha sonra 28 Ocak 2020'de şirkette başka üç çalışanda COVID-19 pozitif bulundu. Son salgında, kitlelerin hareketinin payını artırdığı Çin'deki yıllık kutlamalar nedeniyle insanlardan insanlara bulaşma çok hızlı arttı. İnsandan insana bulaşma birkaç şekilde olabilir. Öksürük veya hapşırma, toplu taşıma yüzeylerine dokunma, restoranlar ve diğer halka açık yerlerden (tuvaletler, asansörler, otobüs durakları) gelen damlacıklar yoluyla olabilir. Geçmişte diğer zoonotik koşullarda [2] meydana geldiği gibi, yeni bir koronavirüs olan SARS-CoV-2'nin yayılmasının durdurulması büyük önem kazandı. Yarasalardan kaynaklanan SARS-CoV ve MERS-CoV gibi mevcut ve önceki koronavirüsler, gelecekte Çin'de ve yurtdışında yeni salgın hastalıklarla ilgili endişelerle birlikte hayvanlar ve insanlar arasındaki etkileşimde bir endişe kaynağı meydana getirmektedir.

Dünya Sağlık Örgütü (DSÖ), hızlı yayılımı ve bulaşıcılık düzeyini göz önünde bulundurarak COVID-19 salgınına pandemi olarak ilan etti. DSÖ tarafından pandemi olarak ilan edilen yeni koronavirüs hastalığı ilk olarak Çin'in Wuhan kentinde ortaya çıktı. Kısa sürede Çin'e ve dünyanın diğer ülkelerine yayıldı [3,4]. COVID-19'a neden olan bir etken henüz tanımlanmadı, ancak virüs etiolojisi bilinmeyen bir pnömoni formu olarak belirtildi [5]. Bu patojen solunum sistemini hedef almaktadır ve bulaşma solunum damlacıkları veya aerosol emisyonları yoluyla gerçekleşmektedir.

Halk arasında COVID-19 olarak bilinen salgına neden olan virüsün adı, şiddetli akut solunum sendromu koronavirüs-2'dir (SARS-CoV-2) [6]. Bu virüs, yüksek seviyede ölüm oranlarına sahip hayati solunum yolu enfeksiyonlarına sebebiyet vermekte ve insanlar için önemli bir tehdit unsuru meydana getirmektedir. COVID-19 pandemisinin en çok bilinen semptomlarını şiddetli ateş, kuru öksürük ve nefes alış veriş esnasında çekilen zorluk oluşturmaktadır [7]. Ayrıca bel ağrısı, halsizlik, ishal, mide bulantısı, baş ağrısı ve baş dönmesi gibi belirtilerde de görüldüğü bilinmektedir [8]. Akut Solunum Sıkıntısı Sendromu (ARDS), ağır hastalığı olan kişilerde bir süre sonra ortaya çıkabilir. Tüm bu semptomların yanı sıra COVID-19 hastalarını tespit etmek için bir dizi test yapılıyor. Altın standart olarak bilinen RT-PCR testi DSÖ'nün önerisi ile yapılmaktadır [9]. Bu test zaman alıcı, maliyetli bir testtir ve sonuçlar geç alınır [10]. Ocak-Temmuz 2020 döneminde, enfekte olmuş nüfus, kayıplarla birlikte katlanarak birikmekteydi. Virüs bulaşmış personelin miktarı ve onları tedavi etmek için ayrılan kaynaklar hükümetler için sorunlar yaratmaktaydı. Ayrıca karantina tesislerinin kurulması ve

sürdürülmesi, kaynakları parasal ve insan gücü açısından yormaktaydı. Daha da önemlisi, patojenin nedeni ve bulaşması hakkında bilgi eksikliği, enfekte olanları tedavi ederken sağlık görevlilerinin önemini ortaya çıkarmaktaydı. Bu nedenle COVID-19, sağlık hizmetlerinin geleceğini teknolojik katılımı ile temassız tedavi stratejilerine yönlendiriyordu. Bu nedenle COVID-19 hastalarını tespit etmek için bu teste ek olarak tıbbi görüntüleme yöntemleri kullanılmaktadır [11]. Bunlar arasında en çok kullanılanları bilgisayarlı tomografi (BT) ve akciğer grafisi (X-ray) görüntüleridir. Diğer bir yardımcı yöntem, solunum sistemi tarafından üretilen öksürük akustik seslerinin analizine dayanan yaklaşımlardır [12]. Literatürde COVID-19 tespitinde BT ve röntgen görüntülerinin kullanıldığı birçok çalışma bulunmaktadır [13,14]. Doğrudan veriler üzerinde çalışabilen derin öğrenme teknikleri yaygın olarak kullanılmaktadır [15,16]. Bu çalışmalarda son teknoloji modeller sıklıkla kullanılmıştır. Bunlar, önceden eğitilmiş modelleri ve bol miktarda transfer öğrenme modellerini içerir. Derin öznitelik çıkarımı olarak adlandırılan başka bir yaklaşımla yapılmış birçok çalışma vardır [17,18]. Geleneksel öznitelik çıkarım yöntemleri, COVID-19 hastalarını tespit etmede en çok kullanılan yöntemler arasındadır [19,20].



BÖLÜM 2

SOLUNUM SİSTEMİ

2.1 GİRTLAK VE SOLUNUM SİSTEMİ

Solunum sistemi, nefes almaya destek olan organ ve doku ağının bütününe verilen isimdir. Hava yolları, akciğerler ve kan damarlarını muhteviyatında barındırır. Akciğerlere kuvvet veren adaleler de solunum sisteminin muhteviyatında yer alan parçalardan biridir. Bu parçalar, oksijeni vücutta dolaştırmak ve karbondioksit gibi atık gazları vücuttan uzaklaştırmak amacıyla beraber çalışırlar.

Solunum sisteminin birçok işlevi vardır. Nefes almaya ve nefes vermeye yardımcı olmanın yanı sıra konuşmayı ve koku almayı sağlar. Havayı vücut sıcaklığına göre ısıtır ve havayı vücudun ihtiyaç duyduğu nem seviyesine kadar nemlendirir. Vücuttaki hücrelere oksijen sağlar. Nefes verirken vücudu karbondioksit de dâhil olmak üzere atık gazlardan temizler. Hava yollarını zararlı maddelerden ve tahriş edici maddelerden korur.

Solunum sistemi, nefes almaya yardımcı olmak amacıyla birlikte çalışan birçok farklı bölümü muhteviyatında barındırır [21]. Her kısım grubunun pek çok muhtelif bileşeni vardır. Hava yolları havayı ciğerlere iletir. Hava yolları muhteviyatında ağız ve burnu, sinüsleri, boğazı(farenks), trakeayı, bronş tüplerini ve akciğerleri barındıran karmaşık bir sistemdir. Bu bölümler sırasıyla şöyledir:

Ağız ve burun: Vücudun dışındaki havayı solunum sistemine çeken açıklıklar.

Sinüsler: Solunan havanın sıcaklığını ve nemini düzenlemeye yardımcı olan kafadaki kemikler arasındaki boşluklar.

Farenks (boğaz): Ağızdan ve burundan gelen havayı soluk borusuna (soluk borusu) ileten tüp.

Trakea: Boğazı ve ciğerleri birbirine bağlayan geçit.

Bronş tüpleri: Her bir akciğere bağlanan nefes borusunun altındaki tüpler.


Akciğerler: Havadaki oksijeni alıp kana ileten iki organ.

Akciğerler kan dolaşımı sırasında tüm organlara ve diğer dokulara oksijen verir. Kaslar ve kemikler, solunan havanın akciğerlere girip çıkmasına yardımcı olur. Solunum sistemindeki bazı kaslar ve kemikler diyafram ve kaburgalardır. Diyafram akciğerlerin havayı çekmesine ve dışarı itmesine yardımcı olan kastır. Kaburgalar ise Akciğerleri ve kalbi çevreleyen ve koruyan kemiklerdir. Nefes verildiğinde, kan karbondioksit ve diğer atıkları vücuttan dışarı taşır. Akciğerler ve kan damarları ile çalışan diğer bileşenler arasında alveoller, bronşiyoller, kılcak damarlar, akciğer lobları, plevra bulunur. Alveoller akciğerlerde oksijen ve karbondioksit değişiminin gerçekleştiği küçük hava kesecikleridir. Bronşiyoller bronş tüplerinin alveollere giden küçük dallarıdır. Kılcak damarlar alveol duvarlarındaki oksijen ve karbondioksiti hareket ettiren kan damarlarıdır. Akciğer lobları akciğerin bölümleridir. Sağ akciğerde üç lob ve sol akciğerde iki lob bulunur. Plevra ise her bir akciğer lobunu çevreleyen ve akciğerlerinizi göğüs duvarından ayıran ince keseciklerdir.

Solunum sisteminizin diğer bileşenlerinden bazıları arasında kirpikler, epiglot, gırtlak (larenks) bulunur. Kirpikler hava yollarındaki tozu ve diğer tahriş edici maddeleri filtrelemek için dalga benzeri bir hareketle hareket eden küçük tüyledir. Epiglot nefes borusunun girişinde, yutma işlemi gerçekleştiğinde yiyecek ve sıvıları solunum yolunuzdan uzak tutmak için kapanan doku kanadı. Gırtlak ise hava içeri ve dışarı hareket ettiğinde konuşmayı ve ses çıkarmayı sağlayan içi boş organdır.

Birçok durum solunum sistemini oluşturan organ ve dokuları etkileyebilir. Bazıları, enfeksiyona neden olan virüsler veya bakteriler de dâhil olmak üzere havadan soluduğunuz tahriş edici maddeler nedeniyle gelişir [22]. Diğerleri hastalık veya yaşlanmanın bir sonucu olarak ortaya çıkar. Enflamasyona (şişme, tahriş ve ağrı) neden olabilecek veya solunum sistemini başka şekilde etkileyebilecek durumlar şunları içerir. Toz, küf ve polen gibi proteinlerin solunması bazı kişilerde solunum yolu alerjilerine neden olabilir. Bu proteinler solunum yollarında iltihaplanmaya neden olabilir. Kronik (uzun süreli) bir hastalık olan astım, solunum yollarında nefes almayı zorlaştıran iltihaplanmaya neden olabilir. Enfeksiyonlar

pnömoniye (akciğer iltihabı) veya bronşite yol açabilir. Yaygın solunum yolu enfeksiyonları arasında grip (grip) veya soğuk algınlığı bulunur. Solunum bozuklukları arasında akciğer kanseri ve kronik obstrüktif akciğer hastalığı (KOAH) bulunur. Bu hastalıklar, solunum sisteminin vücuda oksijen verme ve atık gazları filtreleme yeteneğine zarar verebilir. Yaşlandıkça akciğer kapasitesi azalır. Solunum sisteminin hasar görmesi solunum problemlerine neden olabilir. Akciğerlerin yapısı ve solunum sistemi gösterimi Şekil 2.1'de gösterilmiştir.



Şekil 2.1 Akciğerlerin yapısı ve solunum sistemi gösterimi.

2.2 ÖKSÜRÜĞÜN OLUŞUMU

Öksürük, boğazınızı mukus veya yabancı tahriş edici maddelerden temizleyen yaygın bir refleks eylemidir [23]. Herkes zaman zaman boğazını temizlemek için öksürürken, bir takım koşullar daha sık öksürüğe neden olabilir. Üç haftadan kısa süren öksürük akut öksürüktür. Çoğu öksürük nöbeti iki hafta içinde düzeler veya en azından önemli ölçüde iyileşir.

Öksürüğe hem geçici hem de kalıcı olmak üzere çeşitli koşullar neden olabilir. Öksürüğün en yaygın nedeni, soğuk algınlığı veya grip gibi bir solunum yolu enfeksiyonudur. Solunum yolu enfeksiyonlarına genellikle bir virüs neden olur ve birkaç günden bir haftaya kadar sürebilir. Gripten kaynaklanan enfeksiyonların temizlenmesi biraz daha uzun sürebilir ve bazen antibiyotik gerektirebilir. Sigara içmenin neden olduğu öksürük, neredeyse her zaman belirgin bir sese sahip kronik bir öksürüktür. Genellikle sigara içenlerin öksürüğü olarak bilinir. Küçük

çocuklarda öksürüğün yaygın bir nedeni astımdır. Tipik olarak, astımlı öksürük, hırıltıyı içerir ve bu da tanımlanmasını kolaylaştırır. Yüksek tansiyon ve kalp rahatsızlıklarını tedavi etmek için yaygın olarak kullanılan anjiyotensin dönüştürücü enzim (ACE) inhibitörleri öksürüğe neden olabilir. Ayrıca öksürük COVID-19 belirtileri içinde önde gelen bir semptomdur.

2.3 COVID-19'UN ÖKSÜRÜĞE ETKİLERİ

COVID-19 ile ilişkili öksürüğün hastalığın erken evrelerinde kuru olduğu bildirilmiştir [24,25]. Ancak daha yakın zamanlarda, hastalık akciğerleri etkilemeye başladıkça öksürüğün daha ıslak hale geldiği belirtilmiştir [26].

Patofizyolojik açıdan, her iki öksürük olayının sunumu açıklanabilir. Bir kişi COVID-19 virüsüne maruz kaldığında, sistemine mukus zarı veya kan yoluyla girer [27]. Virüs daha sonra vücut hücrelerine girmek için anjiyotensin dönüştürücü enzim 2 (ACE-2) reseptörünü kullanır [27]. ACE-2 reseptörünün COVID-19 virüsü tarafından kullanılması nedeniyle inhibisyonu, vücutta kalp rahatsızlıklarını tedavi etmek için ACE-Inhibitörleri alan bireylerle benzer bir reaksiyona sahiptir [26]. Bu ilaçları kullanan hastaların çok azında kronik kuru öksürüğe neden olan immün olmayan B tipi aşırı duyarlılık reaksiyonu olduğu bildirilmiştir [28].

Virüs bir hücreye girdiğinde, vücuttaki ACE-2 reseptörleri ile diğer hücrelere bağlanmak için paketlenen ve salınan daha fazla viral protein ve viral RNA oluşturur [27]. Virüs akciğerleri etkilediğinde, vücut o bölgeye nötrofiller (beyaz kan hücreleri) gönderecek ve reaktif oksijen türlerini ve sitokinleri serbest bırakacaktır [27]. Beyaz kan hücrelerinin bu birikmesi inflamatuvar bir yanıttır ve şiddetine bağlı olarak balgam üretimine yol açarak onu ıslak bir öksürük haline getirebilir [29]. Balgamın içeriğine bağlı olarak, akciğer dokusunun (kan) tahribatı ve ikincil bakteri enfeksiyonu da olabilir [30].

Kuru öksürükten ıslak öksürüğe bu olası geçiş, semptom olarak öksürüğü olan hastalıklar arasında dikkat çekicidir. Bu nedenle COVID-19 pozitif bireyler arasındaki öksürük progresyonu, COVID-19'lu herkes üretken öksürük olaylarıyla ilişkili olabilecek daha şiddetli reaksiyon göstermeyeceğinden tanı ve hastalık progresyonu hakkında fikir verebilir. Öksürüğün ilerlemesi, hastalığın ilerlemesinin ve kötüleşmesinin klinik bir göstergesidir [31]. Ses kayıtlarından öksürük tespiti, özellikle mevcut fiziksel mesafe döneminde tıp uzmanlarını destekleyebilecek, büyüyen bir araştırma alanıdır.

BÖLÜM 3

LİTERATÜR

Çeşitli çalışmalar [32–34], çeşitli görüntüleme yöntemlerinde hastalık tespit sürecini hızlandırmak için bilgisayarlı görme algoritmalarını kullanmıştır. Bazı başka çalışmalar ise, görüntü analiz tekniklerinin uzman radyologlardan daha iyi performans gösterme potansiyeline sahip olduğunu göstermiştir [35,36]. COVID-19'u teşhis etmek için, aşağıda tartışacağımız iki tıbbi görüntüleme yöntemi bilgisayarlı tomografi (BT) ve akciğer grafisi (X-ray) denenmiştir. Ayrıca ses analiz yöntemlerinden ise öksürük seslerinden COVID-19 tespiti denenmiştir.

3.1 BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİ

Son araştırmalarda radyologlar, göğüs BT taramalarını kullanarak COVID-19'un teşhis edilebileceğini öne sürmüşlerdir [37,38]. Tanı sürecini hızlandırmak için BT taramalarıyla ilgili birçok derin öğrenme (DL) tekniği önerilmiştir. Wang ve ark. [39], COVID-19 hastalarındaki radyografik değişiklikleri saptamak için DL yöntemlerini kullandılar. Patojenle doğrulanmış COVID-19 vakalarının BT taramalarında önerilen modeli değerlendirdiler ve DL'nin COVID-19 teşhisine uygun radyolojik özellikleri çıkarabildiğini gösterirler. InceptionNet modeliyle 1065 veri kullanarak %89,5 oranında bir genel başarıma ulaştılar. Xiaowei ve ark. [40], konum odaklı bir 3B DL modeli kullanarak pulmoner BT taramalarında COVID-19'un otomatik olarak taranması için bir yöntem sundu. Diğer iyi bilinen enfeksiyonlardan COVID-19 bulaşmış hasta taramalarını belirlemek için umut verici bir doğruluk elde ettiler. Rastgele İlgi Bölgesinde InceptionNet modeliyle 618 veri kullanarak %86,7 oranında bir genel başarıma ulaştılar. Chen ve ark. [41], BT taramalarında şüpheli lezyonları saptamak için UNet++ mimarisini [42] kullandılar. UNet++ modeliyle 35355 veri kullanarak %95,24 oranında bir genel başarıma ulaştılar. Ophir ve ark. [43] Coronascore'u (akciğerlerdeki hastalığın evrimini temsil eden) hesaplamak için 2B ve 3B evrişimli sinir

ağlarını kullandılar. 2B KSA ile her bir BT taraması diliminde virüsün varlığını tahmin etmeye çalıştılar ve bir 3B KSA kullanarak diğer akciğer hastalıklarını tespit ettiler. 2B + 3B KSA modeliyle 107 veri kullanarak %98,2 oranında bir genel başarıma ulaştılar. Benzer şekilde Lin ve ark. [44]'de, COVID-19'un tespiti için hacimsel göğüs BT incelemelerinden görsel özellikler çıkarmak için bir sinir ağı (COVNet) geliştirilmiştir. Çalışma, DL tabanlı modellerin COVID-19'u doğru bir şekilde tespit edebileceğini ve onu toplum kökenli pnömoni ve diğer akciğer hastalıklarından ayırt edebileceğini ileri sürüyor. COVNet modeliyle 4356 veri kullanarak %95 oranında bir genel başarıma ulaştılar. Shan ve ark. [45] göğüs BT taramaları üzerinden oluşturdukları DSA modeliyle 549 veri üzerinden %91,6 oranında bir genel başarıma ulaştılar. Zhang ve ark. [46] göğüs BT taramaları üzerinden oluşturdukları DenseNet modeliyle 1531 veri üzerinden %95,18 oranında bir genel başarıma ulaştılar. Mucahid ve ark. [47]] göğüs BT taramaları üzerinden oluşturdukları geleneksel öznitelik çıkarma teknikleri modeli ve DVM sınıflandırıcısıyla 150 veri üzerinden %99,64 oranında bir genel başarıma ulaştılar. Zhao ve ark. [48] CSSL+TL göğüs BT taramaları üzerinden oluşturdukları CSSL+TL modeliyle 349 veri üzerinden %89 oranında bir genel başarıma ulaştılar. Gozes ve ark. [49] göğüs BT taramaları üzerinden oluşturdukları U-Net + ResNet modeliyle 6150 veri üzerinden %99,4 oranında bir genel başarıma ulaştılar. Asnaoui ve ark. [50] göğüs BT taramaları üzerinden oluşturdukları Fine Tuning (İnce Ayar) + KSA modeliyle 5856 veri üzerinden %96,61 oranında bir genel başarıma ulaştılar. Literatürde BT görüntüleri ile COVID-19 tespitine dair çalışmalar Çizelge 3.1'de verilmiştir.

Çizelge 3.1 Literatürde Bilgisayarlı Tömografi görüntüleri kullanılarak COVID-19 tespiti. (ACC, doğruluk, Spe, özgülük, Rec, Hatırlama, F1, F1 skoru).

Yazarlar	Veri Tipi	Teknik	Veri Sayısı	Performans Sonuçları (%)
Wang ve ark. [39]	Göğüs BT taramaları	InceptionNet	1065	ACC=89,5
Xu ve ark. [40]	Göğüs BT taramaları	3B KSA	618	ACC=86,7
Chen ve ark. [41]	Göğüs BT taramaları	UNet++	35355	Sen=100 Spe=93,55 ACC=95,24
Ophir ve ark. [43]	Göğüs BT taramaları	2B + 3B KSA	107	Rec=99,6 Spe=92,2 ACC=98,2
Lin ve ark. [44]	Göğüs BT taramaları	KSA	4356	ACC=95 Sen=87 Spe=92
Shan ve ark. [45]	Göğüs BT taramaları	DSA	549	ACC=91,6
Zhang ve ark. [46]	Göğüs BT taramaları	DenseNet	1531	Sen=90 Spe=87,84 ACC=95,18
Mucahid ve ark. [47]	Göğüs BT taramaları	Geleneksel Öznitelik Çıkarma teknikleri +DVM	150	ACC=99,64 Spe=100 Pre=100 F1-Score=99,6
Zhao ve ark. [48]	Göğüs BT taramaları	CSSL+TL	349	ACC=89
Gozes ve ark. [49]	Göğüs BT taramaları	U-Net + ResNet	6150	ACC=99,4 Sen= 94 Spe=98
Asnaoui ve ark. [50]	Göğüs BT taramaları	Fine Tuning(İnce Ayar) + KSA	5856	ACC=96,61 Sen=94,92 Spe=98,43 Pre=98,49

3.2 X-RAY GÖRÜNTÜLERİ

Devam eden görüntü işleme çalışmaları BT taramaları ile sınırlı değildir. Ayrıca X-ışınları üzerinde çalışmalar yapılmıştır. BT taramalarından daha az duyarlı olmalarına rağmen, daha az invazivdirler ve daha taşınabilirler. İyonize Radyasyon (Tıbbi Maruziyet) (IR(ME)R 17) yönergelerini takiben, iyonlaştırıcı radyasyon dozu, tanısal kalitede bir görüntü üretmeye devam ederken makul olarak ulaşılabilir olduğu kadar düşük tutulmalıdır [51]. Ezz ve ark. [52], X-ray görüntülerinde COVID-19'u otomatik olarak teşhis etmek için DL tabanlı bir çerçeve (COVIDX-Net) önermektedir. COVIDX-Net, VGG19 [53] ve GoogleMobileNet [54] gibi yedi farklı (Konvolüsyonel Sinir Ağı) KSA modeli içerir. Modeller hasta durumunu COVID-19 negatif veya pozitif olarak sınıflandırabilir. Bununla birlikte, veri eksikliği nedeniyle, teknik, 25'i doğrulanmış korona hastası olmak üzere yalnızca 50 X-ışını görüntüsü üzerinde doğrulanmıştır. COVIDX-Net modeli %90 oranında bir genel başarımlı sonuç vermiştir. Linda ve ark. [55] X-ray görüntülerinden COVID-19 vakalarının tespiti için özel olarak hazırlanmış başka bir DL tabanlı çözüm tanıttı. Ayrıca COVIDx adlı bir veri seti geliştirdiler. COVID-Net ile 13975 veri üzerinden %93,3 doğruluk elde ettiler. Narin ve ark. [56]'da, üç farklı KSA tabanlı model (yani ResNet-50, Inception ve InceptionResNet), pnömoni ile enfekte hastaların röntgenlerinde COVID-19'u tespit etmek için kullandılar. Sonuçlar Narin ve arkadaşlarının %99,7 doğruluk elde ettiğini göstermektedir. Benzer şekilde, Farooq ve ark. [58], COVID-19 ile ilgili anormallikleri (COVID-ResNet olarak adlandırılır) tespit etmek için model performansını iyileştirmek için önceden eğitilmiş bir ResNet-50 [57] mimarisine ince ayar yapma adımlarını uyguladılar. 5941 adet veriyle %96,23 oranında başarıma ulaştılar. Prabira ve ark. [59] göğüs röntgenlerinden anlamlı özellikleri çıkarmak için DL'yi kullandı ve ardından enfekte hastaları tespit etmek için çıkarılan özellikleri kullanarak bir destek vektör makinesini eğitti. 381 adet veriyle %98,66 oranında başarıma ulaştılar. Abbas ve ark. [60] Transfer öğrenimi + KSA modeliyle 1764 adet veriyle %95,12 oranında başarıma ulaştılar. Chowdhury ve ark. [61] KSA + Resim Büyütme modeliyle 3487 adet veriyle %99,7 oranında başarıma ulaştılar. Alqudah ve ark. [62] KSA modeli, DVM ve RF sınıflandırıcısı ile 2479 adet veriyle %98,95 oranında başarıma ulaştılar. Goshal ve ark. [63] Bayes Konvolüsyonel Sinir Ağı (BKSA) modeliyle 5941 adet veriyle %89,2 oranında başarımlı sonuç elde ettiler. Fatima ve ark. [64] KSA modeliyle 260 adet veriyle %100 oranında başarıma ulaştılar. Xin ve ark. [65] DenseNet modeliyle 555 adet veriyle %88,9 oranında başarıma ulaştılar. Karim ve ark. [66] DSA modeliyle 15959 adet veriyle %97,82 oranında başarıma ulaştılar. Ioannis ve ark. [67] TL +

KSA 1427 adet veriyle %97,82 oranında başarıma ulařtılar. Literatürde X-ray görüntüleri ile COVID-19 tespitine dair çalışmalar Çizelge 3.2’de verilmiştir.



Çizelge 3.2 Literatürde X-ray görüntüleri kullanılarak COVID-19 tespiti. (ACC, doğruluk, Spe, özgülük, Rec, Hatırlama, F1, F1 skoru).

Yazarlar	Veri Tipi	Teknik	Veri Sayısı	Performans Sonuçları (%)
Ezz ve ark. [52]	X-Ray	COVIDX-Net	50	ACC=90
Linda ve ark. [55]	X-Ray	COVID-Net	13975	ACC=93,3
Narin ve ark. [56]	X-Ray	ResNet50, InceptionV3 ve InceptionResNetV2	3113	ACC=99,7
Farooq ve ark. [58]	X-Ray	İnce Ayar + ResNet	5941	ACC=96,23
Prabira ve ark. [59]	X-Ray	DSA + DVM	381	ACC=98,66
Abbas ve ark. [60]	X-Ray	Transfer öğrenimi + KSA	1764	ACC=95,12 Sen=97,91 Spe=91,87
Chowdhury ve ark. [61]	X-Ray	KSA + Resim büyütme	3487	ACC=99,7 Sen=99,7 Spe=99,55 Pre=99,7
Alqudah ve ark. [62]	X-Ray	KSA, DVM ve RF sınıflandırıcısı	2479	ACC=98,95 Sen=99,52 Spe=98,24 Pre=98,58
Goshal ve ark. [63]	X-Ray	Bayes Konvolüsyonel Sinir Ağı (BKSA)	5941	ACC=89,82
Fatima ve ark. [64]	X-Ray	KSA	260	ACC=100 Sen=100 Spe=100 Pre=100
Xin ve ark. [65]	X-Ray	DenseNet	555	ACC=88,9
Karim ve ark. [66]	X-Ray	DSA	15959	Pre=95,2 Rec=94,5 F1=94,8
Ioannis ve ark. [67]	X-Ray	TÖ + KSA	1427	ACC=97,82

3.3 ÖKSÜRÜK AKUSTİK SESLERİ

COVID-19'un en yaygın semptomları pnömoni ve öksürük olarak ifade edilebilir. Bu nedenle, ses analizi, hafif tanı için potansiyel bir araç olarak kabul edilmiştir. Düşük maliyetli akıllı telefonlar ile bile çalışabilen solunum ve akciğer ses analizi [68] ile tanılama yapan uygulamalar bulunmaktadır. Yaşlılar da dâhil olmak üzere yüksek ölüm risk grupları da konuşma analizi kullanılarak sürekli olarak izlenebilir [69]. Öksürük [70,71], hapşırma [70], boğaz temizleme ve yutma seslerinin [72] tümü konuşma ve ses işleme kullanılarak analiz edilebilir. Şu anda, COVID-19 ile ilgili konuşma verilerinin kullanılabilirliği sınırlıdır, ancak potansiyel faydaları [73]'de vurgulanmıştır.

Dikkat çeken yaklaşımlardan biri olan öksürük akustik veri analizi ile yapılan çalışmalar son zamanlarda literatürde yerini almıştır. COVID-19 hastalarını tespit etmek için öksürük akustik verilerine dayalı yaklaşımlar aşağıdaki gibidir:

Imran ve ark. AI4COVID-19 adını verdikleri bir çalışma ile öksürük ses sinyallerine bakarak COVID-19 hastalarını belirlemeyi amaçladı. KSA modelleri için mel-spektrogram görüntüleri elde ettiler. Klasik makine öğrenimi yaklaşımı için, öznitelik çıkarma ve destek vektör makineleri (DVM) sınıflandırma algoritmasına dayalı MFCCs ve temel bileşen analizini kullandılar. Sonuç olarak, %95,6 doğruluk ve %95,6 F1 skoru elde ettiler [74]. Laguarda ve ark. bir cep telefonundan alınan öksürük ses kayıtlarının analizine dayalı bir çalışma önerdi. Öksürüğün ses kayıtlarını kurdukları internet sitesi üzerinden elde ettiler. Mel Frekans Sepstral Katsayıları (MFCC's) dönüşümü ile yüksek performanslı bir model ve bu sinyallere önceden eğitilmiş üç paralel ResNet50 modeli önerdiler. Elde edilen en yüksek hatırlama ve özgüllük değerlerini sırasıyla %98,5 ve %94,2 olarak buldular [75]. Alsabek ve ark. COVID-19 hastalarından ve COVID-19 olmayan kişilerden öksürük sesi, solunum sesi ve ses verilerini kullanan bir çalışma önerdi. Çalışmalarında öznitelikleri MFCCs yöntemini kullanarak elde etmişler ve Pearson Korelasyon katsayı değerleri üzerine bir çalışma yapmışlardır [76]. Sharma ve ark. öksürük, nefes ve ses verilerini içeren "Coswara" adlı bir veri seti ile çalıştı. 28 spektral ölçüm ve rastgele orman sınıflandırıcıları ile bir çalışma önerdiler. Elde edilen genel doğruluk oranı %67,7 idi [77] Mouawad ve ark. öksürük ve diğer vokal sesleri yüksek hassasiyetle algılayabilen, hızlı ve güvenilir tarama sağlayan bir model geliştirmiştir. Spektral yaklaşımlardan MFCC'si ve doğrusal olmayan istatistiksel yaklaşımlardan tekrarlı niceleme analiz yöntemlerini kullandılar. Beş farklı sınıflandırma algoritması ile yüksek performans elde

ettiklerini bildirmişlerdir. Performanslarının %97,0 doğruluk değerine ve %62,0 F1-skoru değerine sahip olduğu hesaplanmıştır [78]. Pal ve Sankarasubbu, dört sınıf öksürük sinyaline dayanan bir çalışma önerdi: COVID-19, astım, bronşit ve sağlıklı. MFCC's, log enerji, sıfır geçiş oranı, çarpıklık, entropi, formant frekansları ve basıklık gibi zaman, frekans ve doğrusal olmayan özniteliklerle çalışmanın sonuçlarını elde ettiler. Elde edilen en yüksek doğruluk puanı ve F1-skoru sırasıyla %97,0 ve %97,3 idi [79]. Pahar ve ark. ResNet50 KSA modeli ile %95,0 doğruluk elde edilmiştir. Laguarda ve ark. önceden eğitilmiş 3 paralel ResNet50 modelini kullanarak %98,5 duyarlılık değeri ve %94,2 özgüllük değeri elde etti [80]. Tena ve ark.[81] TFR analizi ile YAMNet modeli 692 veri üzerinden %83,67 genel doğruluk değeri elde ettiler. C. Brown ve ark. [82] Spektrogram, spektral centroid, MFCCs kullanan KSA modeli 439 veri üzerinden %80,0 genel doğruluk değeri elde ettiler. Espotovic ve ark. [83] Spektrogram ve dalgacık kullanarak topluluk destekli yaklaşım modeli 503 veri üzerinden % 88,52 genel doğruluk değeri elde ettiler. R.Islam ve ark. [84] Sıfır geçiş oranı, enerji, enerji entropisi, spektral merkez, spektral entropi, spektral akı, spektral roll-off, MFCCs kullanan KSA modeli 100 veri üzerinden %88,52 genel doğruluk değeri elde ettiler. Rahman ve ark. [85] Spektrogramları kullanan istifleme tabanlı KSA modeli 1064 veri üzerinden %96,5 genel doğruluk değeri elde ettiler. Erdoğan ve Narin [86] IMF ve DWT tabanlı öznitelikler+ReliefF öznitelik seçimi/SVM makine öğrenmesi modeli ile 1187 veri üzerinden %98,4 genel doğruluk değeri elde ettiler. Aynı şekilde Erdoğan ve Narin [86] ResNet50 tabanlı derin öznitelikler +ReliefF öznitelik seçimi/SVM DL modeli ile ise 1187 veri üzerinden %97,8 genel doğruluk değeri elde ettiler. Literatürde öksürük akustik sesleri ile COVID-19 tespitine dair çalışmalar Çizelge 3.3'de gösterilmiştir.

Çizelge 3.3 Literatürde öksürük akustik sinyallerini kullanılarak COVID-19 tespiti. (ACC, doğruluk, Spe, özgülük, Rec, Hatırlama, F1, F1 skoru).

Yazarlar	Yöntem/Algoritma	Veri Sayısı	Performans Sonuçları (%)
Imran ve ark. (2020) [74]	MFCCs ve PCA/DVM	543	Rec = 96,0 Spe = 95,2 ACC = 95,6 F1 = 95,6
Laguarta ve ark. (2020) [75]	MFCCs /3 paralel ResNet50	5320	Rec = 98,5 Spe = 94,2
Alsabek ve ark.[76]	Spektral merkez (SC), spektral yuvarlanma (SR), sıfır geçiş oranı (ZCR), MFCCs, Delta-delta MFCCs, LTSM	240	F1=97,9 ACC= 97,0
Sharma ve ark. (2020) [77]	MFCCs ve diğer spektral ölçümler/ RF	941	ACC = 67,7
Mouawad ve ark. (2020) [78]	MFCCs ve RQA/XGBoost	1927	ACC = 97,0 F1 = 62,0
Pal ve Sankarasubbu (2020) [79]	MFCCs, zaman alanı ve doğrusal olmayan ölçümler /TabNet network	150	Rec = 96,9 Spe = 96,8 ACC = 97,0 F1 = 97,3

Yazarlar	Yöntem/Algoritma	Veri Sayısı	Performans Sonuçları (%)
Pahar ve ark. (2020) [80]	MFCCs, log energy, zero-crossing rate ve kurtosis/ResNet50	1171	Rec = 93,0 Spe = 95,0 ACC = 98,0
Tena ve ark. [81]	TFR analizi ile YAMNet	692	ACC: 83,67 Sen: 89,58 Spe: 71,58
Brown ve ark. (2021) [82]	Spektrogram, spektral centroid, MFCCs kullanan KSA tabanlı yaklaşım	439	ACC= 80
Espotovic ve ark. (2021) [83]	Spektrogram ve dalgacık kullanarak topluluk destekli yaklaşım.	503	ACC=88,52
Islam ve ark. (2022) [84]	Sıfır geçiş oranı, enerji, enerji entropisi, spektral merkez, spektral entropi, spektral akı, spektral roll-off, MFCCs kullanan KSA tabanlı yaklaşım.	100	ACC=88,2

Yazarlar	Yöntem/Algoritma	Veri Sayısı	Performans Sonuçları (%)
Rahman ve ark. [85]	Spektogramları kullanan istifleme tabanlı KSA tabanlı yaklaşım	1064	ACC=96,5
Erdoğan ve Narin [86]	IMF ve DWT tabanlı öznitelikler+ReliefF öznitelik seçimi/SVM	1187	Rec=99,5 Spe=97,3 ACC=98,4 F1=98,6
Erdoğan ve Narin [86]	ResNet50 tabanlı derin öznitelikler +ReliefF öznitelik seçimi/SVM	1187	Rec=98,5 Spe=97,3 ACC=97,8 F1=98,0



BÖLÜM 4

ÖRÜNTÜ TANIMA

Genel bir örüntü tanıma yöntemi sırasıyla (1) verilerin elde edilmesi, (2) verilerdeki istenmeyen girişimlerin yok edilmesini içeren ön işlemlerin yapılması, (3) probleme özgü öznelik çıkarılması, (4) problemi çözmeye yönelik anlamlı özneliklerin seçilmesi, (5) sınıflandırma ve (6) sınıflandırma performansının değerlendirilmesi adımlarından oluşmaktadır (Şekil 4.1). Bu bölümde, öksürük akustik ses sinyalleri analizi çalışmalarına yönelik olarak özelleştirilmiş örüntü tanıma yöntemleri kısaca tanıtılmaktadır.




Şekil 4.1 Genel bir örüntü tanıma sistemi akış şeması.

4.1 ÖKSÜRÜK AKUSTİK SESİ VERİLERİNİN ELDE EDİLiŞİ

COVID-19(+) ve COVID-19(-) ile ilgili öksürük akustik verileri, ücretsiz erişim sitesi <https://virufy.org/>'dan elde edilmiştir. Veriler, Stanford Üniversitesi tarafından geliştirilen bir mobil uygulama tarafından sağlandı. Veriler toplam 1187 kişiye aittir. Tüm veriler RT-PCR testinden elde edilen sonuçlara göre pozitif ve negatif olarak belirlendi. Test sonucunda 595 COVID-19(+) ve 592 COVID-19(-) kişinin verileri etiketlendi (Çizelge 4.1). Tüm veriler gürültüden arındırıldı. Ayrıca çalışma yapılmadan önce tüm veriler z-normalizasyon yöntemi ile normalize edilmiştir. COVID-19(-) ve COVID-19(+) kişilere ait öksürük sesi sinyalleri sırasıyla Şekil 4.2 ve Şekil 4.3'te gösterilmiştir.

Çizelge 4.1 Tezde yararlanılan veri sayıları.

Sınıf	Veri Sayısı
COVID-19(+)	595
COVID-19(-)	592



Şekil 4.2 COVID-19(-) kişilere ait öksürük sesi sinyali gösterimi.

4.2.1 Verilerin Normalize Edilmesi

Normalizasyon, temelde makine öğrenimi için veri hazırlamanın bir bölümü olarak kullanılan bir yöntemdir. Normalizasyonun hedefi, veri kümesindeki sayısal sütunların değerlerini, değer aralıklarındaki farklılıkları değiştirmeden ortak bir ölçüğe dönüştürmektir. Makine öğrenimi için her veri kümesi normalizasyon işlemini uygulamak gerekmez. Yalnızca öznitelikler farklı aralıklara sahip olduğunda gereklidir. Genellikle değerler 0-1 aralığına dönüştürülür ancak normalizasyonun türüne göre farklı aralıklara da dönüştürülebilir.

Elde edilen özniteliklerin farklı boyutlarda olması sınıflandırıcı başarımlarını kötü etkilemektedir. Bu problemi aşmak için verilerin aynı boyuta indirgenmesi gerekmektedir. Bu sebeple normalizasyon yöntemleri ortaya konmuştur.

4.2.1.1 Z-Skor Normalizasyon

Z-skor normalizasyon, bir veri noktasının ortalamasından gelen standart sapmaların sayısı olarak karşımıza çıkar. Z-skor değeri bulunacak veriden veri setinin ortalama değeri çıkartılıp veri setinin standart sapmasına bölünür. Genel formül şu şekildedir [87]:

$$X_k^{\text{yeni}} = \frac{X_k - \mu_k}{STD_k} \quad (4.1)$$

Formülde verilen X_k , k-inci öznitelik normalize edilecek girdi verisi olmak üzere μ_k ve STD_k sırasıyla bu özneliğin ortalama ve standart sapmasını ifade etmektedir.

4.2.1.2 Min-Max Normalizasyon

Veri setindeki en küçük ve en büyük değerlere göre yapılan Min-Max normalizasyon yöntemi, verileri [0,1] aralığına indirger. Genel ifadesi şu şekildedir [88].

$$v' = \frac{v - \min_x}{\max_x - \min_x} \quad (4.2)$$

Burada \min_x , x özniteliğinin minimum değeri ve \max_x , x özniteliğinin maksimum değeridir. x özniteliğinin orijinal ve normalize edilmiş değerleri sırasıyla v ve v' ile gösterilir. Yukarıdaki denklemden, minimum ve maksimum öznitelik değerlerinin sırasıyla 0 ve 1'e eşit olduğu görülebilir.

4.3. ÖZİNİTELİK ÇIKARIMI

Gerçek hayatta, topladığımız tüm veriler büyük miktarlardadır. Bu verileri anlamlandırmak için bir sürece ihtiyaç duyarız. Manuel bir şekilde bu verileri işlemenin olanağı yoktur. İşte bu noktada öznitelik çıkarma konsepti devreye girer.

Öznitelik çıkarma işlemi temelde işlenmemiş veri setinin işlenmek amacıyla daha küçük parçalara indirildiği bir boyut indirgeme prosesidir. Bu büyük sayıda veri içeren kümelerin kritik özelliklerinden biri de işlenebilmeleri sırasında yüksek miktarda bilgi işlem kaynağına ihtiyaç duyan yüksek sayıda değişkene sahip olmasıdır. Öznitelik çıkarma işlemi, değişkenleri seçen, işlenmesi gereken veri miktarını etkili bir şekilde azaltan ve yine de orijinal veri kümesini doğru ve tam olarak tanımlayan yöntemlere verilen isimdir.

Öznitelikleri çıkarma tekniği, büyük bir veri kümeniz olduğunda ve önemli bilgileri kaybetmeden kaynak sayısını azaltmanız gerektiğinde yararlı bir yöntemdir. Öznitelik çıkarma, veri kümesindeki gereksiz veri miktarını azaltmaya yardımcı olur.

Sonuç olarak, verilerin azaltılması, daha az makine eforu ile modelin oluşturulmasına yardımcı olur ve ayrıca makine öğrenme sürecinde öğrenme ve genelleme adımlarının hızının artmasına yardımcı olur.

4.3.1 Deneysel Mod Ayırıştırma

DMA, doğrusal olmayan ve değişmez olmayan dataları çözümlenmek amacıyla yararlanılan bir metottur. Söz konusu metot Huang marifetiyle 1998'de [89-91] tanıtıldı. DMA'de, giriş işareti

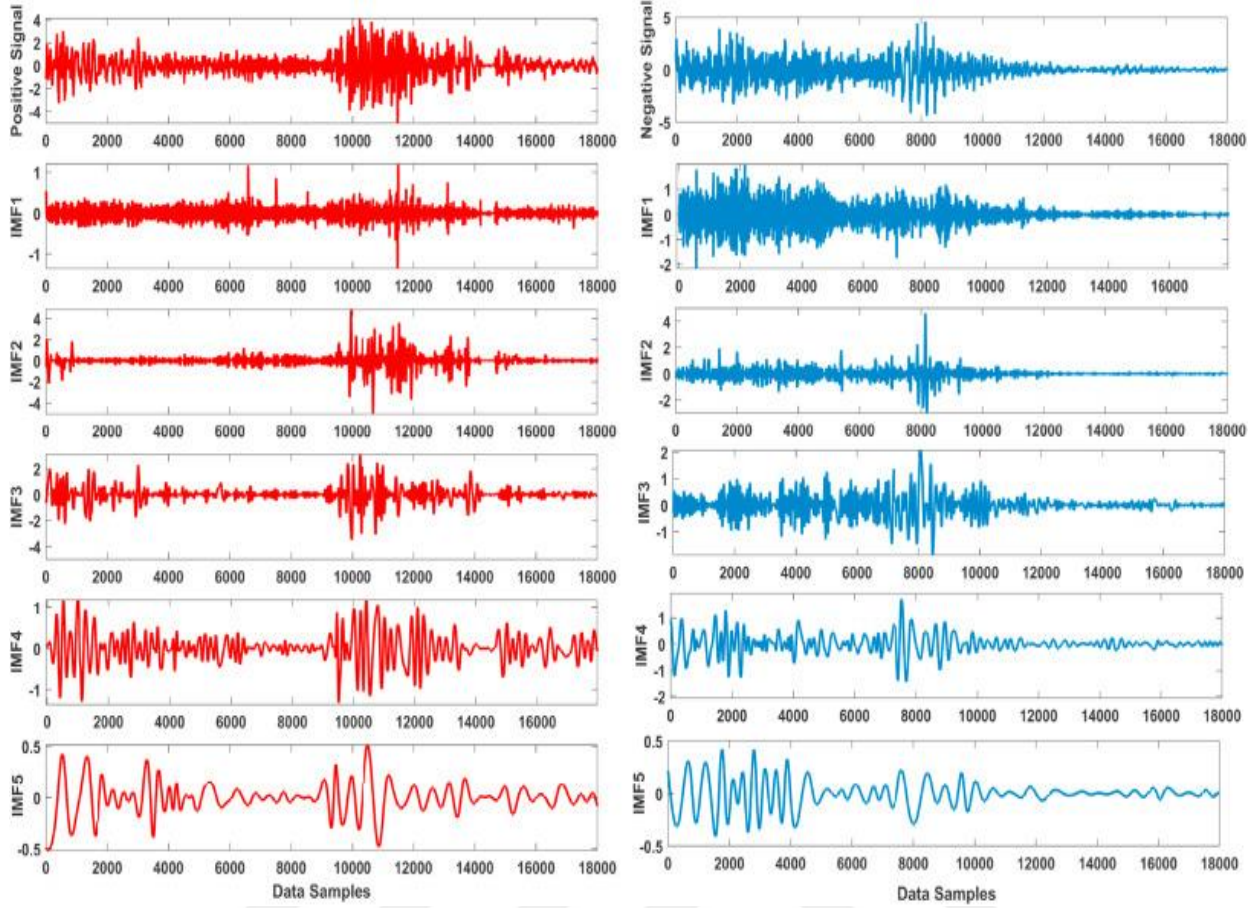
döngüsel şekilde yüksek sıklıktan düşük sıklığa iç mod fonksiyonlarına (İMF) ayrıştırılır. İMF'ler iki önemli ilkeye dayanmaktadır [89]. Bunlar:

- 1) Tüm veri setindeki yerel uç noktaların ve sıfır geçişlerin sayısı birbirine eşit olmalı veya en fazla 1 noktada farklı olmalıdır.
- 2) Rastgele noktaların her birinde, lokal maksimumlar ve lokal minimumlar tarafından ifade edilen zarfın ortalaması sıfırdır.

DMA işlemi, verilen bir $x(t)$ sinyaline aşağıdaki gibi tatbik edilir:

- 1) Orijinal $x(t)$ işaretinin bütün yerel uç noktaları tanımlanır.
- 2) $x(t)$ işaretinin üst ve alt zarfları, kübik spline'ların interpolasyonu ile oluşturulur.
- 3) Alt ve üst zarflardan her bir noktadaki averaj $m(t)$ değeri hesaplanır.
- 4) Fark sinyali, $x(t)$ işaretinden averaj değer çıkarılarak kalküle edilir. $d(t) = x(t) - m(t)$
- 5) $d(t)$ bir İMF ise, $c(t) = d(t)$ olacak şekilde atanır ancak $d(t)$ bir İMF değilse, $d(t)$ orijinal işaret şeklinde alınır ve ilk 4 madde $d(t)$ değeri bir İMF olana kadar döngü devam ettirilir.
- 6) Birinci bileşen bulunduktan sonra $x(t)$ işaretinden çıkarılır ve $r(t) = x(t) - c(t)$ kalıntı değeri olarak elde edilir.
- 7) Son maddede $r(t)$ orijinal veri olarak alınır ve ilk 6 madde yinelernir. DMA, $r(t)$ kalıntısı monoton bir fonksiyon veya artık bir İMF komponentinin çıkarılamayacağı bir değişmez olduğunda proses bitirilir.

Çalışmada kullanılan COVID-19(+) ve COVID-19(-) akustik öksürük verilerinden meydana getirilen 5 mertebeli İMF işaretleri Şekil 4.4'te gösterilmiştir. Zaman alanı ölçümlerinden ortalama, standart sapma ve karekök ölçümlerinden yararlanılmıştır. Her bir İMF sinyalinde, doğrusal olmayan kaotik ölçümlerden Shannon entropisi, log enerjisi, eşik, zaman, norm ve yaklaşık entropi ölçümleri kullanılmıştır. Elde edilen toplam 45 öznitelik Çizelge 4.2'de açıklanmaktadır.



Şekil 4.4 COVID-19(+) ve COVID-19(-) akustik öksürük verileri ve beş seviyeli İMF sinyalleri.

Çizelge 4.2 İMF sinyallerinden elde edilen öznelilik açıklaması.

Öznelilikler	Açıklama	Öznelilik Sayısı
Standart Sapma	Tüm İMF'lerin standart sapması	5
Ortalama	Tüm İMF'lerin ortalaması	5
Karekök Ortalama	Tüm İMF'lerin karekök ortalaması	5
Shannon Entropi	Tüm İMF'lerin Shannon entropisi	5
Log Enerji Entropi	Tüm İMF'lerin Log enerji entropisi	5
Eşik Entropi	Tüm İMF'lerin Eşik Entropisi	5
Zaman Entropi	Tüm İMF'lerin zaman entropisi	5
Norm Entropi	Tüm İMF'lerin Norm entropisi	5
Yaklaşık Entropi	Tüm İMF'lerin yaklaşık entropisi	5
Toplam Öznelilik Sayısı		45

4.3.2. Ayrık Dalgacık Dönüşümü

Sürekli Dalgacık Dönüşümü (SDD) çok büyük veri yığınlarının oluşmasına sebep olur. Oluşan bu dataların tamamı üstünde çalışma gerçekleştirmek önemli güçlükler içermektedir. Söz konusu işlemin nihayetinde konum ve ölçekle ilişkili olarak dalgacık katsayıları bulunur. Eğer ölçekleme ve öteleme 2'nin kuvvetleri olarak seçilirse çözümlenmeler SDD'ye kıyasla daha verimli olur. Ayrık Dalgacık Dönüşümü denilen bu işlem SDD ile eşit derecede kararlı neticeler ihtiva eder.

Dalgacık (Wavelet) dalganın ufak bir bölümü şeklinde ifade edilebilir. Söz konusu kapsamda dalgacık, zamanı kısıtlı bir titreşim sinyalidir [92]. Dalgacık çözümlemede çok sık faydalanılan temel dalgacıklar Daubechies, Morlet, Haar, Meksika şapka türü olarak bilinir. Dalgacıklar, muhtelif frekans komponentlerine göre veriyi ayırırlar. Ayrıca dalgacıklar veriyi kendi ölçekleriyle eşleştirirler. Son olarak ise aslında dalgacıklar eşleştirdikleri ölçekte çözünürlüğe sahip bileşenler üzerinde çalışan matematiksel denklemlerdir.

Dalgacık katsayılarının ölçek değerinde hesaplanması fazla sayıda katsayının meydana gelmesine ve aşırı işlem külfetine sebep olur. Bu yüzden bu katsayıların sadece tercih edilen ölçekler ve zaman bölümünde kalkülasyonu bile pek çok avantajı mümkün kılar. Bundan dolayı daha az miktarda fakat buna rağmen sinyalin sıklık-ölçek enformasyonunun zaman ekseninin her noktasında farklılaştığını ortaya koyan katsayılara ulaşılır. Söz konusu katsayılar bir zaman serisi oluştururlar ve söz konusu zaman serilerinden muhtelif hedefler doğrultusunda yararlanılabilir.

ADD işleminde, ikilik ölçek ve zaman adımından faydalanılır. Bu yolla oluşturulan verilerden her biri iki ve ikinin üsleri olarak ölçek değerlerine ait zaman serilerini ya da dalgacık katsayılarını ihtiva ederler. ADD için yararlanılan dalgacık denklemi (4.3)'de gösterilmiştir.

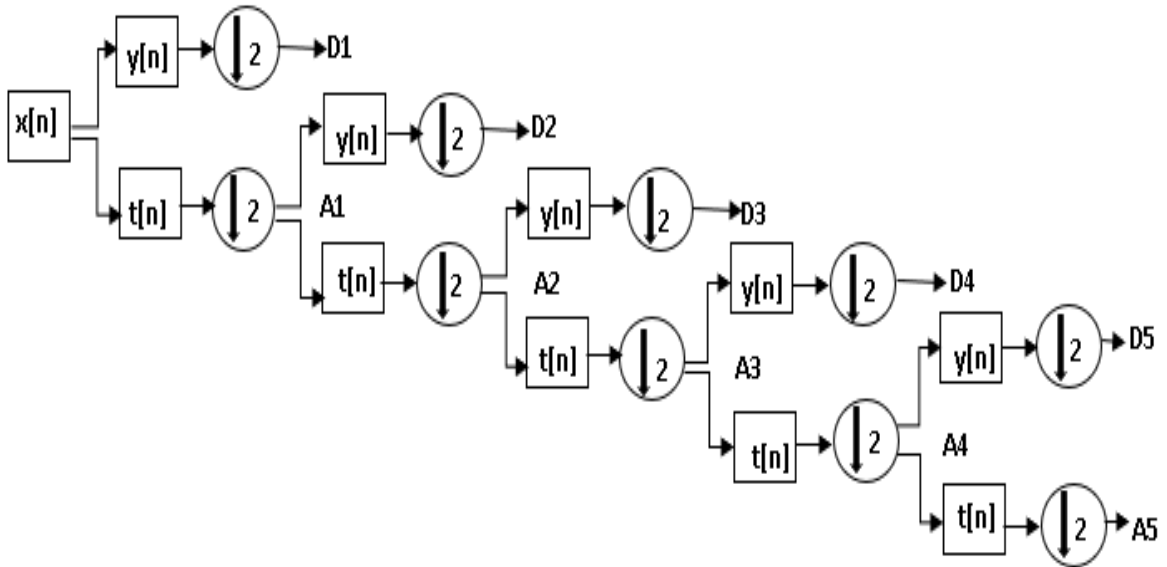
$$\Psi_{m,n} \left(\frac{t - \tau}{s} \right) = s_0^{-\frac{m}{2}} \Psi \left(\frac{t - n\tau_0 s_0}{s_0^m} \right) \quad (4.3)$$

Denklem 4.3'te m ve n tamsayı değerleridir. Bu değerler, dalgacığın sırasıyla ölçek ve zaman aksisindeki öteleme değişkenleridir. s_0 değişmez bir öteleme adımını belirtir ve bu çalışmada 2 olacak şekilde belirlenmiştir. τ_0 zaman aksisindeki öteleme aralığını gösterir ve değeri 1

olacak şekilde kullanılmıştır. Bu değerler literatürde çok sık yararlanılan değerler göz önüne alınarak seçilmiştir. İkinci katları kullanılarak oluşturulan dalgacık denklemi (4.4)'deki gibi ifade edilebilir.

$$\Psi_{m,n}(t) = 2^{\frac{-m}{2}} \Psi(2^{-m}t - n) \quad (4.4)$$

COVID-19(+) kişilerin sabit olmayan öksürük akustik sinyallerinin spektral analizleri yüksek sıklıklarda düşük boyutlu, düşük sıklıklarda yüksek boyutlu pencereden yararlanılarak gerçekleştirilmiştir. Optimum zaman-sıklık çözünürlüğü meydana getirmeyi hedefleyen DD ile Şekil 4.5'te akış diyagramı gösterilen 5 seviyeli detay ve yaklaşık katsayıları elde edilmiştir. Daubechies-6 ana dalgacığı kullanılmıştır. Her bir katsayı için 9 ar adet öznitelik olmak üzere toplam 54 adet öznitelik elde edilmiştir. Elde edilen toplam 54 öznitelik Çizelge 4.3'de gösterilmektedir.

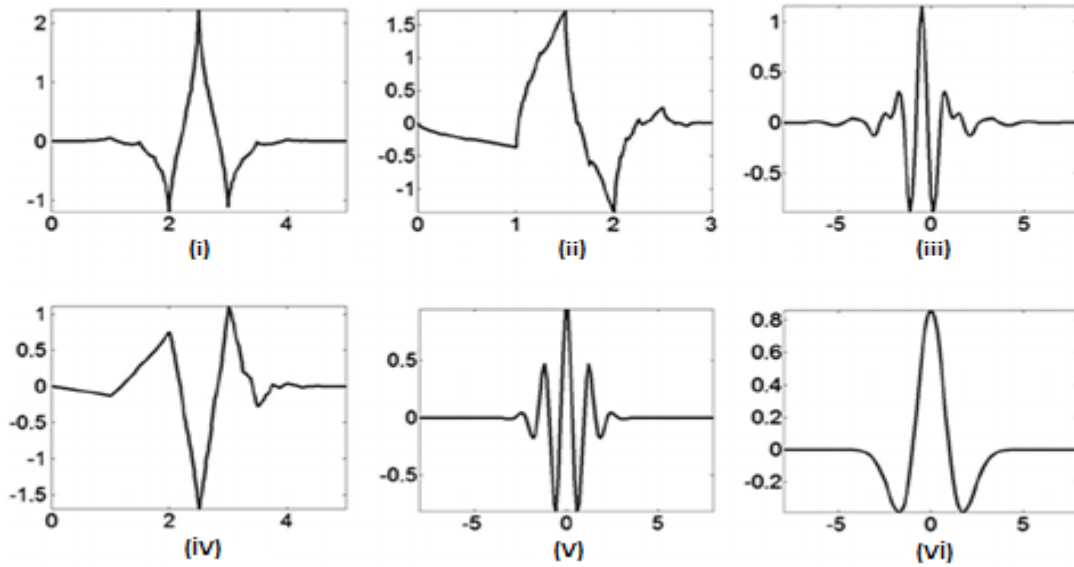


Şekil 4.5 Beş seviyeli dalgacık dönüşümü gösterimi

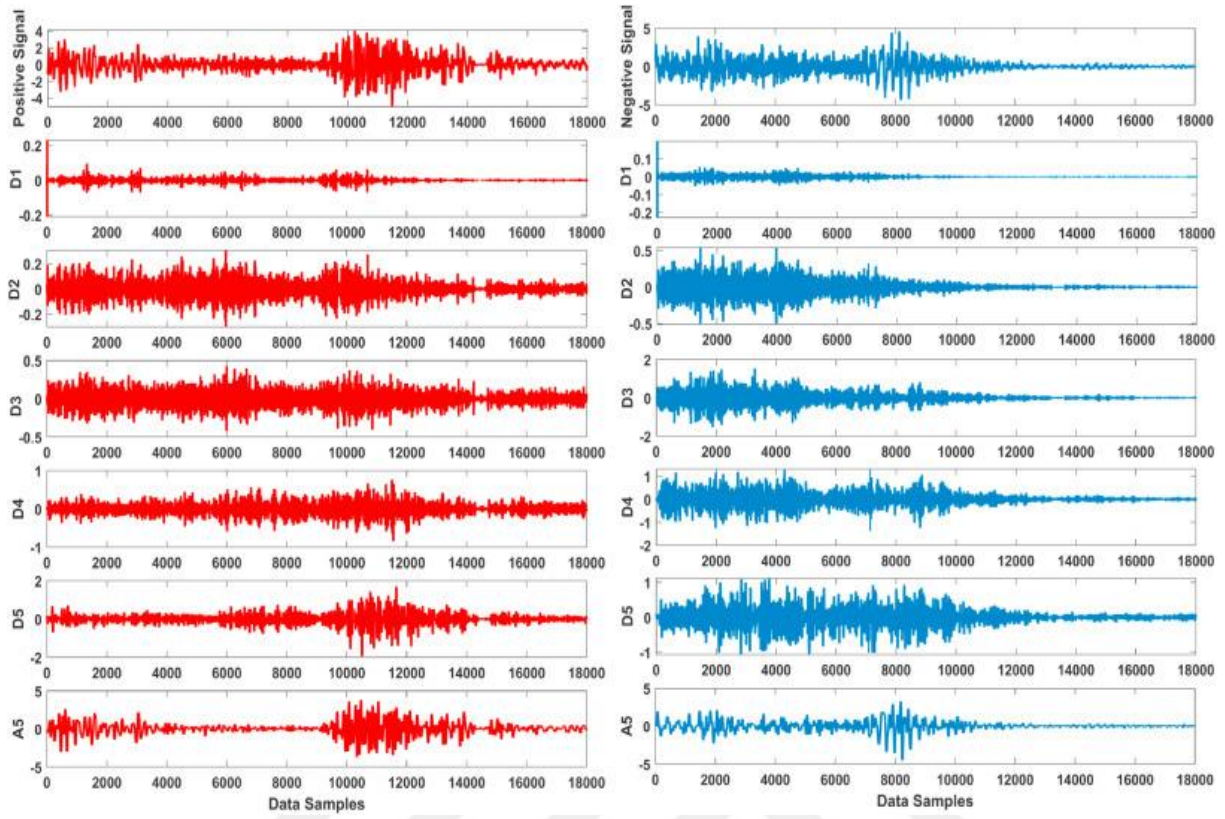
Çizelge 4.3 ADD sinyallerinden elde edilen özniteliklerin açıklaması.

Öznitelikler	Açıklama	Öznitelik Sayısı
Standart Sapma	D1,D2,D3,D4,D5,A5 katsayılarının standart sapması	5
Ortalama	D1,D2,D3,D4,D5,A5 katsayılarının ortalaması	5
Karekök Ortalama	D1,D2,D3,D4,D5,A5 katsayılarının karekök ortalaması	5
Shannon Entropi	D1,D2,D3,D4,D5,A5 katsayılarının Shannon entropisi	5
Log Enerji Entropi	D1,D2,D3,D4,D5,A5 katsayılarının Log enerji entropisi	5
Eşik Entropi	D1,D2,D3,D4,D5,A5 katsayılarının Eşik Entropisi	5
Zaman Entropi	D1,D2,D3,D4,D5,A5 katsayılarının zaman entropisi	5
Norm Entropi	D1,D2,D3,D4,D5,A5 katsayılarının Norm entropisi	5
Yaklaşık Entropi	D1,D2,D3,D4,D5,A5 katsayılarının yaklaşık entropisi	5
Toplam Öznitelik Sayısı		45

Dalgacık dönüşünde en önemli parçalardan biri ana dalgacık fonksiyonunun seçimidir. Coiflets, Daubechies, Meyer, Symlets, Morlet, Meksika şapka en önde gelen ana dalgacık fonksiyonlarıdır. Bu ana dalgacıklar Şekil 4.6'da gösterilmiştir [93]. Ayrıca 5 seviyeli ADD'den elde edilen sinyal çizimleri Şekil 4.7'de gösterilmiştir.



Şekil 4.6 Coiflets dalgacık (ii) Daubechies dalgacık (iii) Meyer dalgacık (iv) Symlets dalgacık (v) Morlet dalgacık (vi) Mexican dalgacık.



Şekil 4.7 COVID-19(+) ve COVID-19(-) öksürük verileri ve 5 seviyeli ADD katsayıları.

4.4 SKALOGRAM

Skalogramlar, sinyalin enerji yoğunluğunu elde etmek için SDD analizini kullanan bir tür zaman-frekans gösterimidir. Duruğan olmayan sinyalleri analiz etmek için yaygın olarak kullanılmaktadır. Skalogram, sabit göreceli bant genişliğine sahip bir spektrum olarak görülebilir.

Skalogramın matematiksel formülü şu şekildedir:

$$S(s) := ||Wf(s, u)|| = \left(\int |Wf(s, u)|^2 du \right)^{\frac{1}{2}} \quad (4.5)$$

Burada s ölçek ve u zamanı göstermektedir. Wf ise enerji ifadesini göstermektedir.

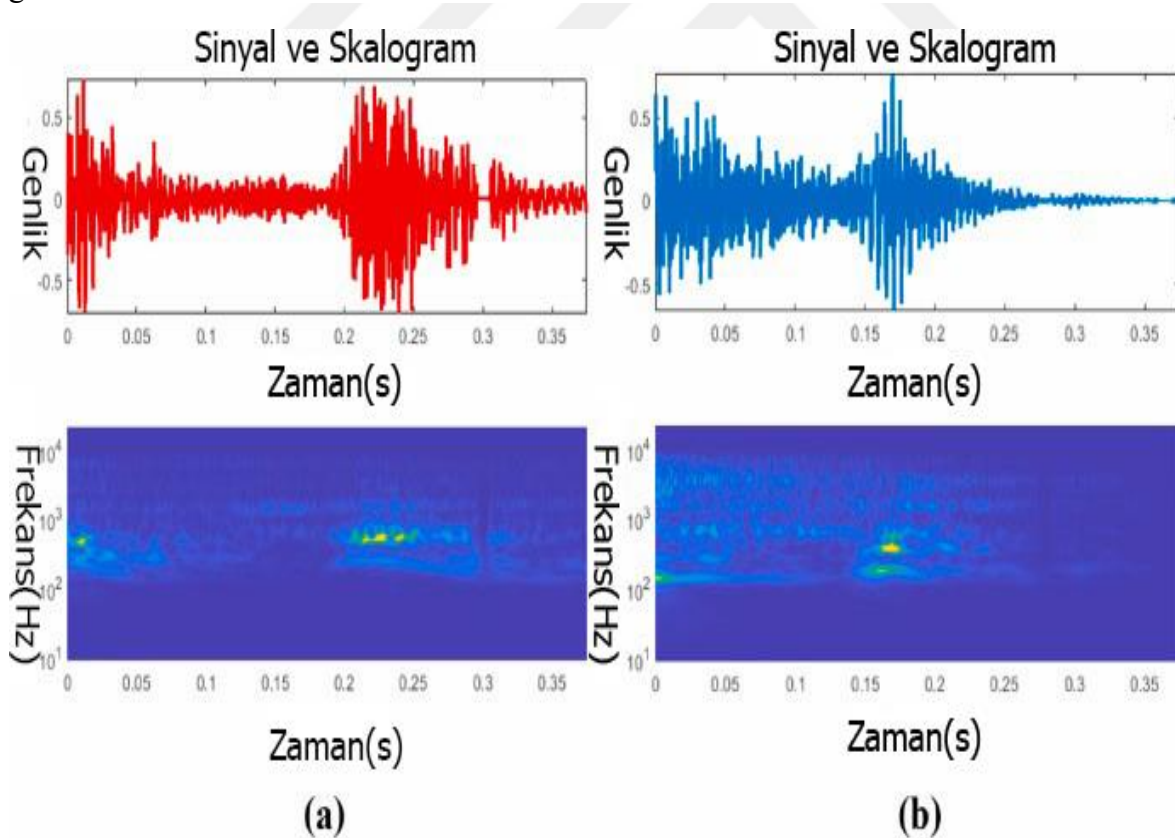
Eğer sadece $[t_0, t_1]$ aralığıyla ilgileniyorsak skalogram ifadesi aşağıdaki formülle gösterilir:

$$S[t_0, t_1] := ||Wf(s, u)||_{[t_0, t_1]} = \left(\int_{t_0}^{t_1} |Wf(s, u)|^2 du \right)^{\frac{1}{2}} \quad (4.6)$$

Skalogram grafiğindeki renkler, SDD katsayılarının göreceli değerlerini gösterir. Işık alanları, SDD katsayılarının daha yüksek değerleri anlamına gelir ve bu nedenle sinyal, dalgacığa çok benzer. Öte yandan karanlık alan, SDD katsayılarının daha düşük değerleri anlamına gelir ve dalgacığın karşılık gelen zaman ve ölçek versiyonlarının sinyalden farklı olduğunu gösterir.

4.4.1 Skalogram Görüntüleri Elde Etme

Bu tez çalışmasında, skalogram görüntülerinin girdi olarak verildiği önceden eğitilmiş modellerden derin öznitelikler elde edilmiştir. Skalogram görüntüleri, sürekli zaman dalgacık dönüşümü yardımıyla tek boyutlu öksürük akustik sinyallerinden elde edilir. Ayrıntılı bilgi için ilgili referanslara bakın [94,95]. Çalışmada sürekli Daubechies-6 (db6) ana dalgacığı kullanılmıştır. COVID-19(+) ve COVID-19(-) sinyallerinin skalogram görüntüleri Şekil 4.8'de gösterilmektedir.



Şekil 4.8 Bir boyutlu öksürük sinyalleri üzerinden elde edilen iki boyutlu skalogram görüntüleri a) COVID-19(+) için b) COVID-19(-) için.

4.5. DERİN ÖZNİTELİK ÇIKARIMI

4.5.1 Derin Öğrenme

Derin öğrenme, makine öğrenmesinin alt dallarından biridir. Bilindiği gibi merkezi sinir sistemi sinirlerden meydana gelir. Bu sinirler ise nöronlardan oluşur. Yapay sinir ağları(YSA) beyindeki bu nöronlar ve aralarındaki bağlantılar dikkate alınarak oluşturulmuştur. Derin öğrenme ise yapay sinir ağlarından esinlenerek oluşturulan bir disiplindir. Tarihsel açıdan incelendiğinde yapay sinir ağı araştırmaları derin öğrenmeye kaynaklık etmiştir. Derin öğrenme aslında temelde bir YSA'dır. Derin şeklinde isimlendirilmesinin nedeni YSA'nın mimarisinden esinlenilmesidir. 1970'lerdeki ilk YSA'lar yalnızca bir iki tabakadan meydana gelmekteydi. Bu katmanların adedi günümüzde sürekli yükselmektedir. Ayrıca yakın zamana gelene kadar YSA'nın eğitilmesinin çok meşakkatli olduğu düşünülüyordu. En önemli sebeplerden biri olarak donanımsal eksiklikler sayılmaktaydı. Teknolojik gelişmelerle birlikte bu sorunlar ortadan kalkmaya başlamış ve tabaka adedi artırılarak derin ağ mimarileri meydana getirme çalışmalarına start verilmiştir. Deneysel olarak, derin ağlar genellikle bir ya da iki gizli tabakaya sahip sinirsel ağlardan çok daha iyidir [96]. Derin öğrenme diğer ağ yapılarıyla karşılaştırıldığında: kompleks yapıları çözümüleme, kullanıcı müdahalesine çok açık olmama, yüksek mertebe soyutlamaları çözümüleme, çok büyük örnekleri ve etiketi olmayan dataları anlamlandırma açılarından muhtelif metodlarla karşılaştırıldığında daha başarılı sonuçlar vermektedir.

Bu sebeplerden ötürü derin öğrenme bazen “yeni nesil sinir ağları” olarak isimlendirilmiştir. Derin öğrenmede amaç insana benzer şekilde düşünen ve karar veren yapılar oluşturmaktır. Bu bağlamda derin öğrenme her türlü ses, metin ve görüntüyü kullanabilir. İnsan beyninden esinlenen derin öğrenme, izokortesin veriyi karmaşık bir hiyerarşiden geçirdiğini gösteren nörobilim bulgularından yararlanır [97]. Derin öğrenme kökenini YSA'dan almaktadır. “Derin” kelimesi özel olarak seçilmiştir. Çünkü derin öğrenmede birbirinin üzerine yığılan katmanlar

bulunmaktadır. Yani yapı gittikçe derinleşmektedir, bu yüzden “derin kelimesi seçilmiştir. Derin öğrenme mimarisi, her biri daha üst düzey öznitelikleri çıkarması beklenen yığın katmanları aracılığıyla meydana getirilir.

Örneğin, görüntüler pikselleri ihtiva eder ve DL modeli, görüntünün kenarlarını, nesneleri katmanlar üzerinden öğrenir. DL yaklaşımları, tasnif işlemleri, görüntü işleme, doğal dil işleme, ses tanıma vb. alanlarda kullanılabilir ve bunlar sığ mimarilere kıyasla performans açısından çok daha güçlü modellere sahiptir [98]. Özellikle son zamanlarda yapılan araştırmalarda biyolojik ve devre kompleksitesine sahip yapılarda DL kullanımının, spesifik olarak kompleks matematiksel denklemleri ihtiva eden problemleri analiz etmede sığ yapılara kıyasla daha başarılı çıktılar ortaya koyduğu gözlemlenmiştir.

4.5.2 Konvolüsyonel Sinir Ağları (KSA)

Çok katmanlı algılayıcıların (ÇKA) bir çeşidi olan Konvolüsyonel Sinir Ağları (KSA) hayvanların görme sisteminden ilham alarak oluşturulmuştur. Konvolüsyonel Sinir Ağları bir nöronun kendi uyarı bölgesinden uyaranlara karşı gösterdiği tepkiye bakılarak oluşturulmuştur [99]. KSA özellikle görüntü ve ses işleme başta olacak şekilde doğal dil işleme ve biyomedikal sinyal işleme gibi birçok muhtelif dalda kullanılmaktadır. Özel olarak görüntü işleme kısmında bugüne dek pek çok sonuç alınmıştır. Bunlarda biri olan Cişeran meydana getirdiği araştırmada MNIST veri kümesi üzerinde, KSA vasıtasıyla hata oranını 2×10^{-2} seviyelerine düşürebilmiştir [100].

4.5.3 Konvolüsyon Katmanı

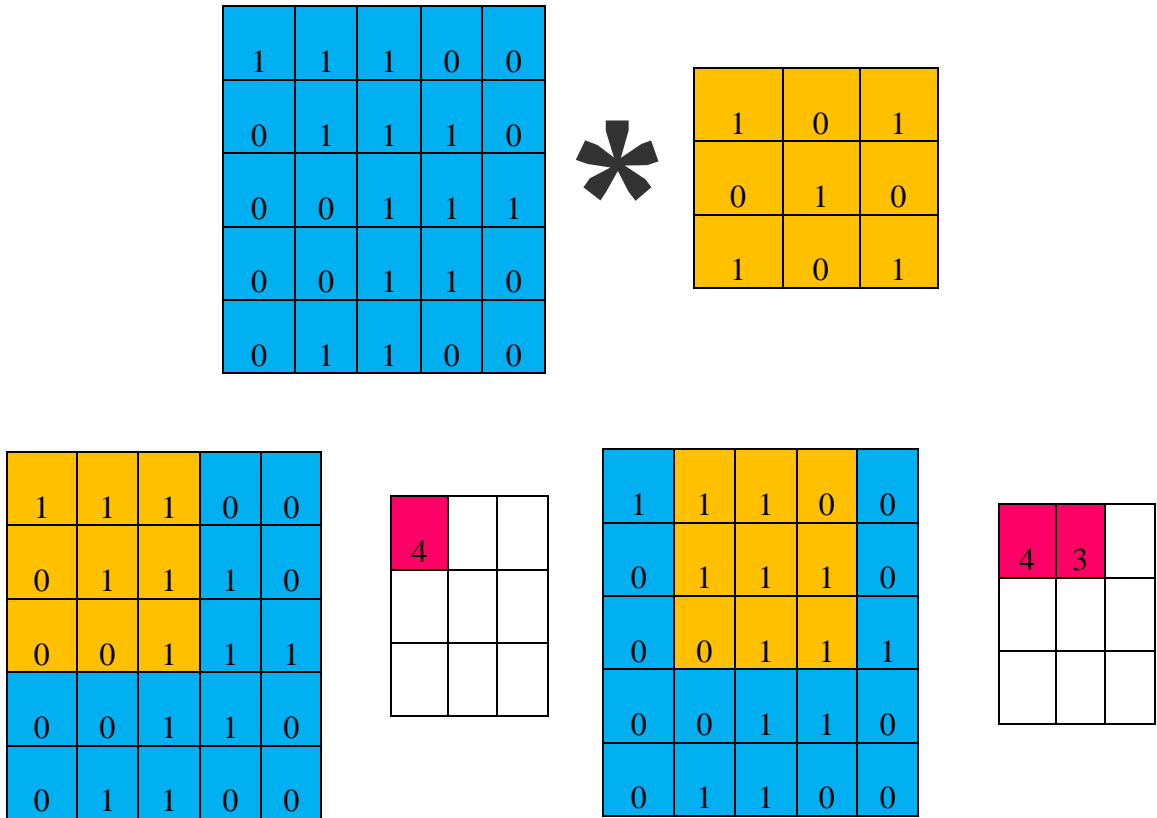
Konvolüsyon katmanında temel hedef giriş verilerinden öznitelik çıkarmaktır. Konvolüsyon prosesi iki fonksiyonun matematiksel işleme girmesine verilen isimdir. KSA’da konvolüsyon prosesi temelde filtre olarak isimlendirilen çekirdek denkleminin ana görüntü üstünde elemanların sırayla kaydırılması manasına gelir. Pencerelerin her birinde kaydırma prosesi,

elemanların filtre matrisiyle birimsel olarak çarpımının toplamıdır. Bütün girişler üzerinde pencere kaydırılarak öznitelik haritası diye isimlendirilen konvolüsyonun çıktısı üretilmiş olur. f ana görüntü, h çekirdek olacak şekilde konvolüsyon prosesi 4.7a,4.7b ve 4.7c’de verilmiştir. Konvolüsyon işlemi Şekil 4.9’da konvolüsyon katmanı gösterimi ise Şekil 4.10 verilmiştir.

$$f * h = \sum_k \sum_l f(k,l)h(i - k, j - l) \quad (4.7a)$$

$$f = \begin{bmatrix} f_1 & f_2 & f_3 \\ f_4 & f_5 & f_6 \\ f_7 & f_8 & f_9 \end{bmatrix} \quad h = \begin{bmatrix} h_1 & h_2 & h_3 \\ h_4 & h_5 & h_6 \\ h_7 & h_8 & h_9 \end{bmatrix} \quad (4.7b)$$

$$f * h = f_1h_9 + f_2h_8 + f_3h_7 + f_4h_6 + f_5h_5 + f_6h_4 + f_7h_3 + f_8h_2 + f_9h_1 \quad (4.7c)$$



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

4	3	4

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

4	3	4
2		

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

4	3	4
2	4	

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

4	3	4
2	4	3

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

4	3	4
2	4	3
2		

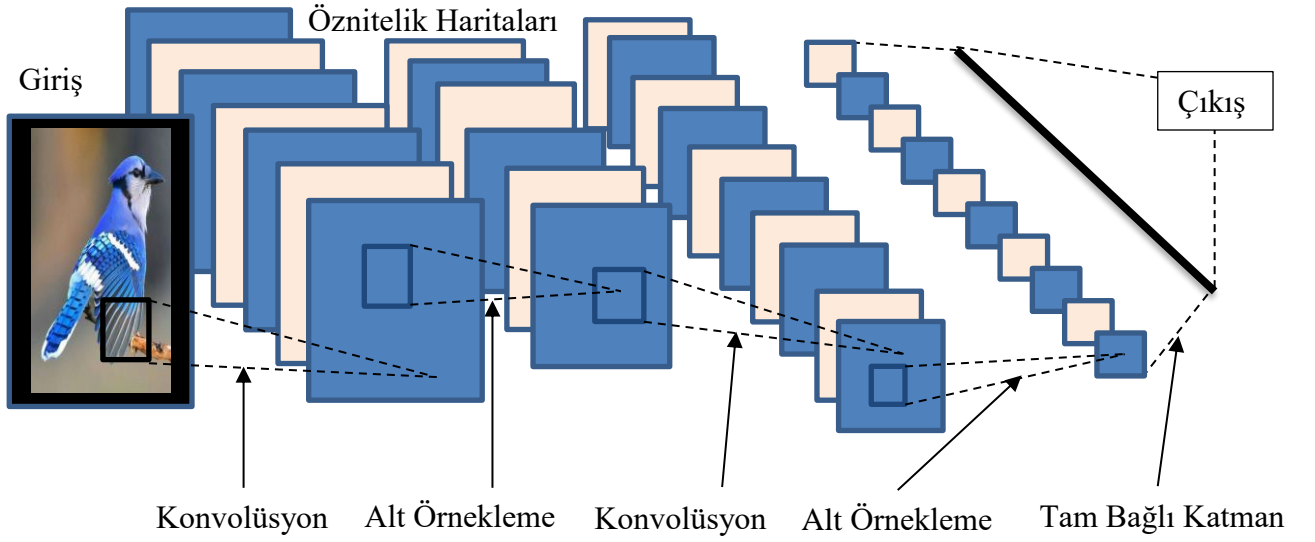
1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

4	3	4
2	4	3
2	3	

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

4	3	4
2	4	3
2	3	4

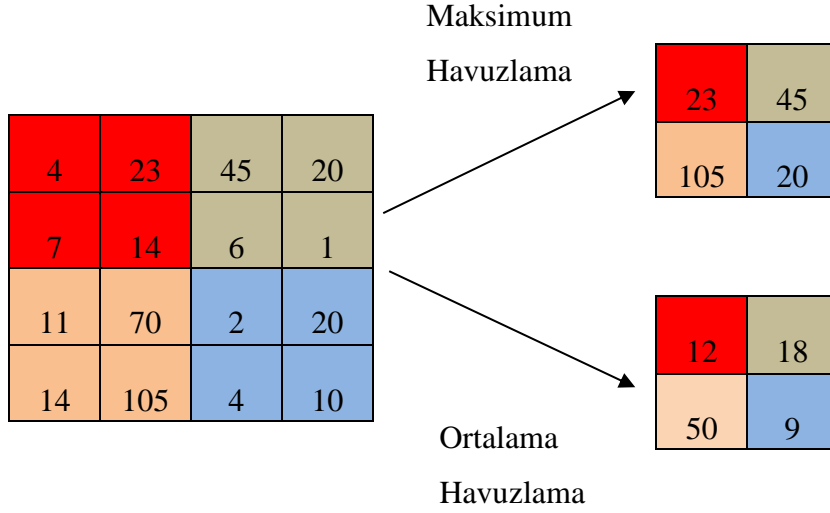
Şekil 4.9 Konvolüsyon İşlemi



Şekil 4.10 Konvolüsyon Katmanı

4.5.4 Havuzlama Katmanı

Havuzlama tabakası diğer bir ifadeyle alt-örnekleme, ağdaki değişkenlerin ve kalkülasyonların adedini azaltarak konvolüsyon katmanının çıktısının boyutunu küçültmek için kullanılır. Havuzlama katmanından çoğunlukla iki konvolüsyon katmanı ya da tam bağlı katmanlar arasında yararlanır. Bu tabaka genellikle maksimum havuzlama ve ortalama havuzlama olarak iki bölüme ayrılır. Bir giriş penceresinde, maksimum havuzlamada penceredeki en yüksek değerler verilirken ortalama havuzlama ise penceredeki ortalama değerler verilir. Havuzlama işlemi havuzlama boyutu ve adım olarak iki kritik parametre içermektedir. Şekil 4.11’de havuzlama örneği verilmiştir.



Şekil 4.11 Havuzlama Örneği

4.5.5 Tam-Bağlı Katman

Konvolüsyon ve havuzlama tabakaları dikdörtgen görünümülü çıktılar oluşturur. Ağırlık matrisi ismi verilen bu çıktılar, vektör matrisine çevrilir. Örneğin her biri 5x5x3 boyutunda 3 boyutlu pikselin 64 öznitelik tabakası varsa, tam bağlı tabakada 4800x1 vektöre çevrilir. Tam bağlı tabakadan bir evvelki katmanda üst mertebeli öznitelikler gösterilir. Bu tabaka vasıtasıyla, bu üst mertebeli öznitelikler gizli tabakaların ağırlıkları ile çarpılabilir.


4.5.6 Hiper Parametre Ayarlamaları ve Seçimleri

Makine öğrenimi modelleri meydana getirilirken, yazılımcının modelde yararlanılacak sınıflandırıcı veya yöntemlerin neler olacağını tespit etmesi gereklidir. Ayrıca belli başlı parametlerin kaç olacağını saptaması da gerekmektedir. K-nn sınıflandırma algoritmasında k'nın kaç olarak alınacağı buna bir örnek olabilir. Aynı şekilde DL modeli dizayn edilirken tabaka sayısına, dropout değerine gerek olup olmadığına modeli dizayn eden kişi saptamalıdır ve hangi modellerden daha başarılı çıktılar alınacağı belli değildir. Bu veri kümesine bağlı olarak değişkenlik meydana getiren parametreler hiper parametre(HP) olarak


isimlendirilmektedir. HP'ler çoğunlukla iki farklı şekilde sınıflandırılmaktadır; bunlar model HP'ler ve iyileştirici HP'lerdir. Model HP'ler modelin muhtevasında var olan parametrelerdir. Aktivasyon fonksiyonları, dropout, tabaka sayısı modele özel HP'lerdir. İyileştirici HP'lerse modelin yapısından daha çok eğitim ve optimizasyon için kullanılan parametrelerdir. İyileştirici hiper parametreler öğrenme oranı, MB boyutu ve devir sayısını ihtiva etmektedir.

4.5.7 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonlarından ÇKA'da doğrusal fonksiyonları olmayan doğrusal fonksiyonlara çevirmek amacıyla yararlanılır. Çünkü burada amaç çok katmanlı ağların lineer olmayan durumlarda da öğrenmesini sağlamaktır. Katmanlarda lineer fonksiyon $y = f(x, w)$ ile matris çarpımı gerçekleştirilip her nöronun ağırlığı kalküle edildikten sonra doğrusal olmayan bir değere çevrilir. Gizli katmanlarda öğrenme süreci geri türev kullanılarak yapıldığı için gizli tabakaların çıktısı belli başlı aktivasyon fonksiyonları ile normalizasyon işlemine tabi tutulmaktadır. Çoğunlukla yararlanılan aktivasyon fonksiyonları: Sigmoid, Softmax, ReLU, TanH, SoftPlus, ELU, PReLU, Swish'dir. En çok yararlanılan aktivasyon fonksiyonları ise ReLU, Softmax ve Sigmoid'dir. ReLU aktivasyon fonksiyonu gösterimi Şekil 4.12'de, Sigmoid aktivasyon fonksiyonu gösterimi ise 4.13'te gösterilmiştir.



Şekil 4.12 ReLU aktivasyon fonksiyonu gösterimi



Şekil 4.13 Sigmoid aktivasyon fonksiyonu gösterimi

4.5.8 Mini-Batch Boyutu

YSA'da bütün datalar nörondan eş zamanlı başlayarak o ağı eğitmekte ve nöron ağırlık katsayıları buna bakılarak belirlenmektedir. Buradaki proses süre ve bellek yönünden zor ve pahalı bir işlemdir. Çünkü her yinelemede öğrenmenin geriye yayılım prosesi ile ağ üzerinde geriye dönük şekilde gradyan kalkülasyonu yapılmakta ve ağırlık katsayıları böylece güncellenmektedir. Buradaki kalkülasyon prosesi data sayısına bağlı olacak şekilde artmaktadır. Bu sebepten dolayı ağın eğitim performansını yükseltmek ve bellekten daha verimli yararlanmak amacıyla bütün data gruplar halinde ele alınmakta ve küçük bölümler şeklinde işlemler gerçekleştirilmektedir. Bu metoda mini-batch (MB) ismi verilmektedir. Başka bir deyişle "mini-batch" dizayn edilen modelin eğitim ve test datalarının modele girdiğinde eş zamanlı olarak ne kadar datayı işleyeceği manasını ihtiva etmektedir. Ağa giren küçük bölümdeki datalar gelişigüzel olarak belirlenmektedir. Her MB üstünde model ileri besleme prosesi yapılır ve hata değerini bulunur. Sonraki aşamada her MB üzerinde geriyayılımdan yararlanarak gradyan kalkülasyonlarını yapılır ve ağırlık katsayıları güncellenir. Bu ağırlık

katsayılarını kalküle etmek amacıyla gradient descentten yararlanır. Temelde MB boyutlarının tamamı eşit olup 10^{-2} ile %5 arasında en uygun olacak şekilde belirlenmektedir. Seçilen değer 10^{-2} 'den küçükse aşırı gürültü olmakta, %5'ten yüksek belirlenirse de modelin eğitim değerleri düşmektedir.

4.5.9 Eğitim Tur Sayısı

Derin öğrenmede modelin eğitim aşamasında MB'te bilindiği üzere bütün küme elemanları bir kerede eğitilmez kısım kısım eğitim işlemi tamamlanır. Her kısım eğitiminin nihayetinde geriyayılım sonucuna göre ağırlıklar tekrar hesaplanılarak güncelleme işlemi yapılır. Eğitim tur sayısında döngülerin her birinde bütün veri kümesinin ileriye ve geriye doğru ilerleme metotları ile model yeniden eğitilip ağırlık katsayıları güncellenmesi buna göre belirlenir. Eğitim tur sayısı düşük belirlenirse model eksik öğrenir veya yüksek belirlenirse model aşırı öğrenir. Bu eğitim tur sayısı tahmini şekilde saptanmaktaydı ancak Tensorflow kütüphanesinin yardımıyla erken durdurma özelliği ile başarımla istenilen mertebeye geldiğinde süreç otomatik olarak durdurulmaktadır.

4.5.10 Öğrenme Hızı

Derin öğrenmede ağırlık parametresinin güncellenmesi geri yayılım vasıtasıyla gerçekleştirilmektedir. Bu güncelleme geriye doğru türev işlemi yapılarak marjinin elde edilmesi ve elde edilen marjinin öğrenme hızı değişkeniyle çarpımı nihayetinde elde edilmektedir. Bulunan değer değişmez veya makul seviyede artan veya azalan olarak regüle edilebilir özelliğe sahip olup 10^{-1} ile 10^{-6} değerleri arasında belirlenmektedir. Öğrenme oranı saptanırken eğer aşırı yüksek bir değer belirlenirse modelin eğitime verisinde yüksek seviyede tesir etmesine sebebiyet vermektedir. Aynı şekilde öğrenme oranının aşırı düşük saptanmasıysa modelin düşük hızda gitmesine ve öğrenme süresinin aşırı yüksek olmasına sebebiyet

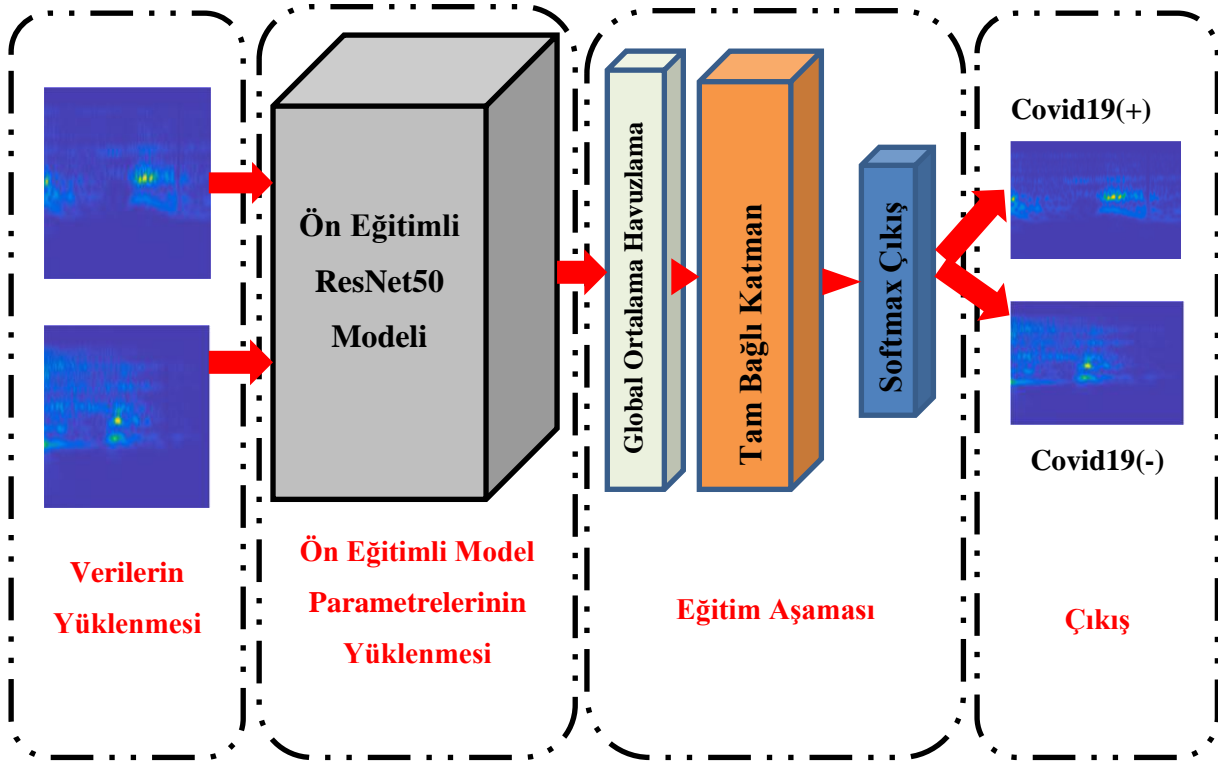
vermektedir. Bu sebeple temelde ilk amaç önce büyük öğrenme hızı değeri kullanıp eğitmeyi arttırmak ve beklenen hata oranına yaklaşıldığında gerekirse öğrenim oranını azaltmaktır.

4.6 DERİN ÖĞRENME MODELLERİ

4.6.1 ResNet50

ResNet50 konvolüsyonel sinir ağı modelinin adı, artık kısma sahip nöral ağların ihtisarından meydana gelmektedir. ResNet50 muhtevasında çok sayıda KSA bulunan gelişmiş bir konvolüsyonel sinir ağı versiyonudur [101]. Katmanlar arası geçişlerin bulunması ResNet modellerinde ağı derinleştirdiği için ağda meydana gelebilecek bozulmalar engellenmektedir.

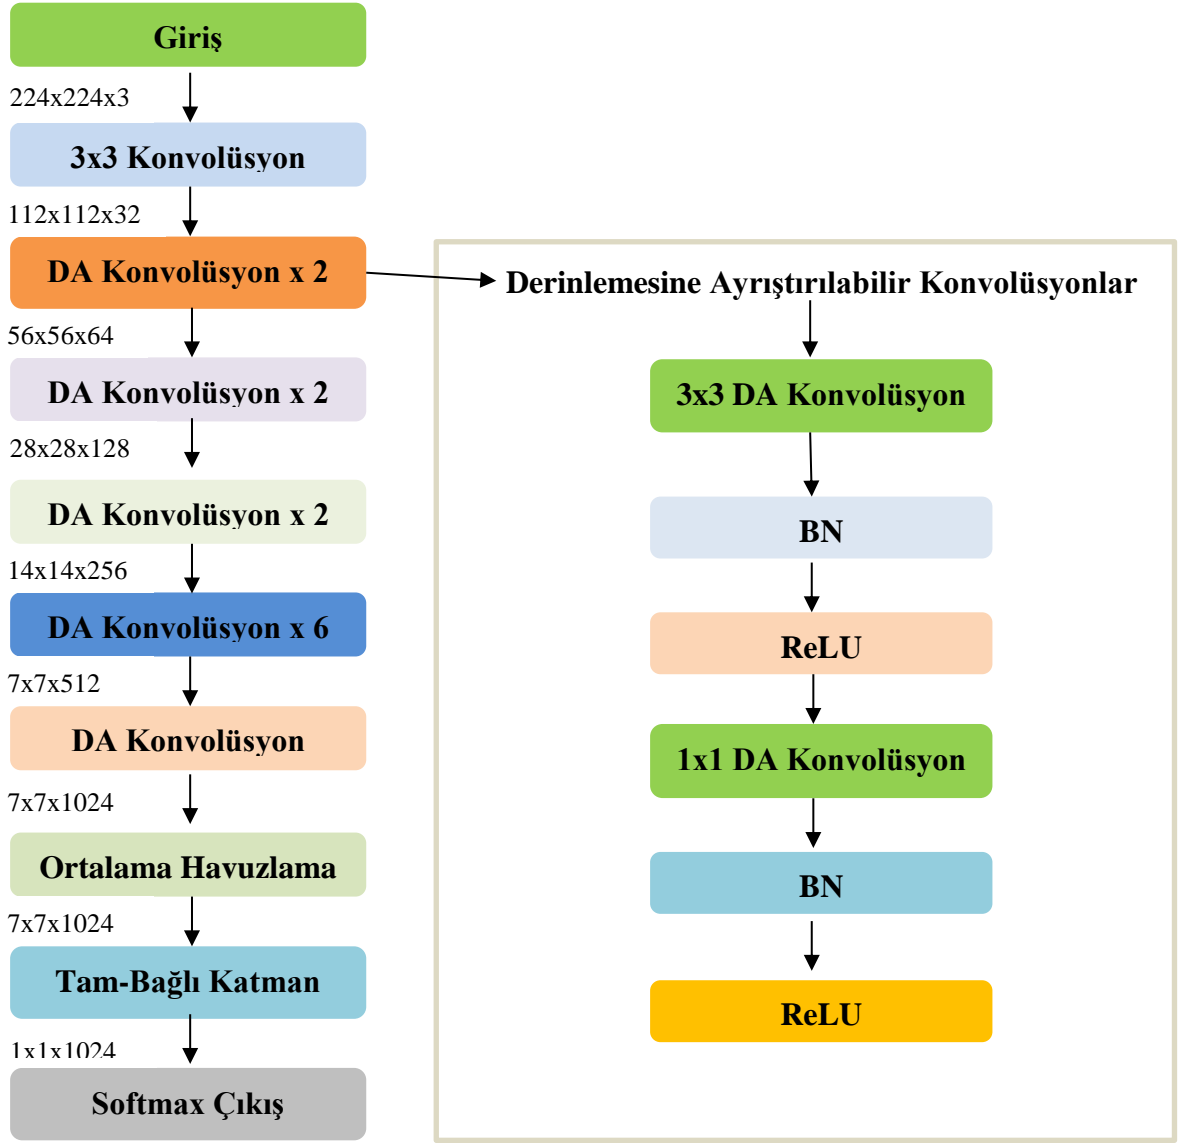
Eğitimin daha hızlı gerçekleşmesi amacıyla bu modellerde darboğaz ismi verilen bloklardan yararlanır. ResNet50 modelinde hemen hemen 23.000.000 değişken kalkülasyonu gerçekleştirilmektedir. Aslında önceden eğitilmiş olan ResNet50 modeli, ImageNet diye bilinen veri seti üstünden eğitilmiş 50 tabakalı yapıya sahip derin bir ağıdır. ImageNet, görüntü işleme müsabakalarında kullanılmak amacıyla meydana getirilmiş 20.000'den daha çok sayıda muhtelif zümreye ait 14.000.000'dan fazla resmi muhteva eden bir veri tabanıdır [102]. Bu tezde yararlanılan önceden eğitilmiş ResNet50 modelinin mimarisi Şekil 4.14'te gösterilmiştir. İki bölümden meydana gelen bu modelde, ilk bölümde ImageNet veri tabanı vasıtasıyla eğitilmiş ResNet50 yapısı ve diğer bölümde yani eğitim bölümünde COVID 19 skalogram resimleri için önerilen ağın modeli yer almaktadır.



Şekil 4.14 Ön Eğitimli ResNet50 Modelinin Gösterimi.

4.6.2 MOBILENET

MobileNet, mobil ve gömülü sistem görüntü uygulamaları amacıyla meydana getirilmiş 28 tabaka ve 4,2 milyon değişkenden meydana gelen bir KSA'dır. MobileNet, mobil araç gereçler ve gömülü düzenlerde kullanıcıların düşük gecikme süresi olan hafif DSA'ların ilerlemesini sağlayan DA konvolüsyonlardan yararlanan çağdaş bir yapıyı kendisine temel olarak almaktadır [103]. MobileNet'te DA konvolüsyon giriş kanallarının her birine tek bir filtre tatbik eder. Noktasal konvolüsyon sonrasında derinlik cihetindeki konvolüsyon sonuçlarını toplamak amacıyla $1 \times 11 \times 1$ konvolüsyon tatbik eder. Gecikme ve başarımlar arasında verimli olarak değiş tokuş eden iki temel global yüksek değişken verilmektedir. Bu yüksek değişkenler modeli meydana getiren kişinin problemin sınırlamalarını temel olarak uygulamaları için doğru boyutlu modeli meydana getirmesine olanak sağlar. TL'yi kullanmak ya da gerçekleştirmek amacıyla daha düşük kalkülasyon gücüne ihtiyaç duyar [54]. MobileNet mimarisi Şekil 4.15'te gösterilmiştir.




Şekil 4.15 Ön Eğitimli MobileNet Modelinin Gösterimi.

4.6.3 KSA’NIN EĞİTİLMESİ

Konvolüsyonel sinir ağı (KSA), öznelik çıkarma ve sınıflandırma bölümlerinden oluşan derin öğrenme modellerinden biridir [104]. Ham verileri kullanarak uçtan uca yaklaşımlarla yüksek performans sergiler. Aynı şekilde çıkarılan özneliklerin hibrit sistemlerde kullanılması da yüksek sonuçlar vermektedir. İçerisindeki farklı büyüklükteki filtreler ile gerçekleştirilen konvolüsyonel işlemleri, havuzlama işlemleri, normalleştirme işlemleri ve seyreltme işlemleri her bir kalıba özel harita oluşturulmasını sağlar. Literatürde önceden eğitilmiş çeşitli KSA

modellerinin kullanıldığı birçok çalışma bulunmaktadır [10,56]. Tezde, ResNet50 ve MobileNet olmak üzere iki farklı mimari üzerinden derin öznitelikler elde edilmiştir. ResNet50 modeli literatürde yaygın olarak kullanılan modeller arasındadır. Sonraki katmanları besleyen artık değer bloklarından oluşan bir yapıya sahiptir. ResNet50 modeli 25,6 milyon parametreden oluşur [105]. Öznitelik çıkarmada kullanılan daha hafif ve hesaplama açısından daha az karmaşık model, önceden eğitilmiş MobileNet KSA mimarisidir [54]. MobileNet modeli 3.5 milyon parametreden oluşmaktadır. Derin öğrenme modellerinde öznitelik çıkarımı tüm katmanlardan yapılabilir. Ancak genellikle sınıflandırma adımından hemen önceki katmandan elde edilen öznitelikler tam bağlantılı katman üzerinde kullanılır. Tezde ResNet50 için tam bağlantılı “fc1000” ve MobileNet için “Logits” katmanları üzerinden derin öznitelikler elde edilmiştir. Özniteliklerin çıkarıldığı katmanlar üzerinde $1 \times 1 \times 1000$ boyutunda öznitelik haritaları elde edilmiştir. Sadece önceden eğitilmiş ResNet50 modeli için elde edilen farklı katmanlardaki öznitelik haritası görüntüleri Şekil 4.16'da verilmiştir. ResNet50 ve MobileNet modelleri için mini-batch size değeri 10 olarak seçilmiştir. Epoch değeri 30 olarak ayarlandı. Öğrenme oranı 0.0001 olarak seçildi.



Şekil 4.16 Bazı katmanlardaki girdi örnek görüntüsünün çıktıları.

4.7 ÖZNETELİK SEÇİMİ

Biyomedikal işaretlerin artması beraberinde özniteliklerinde artmasına sebep olmuştur. Dolayısıyla hesaplama maliyetleri artmakta ve çok fazla zaman harcanmaktadır. Elde edilen her öznitelik işaretin sınıfını tam olarak karşılamayabilir ve hatta diğer öznitelikler içerisinde performansı düşürebilir. Buna boyutluluğun laneti (curse of dimensionality) de denilmektedir [106]. Bunun sonucunda kararlı ve doğru bir otomatik tespit sistemi geliştirilmez. Hem performans artışını sağlamak hem sınıfları en iyi ifade eden öznitelikleri belirlemek önem arz etmektedir. Bunun için öznitelik seçme yöntemleri önerilmektedir.

4.7.1 ReliefF Algoritması ile Öznitelik Seçimi

Relief algoritması Kira ve arkadaşları tarafından 1992 yılında geliştirilmiş bir öznitelik seçme yöntemidir. Bu yöntemin temel amacı öznitelikleri aralarındaki korelasyona göre tartmaktır [107]. Relief algoritması iki sınıfın verileri üzerinde başarılı sonuçlar vermektedir. Ancak, ikiden fazla sınıf içeren veri kümeleri için başarılı sonuçlar vermemiştir. Bu sorunu ortadan kaldırmak için Kononenko 1994 yılında ikiden fazla sınıflı veri setlerinde çalışan ReliefF algoritmasını geliştirmiştir [108]. ReliefF yöntemi, özellikle öznitelikleri sınıflandırırken çok sınıflı örüntü tanıma problemlerinde kullanılan bir yöntemdir [109].

$$W_{yeni}[A] = W_{eski}[A] - \frac{diff(A, R, H)}{m} + \frac{diff(A, R, M)}{m} \quad (4.8)$$

Burada örnek numarası R, en yakın iki komşuyu arıyor. Bunlardan birincisi, aynı sınıfa ait en yakın komşuyu belirten H ve muhtelif bir sınıftan en yakın komşuyu bildiren M olarak ifade edilebilir. Aynı ve muhtelif sınıfların komşularının en yakın olanın hesaplamak amacıyla yüksek boyutlu Öklid mesafesinden yararlanır. A özellikleri için R, M ve H değerlerine dayalı olarak tahminlenen ağırlık katsayısı güncellenir ve ağırlık katsayılarının kullanımı amacıyla m kere çalıştırılır [110]. İki ayrı örnek için öznitelikler arasındaki fark, fark ile hesaplanır ve öznitelik kalitesi yukarıdaki denklemde verilir.

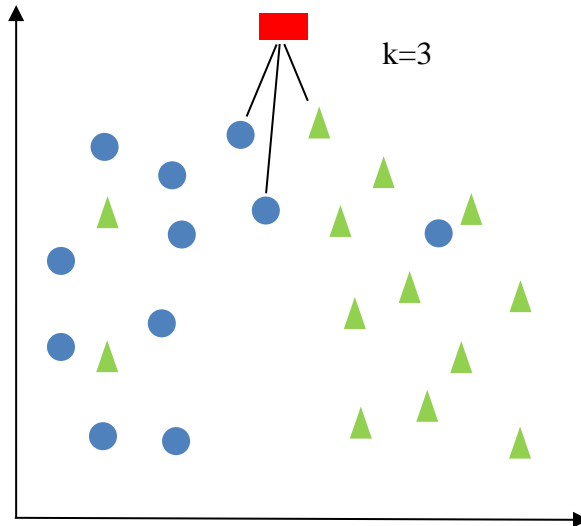
4.8 SINIFLANDIRMA ALGORİTMALARI

Sınıflandırma aşamasında elde edilen öznitelikler denetimli öğrenme ya da denetimsiz öğrenme algoritmaları ile eğitim ve test süreçlerine tabi tutulur. Önce eğitilen bir sınıflandırıcının performansı test verileri ile ne kadar iyi öğrendiği tespit edilir.

Denetimli öğrenme yöntemlerinde sınıf bilgileri bilinirken denetimsiz öğrenmede sınıf bilgileri olmadan sınıflandırma yapılır. Bu tez çalışmasında kullanılan sınıflandırıcı algoritmaları takip eden alt başlıklarda bahsedilmiştir.

4.8.1 K-En Yakın Komşu (K-nn)

Sınıflandırma algoritmaları içinde hem matematiksel olarak hem uygulanabilirliği açısından basit ama etkili bir sınıflandırıcıdır. K-nn sınıflandırıcı algoritması ayrıca bir eğitim aşamasına ihtiyaç duymayan tembel algoritmalarındandır [110]. Yani, veri seti eğitim ve test diye ayrıldıktan sonra, eğitim için ayrılan veriler üzerinde ayrıca matematiksel bir model uygulamadan sadece eğitim veri setindeki öz niteliklere karşılık gelen sınıf bilgilerinin tutulmasından ibarettir [111]. Tüm öznitelik vektörleri d boyutlu bir uzayda gösterilir. d boyutlu bu uzayda tüm örnekler bir noktaya karşı düşürülerek sınıflandırma işlemi gerçekleştirilir. Verinin hangi sınıfa ait olduğu bilgisi d boyutlu uzayda verinin k adet en yakın komşusu göz önüne alınarak saptanır (Şekil 4.17).



Şekil 4.17 K-nn sınıflandırıcısının $k=3$ en yakın değeri için örnek gösterimi.

Şekil 4.17’de gösterilen test verisi olan kırmızı renkli dikdörtgen verinin en yakın komşularının bulunması için bazı uzaklık kıstasları kullanılır. Bunlar Öklid mesafesi, Mahalanobis mesafesi, Manhattan mesafesi ve Minkowski mesafe kıstaslarıdır. Bu mesafe kıstaslarının sırasıyla matematiksel ifadeleri şu şekildedir:

$$D(x, y) = \sqrt{\sum_{k=1}^n (x_k - y_k)^2} \quad (4.9)$$

$$D(x, y) = \sqrt{(x_k - y_k)^T V^{-1} (x_k - y_k)} \quad (4.10)$$

$$D(x, y) = \sum_{k=1}^n |x_k - y_k| \quad (4.11)$$

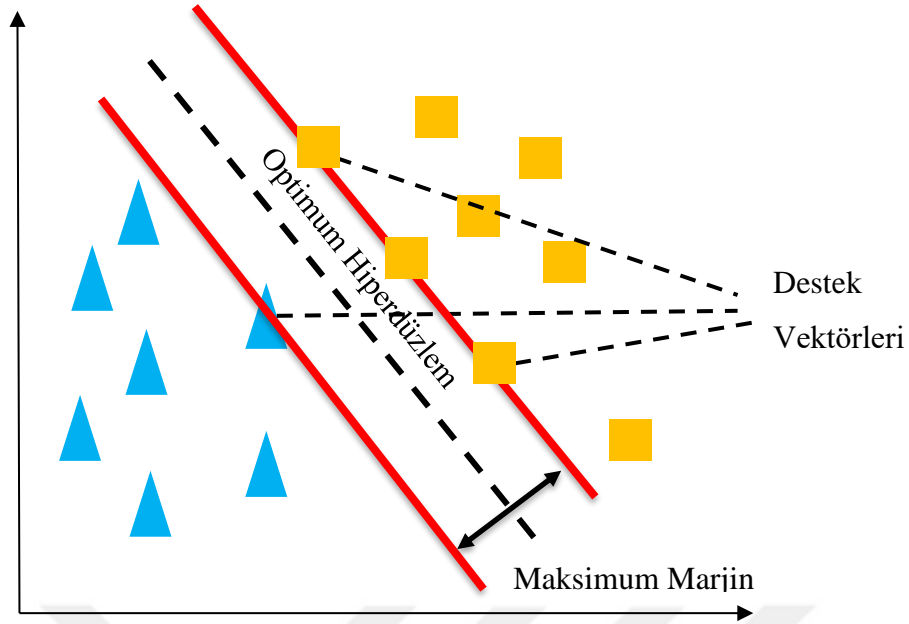
$$D(x, y) = \left(\sum_{k=1}^n (x_k - y_k)^z \right)^{\frac{1}{z}} \quad (4.12)$$

Denklemlerde kullanılan D , uzaklığı, V , kovaryans matrisini, z , ölçekleme parametresini, n ölçüm sayısını, x ve y örnekleri göstermektedir.

K-nn sınıflandırıcısında k adet en yakın komşu değeri genellikle tek sayı olarak seçilmektedir. k sayısının çift olması durumunda test edilecek verinin eşit uzaklığa sahip farklı sınıfların bulunması halinde algoritmanın atanacak sınıf bilgisine karar verememesi durumu ortaya çıkabilir.

4.8.2 Destek Vektör Makinaları

Destek vektör makinaları (DVM) istatistiksel öğrenme nazariyesi temelli bir metottur [112]. Destek vektör makinalarından tasnif ve regresyon gayesiyle doğrusal ve doğrusal olmayan veri kümelerinde istifade edilmektedir [113]. Bu metodun gayesi iki kümeyi birbirinden ayırt eden optimal düzlemin saptanmasıdır. Bu gayeyle iki kümeye de yakın ve birbirine paralel iki hudut çizgisi saptanır. Bu hudut çizgileri destek vektörleri olarak ifade edilmektedir. Bu algoritma iki hudut çizgisinden esinlenerek ortak bir düzlemin saptanması prosesini temel almaktadır (Şekil 4.18). DVM’de bazı küme elemanları doğrusal olarak bir sınıfa ayırlanamamaktadır. Bu gibi hâllerde ise çekirdek denklemlerinden yararlanılarak küme elemanları muhtelif bir boyuta doğrusal olmayan formüller ile de taşınabilir.



Şekil 4.18 DVM destek vektörleri ve optimum hiperdüzlem.

4.8.3 Doğrusal Ayraç Analizi

Linear Ayraç Analizi (LDA), aynı anda iki veya ikiden yüksek sayıda grubun ayraç fonksiyonları yardımıyla istatistiksel olarak ayrılması işlemidir. LDA özellikle sınıflandırma ve verilerin boyutlarının azaltılmasın çok kullanılır [114]. LDA'da sınıfları ayırmak için sınıf içi ve sınıflar arası dağılım denklemleri şu şekilde ifade edilir:

$$S_w = \sum_{j=1}^C \sum_{i=1}^{N_j} (x_i - \mu_i)(x_i - \mu_i)^T \quad (4.13)$$

$$S_B = \sum_{i=1}^C (\mu_i - \mu)(\mu_i - \mu)^T \quad (4.14)$$

Burada c , sınıfların sayısını, N_j sınıflardaki örnek veri sayısını, X_i sınıftaki örnekleri, μ_i , ilgili sınıftaki ortalama değeri ve μ , tüm sınıfların ortalama değerini ifade etmektedir. LDA dönüşüm matrisi:

$$W_{LDA} = \arg \max \frac{W^T S_B W}{W^T S_w W} \quad (4.15)$$

Dönüşüm tamamlandıktan sonra test edilecek veri belirlenen uzaklık ölçütü ile en yakın uzaklığa sahip olduğu sınıfa dâhil edilir [115].

4.8.4 Lojistik Regresyon

Lojistik regresyon (LR), cevap değişkeninin kategorik, iki veya daha fazla sınıf içeren kümelerin incelendiği hâllerde izah edici değişkenlerle neden sonuç bağlantıyı tespit etmek için kullanılan bir tekniktir [118]. LR, yanıt değişkeninin beklenen değerlerinin izah edici değişkenlere göre olasılıksal olarak saptandığı bir regresyon yöntemidir. Basit düzeyde ve çoklu regresyon yönteminde $\varepsilon \cong N(0, \sigma^2)$ parametresi ile bağımlı değişken normal dağılım göstermeli, bağımsız değişkenler normal dağılım göstermeli ve hata varyansı normal dağılım göstermelidir. Bu koşulları içermeyen veri kümelerine basit veya çoklu regresyon analizleri uygulanamaz. LR, bağımlı değişkenin tahmin edilen değerlerini olasılık olarak hesaplayarak olasılık kurallarına göre sınıflandırma imkânı sağlayan istatistiksel bir süreçtir.

4.8.5 Toplu Torbalı Ağaçlar

Toplu öğrenme, bazı öğrenen modellerini birlikte kullanan bir sınıflandırma yöntemidir. Torbalama, rastgele veri kümeleri oluşturan ve modelleri paralel olarak eğiten bir yöntemdir [117]. Modelleri oylama ile birleştirir. Rastgele orman (RF) torbalama işlemi için örnek bir algoritmadır. RF'de karar ağaçları rastgele oluşturulur ve paralel olarak eğitilir. Sonuçlar bir orman oluşturmak için oylama ile birleştirilir.

BÖLÜM 5

PERFORMANS ÖLÇÜTLERİ

Performans ölçütü, kullanılan sınıflandırıcı sisteminin verileri hangi oranda doğru şekilde sınıflandırabildiğinin temel tabiridir. Performans ölçütünde, en önemli hususlardan biri üzerinde çalışılan verilerin eğitim ve test kümelerine nasıl ayrıldığıdır. Çünkü eğitim ve test kümelerindeki elemanların ne oranda ayrıldığına başarımların sonucuna tesir ettiği bilinmektedir. Literatürde veriler, “hold-out” çapraz doğrulama, “k-fold” çapraz doğrulama ve “leave-one-out” çapraz doğrulama yöntemleriyle test ve eğitim kümelerine bölünmektedir. Bunlar içerisinde, k- fold çapraz doğrulama yöntemi en çok tercih edilen yöntemdir. K-fold yönteminde veriler k parçaya bölünür [118]. K parçaya ayrılan verilerin 1 parçası test amacıyla korunurken diğer k-1 adet parçadan eğitim amacıyla istifade edilir. Bu proses k kere tekrar edilip TP, TN, FP ve FN değerleri de saptanmaya çalışılır (Çizelge 5.1).

Çizelge 5.1 Hata Matrisi.

		Gerçekte olması gereken sınıf	
		Pozitif	Negatif
Tahmin edilen sınıf	Pozitif	TP Doğru Pozitif	FP Yanlış Pozitif
	Negatif	FN Yanlış Negatif	TN Doğru Negatif

Çizelge 5.1 de belirtildiği gibi aslında COVID-19(+) olup algoritmanın COVID-19(+) olarak saptadığı kişilerin sayısı TP, aslında COVID-19(+) iken algoritmanın hatalı olarak COVID-19(-) olarak saptadığı kişilerin sayısı FN, aslında COVID-19(-) olup algoritmanın COVID-19(-) olarak saptadığı kişilerin sayısı TN, COVID-19(-) iken algoritmanın hatalı olarak COVID-19(+) olarak saptadığı kişiler FP olarak tasvir edilmektedir [119]. Bu değerlerden yola çıkarak Hassaslık (Sensitivity, SEN), Özgünlük (Specificity, SPE), Pozitif Seçicilik (Positive

Predictivitiy, POS), Negatif Seçicilik (Negatif Predictivitiy, NEG) ve Genel Başarım (Accuracy, ACC) hesaplanmaktadır [120]:

$$SEN = \frac{TP}{TP + FN} \quad (5.1)$$

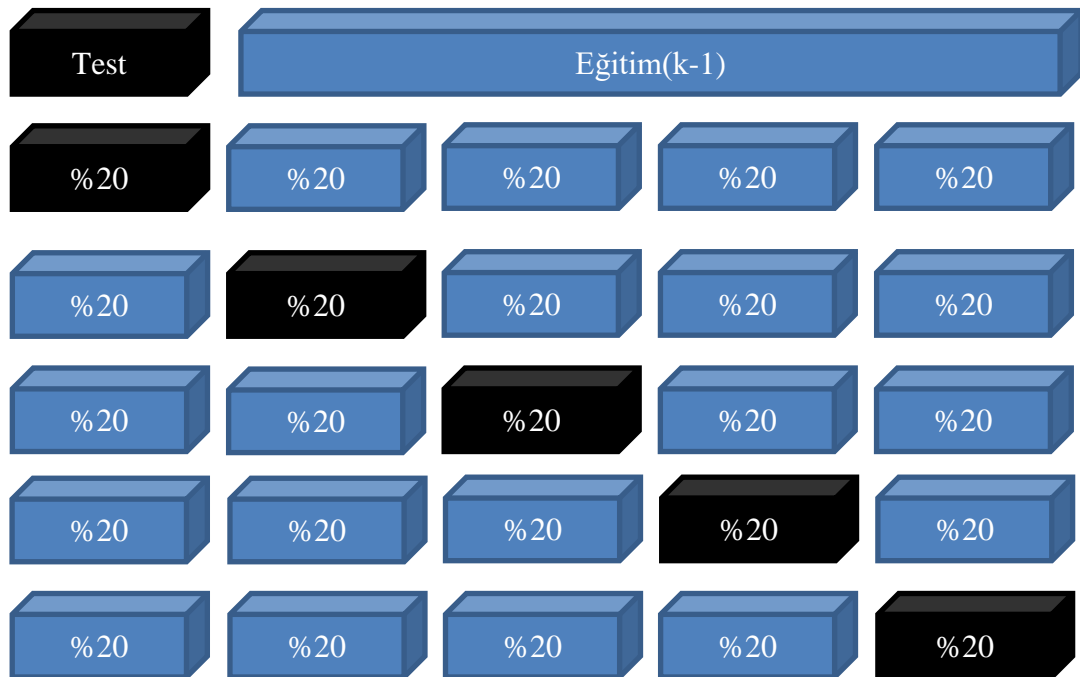
$$SPE = \frac{TN}{TN + FP} \quad (5.2)$$

$$NEG = \frac{TN}{TN + FN} \quad (5.3)$$

$$POS = \frac{TP}{TP + FP} \quad (5.4)$$

$$ACC = \frac{TP + TN}{TP + FN + FP + TN} \quad (5.5)$$

Sınıflandırıcı performanslarını belirken veriler Şekil 5.1’de gösterilen 5- katlı çapraz doğrulama metodundan yararlanılarak eğitim ve test veri kümelerine bölünmüştür. K-Katlamalı değerlendirme metodunda, veri kümesi k tane kısma bölünür. Bunlardan k-1 tanesinden eğitime amacıyla yararlanılırken 1 adedinden test amacıyla istifade edilir. Bu süreç tüm parçalardan test etme amacıyla istifade edilinceye kadar döngü tekrarlanır. Sınıflandırıcı algoritmalarının genel doğruluk değeri ise eğitim ve test amacıyla ayrı ayrı ortalamaları bulunarak sınıflandırıcı eğitim genel doğruluk ve sınıflandırıcı test genel doğruluk değeri olarak hesaplanır [121,122].



Şekil 5.1 Beş Katlı Çapraz Doğrulama Yönteminin Grafikselleştirilmesi.

BÖLÜM 6

DENEYSEL SONUÇLAR

Tezde elde edilen öksürük akustik sinyallerinin ön işleme, geleneksel ve derin öğrenme yaklaşımları ile elde edilen öznelikler, öznelik seçim süreci ve tüm performans ölçütlerinin belirlenmesi MATLAB 2020a ve python yazılımları yardımıyla gerçekleştirilmiştir. Tez konusuyla ilgili 2 adet bildiri ve 1 adet uluslararası (SCI) makale olmak üzere 3 adet çalışma yayınlanmıştır.

İlk çalışma Uluslararası Balkan Üniversitesi tarafından düzenlenen “International Conference of Applied Sciences, Engineering and Mathematics” konferansında sözlü olarak sunulmuştur. Bu çalışmada geleneksel makine öğrenmesi yaklaşımlarından yararlanılmıştır. Çalışmada temelde z-normalizasyon ve min-max normalizasyon tekniklerinin karşılaştırılması gerçekleştirilmiştir. Öznelik çıkarımı için 5 seviyeli ayırık dalgacık dönüşümü yöntemi kullanılmıştır. Sınıflandırma algoritması olarak destek vektör makineleri algoritması kullanılmıştır.

İkinci çalışma Selçuk Üniversitesi tarafından düzenlenen “5th International Conference on Engineering Technologies” konferansında sözlü olarak sunulmuştur. Bu çalışmada geleneksel makine öğrenmesi yaklaşımlarından yararlanılmıştır. Çalışmada temelde sınıflandırma algoritmalarının karşılaştırılması gerçekleştirilmiştir. Ön işleme için z-normalizasyon tekniği kullanılmıştır. Öznelik çıkarımı için 5 seviyeli deneysel mod ayrıştırma yönteminden yararlanılmıştır. Sınıflandırma algoritması için Destek Vektör Makineleri, Lojistik Regresyon, Lineer Diskriminant Analiz, k-En Yakın Komşular ve Toplu-Torbalı-Ağaçlar olmak üzere 5 farklı yöntem kullanılmıştır.

Üçüncü çalışma ise İngiltere merkezli SCI-E kapsamında taranan “Computers in Biology and Medicine” Dergisi’nde yayınlanmıştır. Bu çalışmada geleneksel makine öğrenmesi kısmında ön işleme tekniği olarak z-normalizasyon, öznelik çıkarımı için deneysel mod ayrıştırma ve ayırık dalgacık dönüşümü kullanılmıştır. Derin öğrenme kısmında deneysel mod ayrıştırma ve ayırık dalgacık dönüşümü sinyalleri üzerinden skalogram görüntüleri elde edilmiştir. Elde edilen

görüntüler üzerinde öznitelik seçimi için ReliefF algoritması kullanılmıştır. Sınıflandırma algoritması olarak ise destek vektör makineleri kullanılmıştır.



6.1 Normalizasyon Yöntemlerinin COVID-19 Tahmin Performanslarının Öksürük Akustiği Sesleri Üzerinde Karşılaştırılması

Bu araştırmada, z-normalizasyon ve min-maks normalizasyon ön işleme yöntemi olarak kullanılmıştır. Daha sonra öksürük sesleri üzerinden 5 Katmanlı ayırık dalgacık dönüşümü yöntemi kullanılarak zaman alanı ve doğrusal olmayan ölçümlerle öznelilikler çıkarılmıştır. Ayrıca çalışmada 10 katlı çapraz doğrulama yöntemi kullanılmıştır. Geleneksel makine öğrenimi yaklaşımı yöntemleriyle gerçekleştirilen bu çalışmada, sınıflandırma algoritması olarak destek vektör makinesi algoritması kullanılmıştır. Min-maks normalizasyonun kullanıldığı ilk hesaplamada F1 skoru ve genel doğruluk değeri %100 olarak bulunmuştur. Z-normalizasyonun kullanıldığı ikinci hesaplamada ise F1 skoru % 99.0 ve genel doğruluk değeri %99.2 olarak bulunmuştur. Çalışmanın amacı farklı normalizasyon tekniklerinin başarıma etkisini tespit etmektir.

6.1.1 Veri Seti


COVID-19 (+) ve COVID-19 (-) olan kişilerin öksürük sesleri <https://virufy.org/> adresinden alınmıştır. Veriler, Stanford Üniversitesi aracılığıyla geliştirilen mobil tabanlı bir uygulama ile toplanmıştır. Öksürük sesleri toplam 16 kişiye ait olup bu kişilerin 6'sı kadın, 10'u erkektir. Bu insan grubunun ortalama yaşı 42'dir. PCR testinden elde edilen sonuçlara göre tüm veriler pozitif ve negatif olarak belirtilmiştir. Bu testler sonucunda bu insan grubundan 7'si COVID 19 (+), 9'u COVID 19 (-) idi. Bu sonuçlar etiketlendi. COVID-19 (+) olarak etiketlenen çoğu insanda nefes almada zorluk, boğaz ağrısı ve öksürük gibi belirtiler görülür. Bazılarında konjestif kalp yetmezliği, astım, şeker hastalığı, bazılarında ise tat ve koku kaybı, ateş ve titreme görülür. COVID-19 (-) olarak etiketlenen kişilerden sadece birinde kronik şeker hastalığı var ve birkaçının nefes almada zorluk, boğaz ağrısı, vücut ağrıları ve kötüleşen öksürük şikâyetleri var. Elde edildiği platformdaki veriler bölümlere ayrılmış ve araştırmacıların kullanımına hazır hale getirilmiştir. Bu verilerden 9 COVID-19 (-) etiketli öksürük akustik verisi 73 parçaya, 7 COVID-19 (+) etiketli öksürük akustik verisi 48 parçaya bölünmüştür. Bu veriler çizelge 6.1'de gösterilmiştir. Her bir veri parçasının örnekleme frekansı 48 kHz, öksürme süresi ise 1640 milisaniye (ms) olarak belirlenmiştir.

Çizelge 6.1 Bildiride yararlanılan veri sayıları.

Sınıf	Veri Sayısı
COVID-19(+)	48
COVID-19(-)	73

6.1.2 Sonuçlar

Bu çalışmanın sonucunda toplam 121 örnek içeren bir veri seti elde mevcuttur. Daha önce de belirtildiği gibi bunlardan 73 tanesi COVID-19(-)(0) olan kişilere aittir. 48 tanesi ise COVID-19(+)(1) olan kişilere aittir. Min-maks normalizasyon, ayırık dalgacık dönüşümü, 10 katlı çapraz doğrulama ve destek vektör makineleri kullanılarak yapılan çalışmada 73 COVID-19(-) örneğin hepsi COVID-19(-), 48 COVID-19(+) örneğin hepsi COVID-19(+) olarak tespit edilmiştir. Z normalizasyon, ayırık dalgacık dönüşümü, 10 katlı çapraz doğrulama ve destek vektör makineleri kullanılarak yapılan ikinci çalışmada ise 73 COVID-19(-) örneğin sadece 1 tanesi COVID-19(+) olarak tespit edilmiş, 48 COVID-19(+) örneğin hepsi COVID-19(+) olarak tespit edilmiştir. Sonuçlara ait en yüksek performanslı hata matrisleri Şekil 6.1 ve Şekil 6.2 de gösterilmiştir.



Şekil 6.1 Min-maks normalizasyona dayalı en yüksek performanslı hata matrisi

Gerçek Sınıf 0	72	1
1		48
	0	1
	Tahmini Sınıf	

Şekil 6.2 Z normalizasyona dayalı en yüksek performanslı hata matrisi

6.2 Öksürük Akustik Sinyallerini Kullanarak COVID-19 Tespiti için Sınıflandırma Algoritmalarının Karşılaştırılması

Tüm veriler z-normalizasyon tekniği kullanılarak normalize edilmiştir. 5 katmanlı deneysel mod ayrıştırma yöntemi aracılığıyla elde edilen özneliklerin performansları farklı sınıflandırma algoritmaları kullanılarak karşılaştırılmıştır. Sınıflandırma algoritması olarak, 5 farklı algoritma kullanılmıştır. En yüksek doğruluk ve F1 skoru toplu-torbalı ağaçlar algoritması kullanılarak elde edilmiştir. Bu algoritma sırasıyla %90,6 genel doğruluk ve %90,5 F1 skoru sonucunu vermiştir. Diğer taraftan, çalışmada kullanılan diğer sınıflandırma algoritmaları sırasıyla Destek Vektör Makineleri, Lojistik Regresyon, Lineer Diskriminant Analiz ve k-En Yakın Komşular algoritmalarıdır. Elde edilen sonuçlara göre doğru sınıflandırıcı algoritmasının seçilmesi, yüksek sonuçlar elde edilmesine yardımcı olur. Bu sayede, doğru algoritma seçimiyle öksürük akustik verileri kullanılarak COVID-19(+) kişiler kolayca ve etkili bir şekilde tespit edilebilir.

6.2.1 Veri Seti

COVID-19(+) ve COVID-19(-) ile ilgili öksürük akustik verileri, ücretsiz erişim sitesi <https://virufy.org/>'dan elde edilmiştir. Veriler, Stanford Üniversitesi tarafından geliştirilen bir mobil uygulama tarafından sağlandı. Veriler toplam 1187 kişiye aittir. Tüm veriler RT-PCR testinden elde edilen sonuçlara göre pozitif ve negatif olarak belirlendi. Test sonucunda 595 COVID-19(+) ve 592 COVID-19(-) kişinin verileri etiketlendi. Tüm veriler gürültüden arındırıldı. Ayrıca çalışma yapılmadan önce tüm veriler z-normalizasyon yöntemi ile normalize edilmiştir.

Çizelge 6.2 Çalışmada kullanılan veri sayıları.

Sınıf	Veri Sayısı
COVID-19(+)	595
COVID-19(-)	592

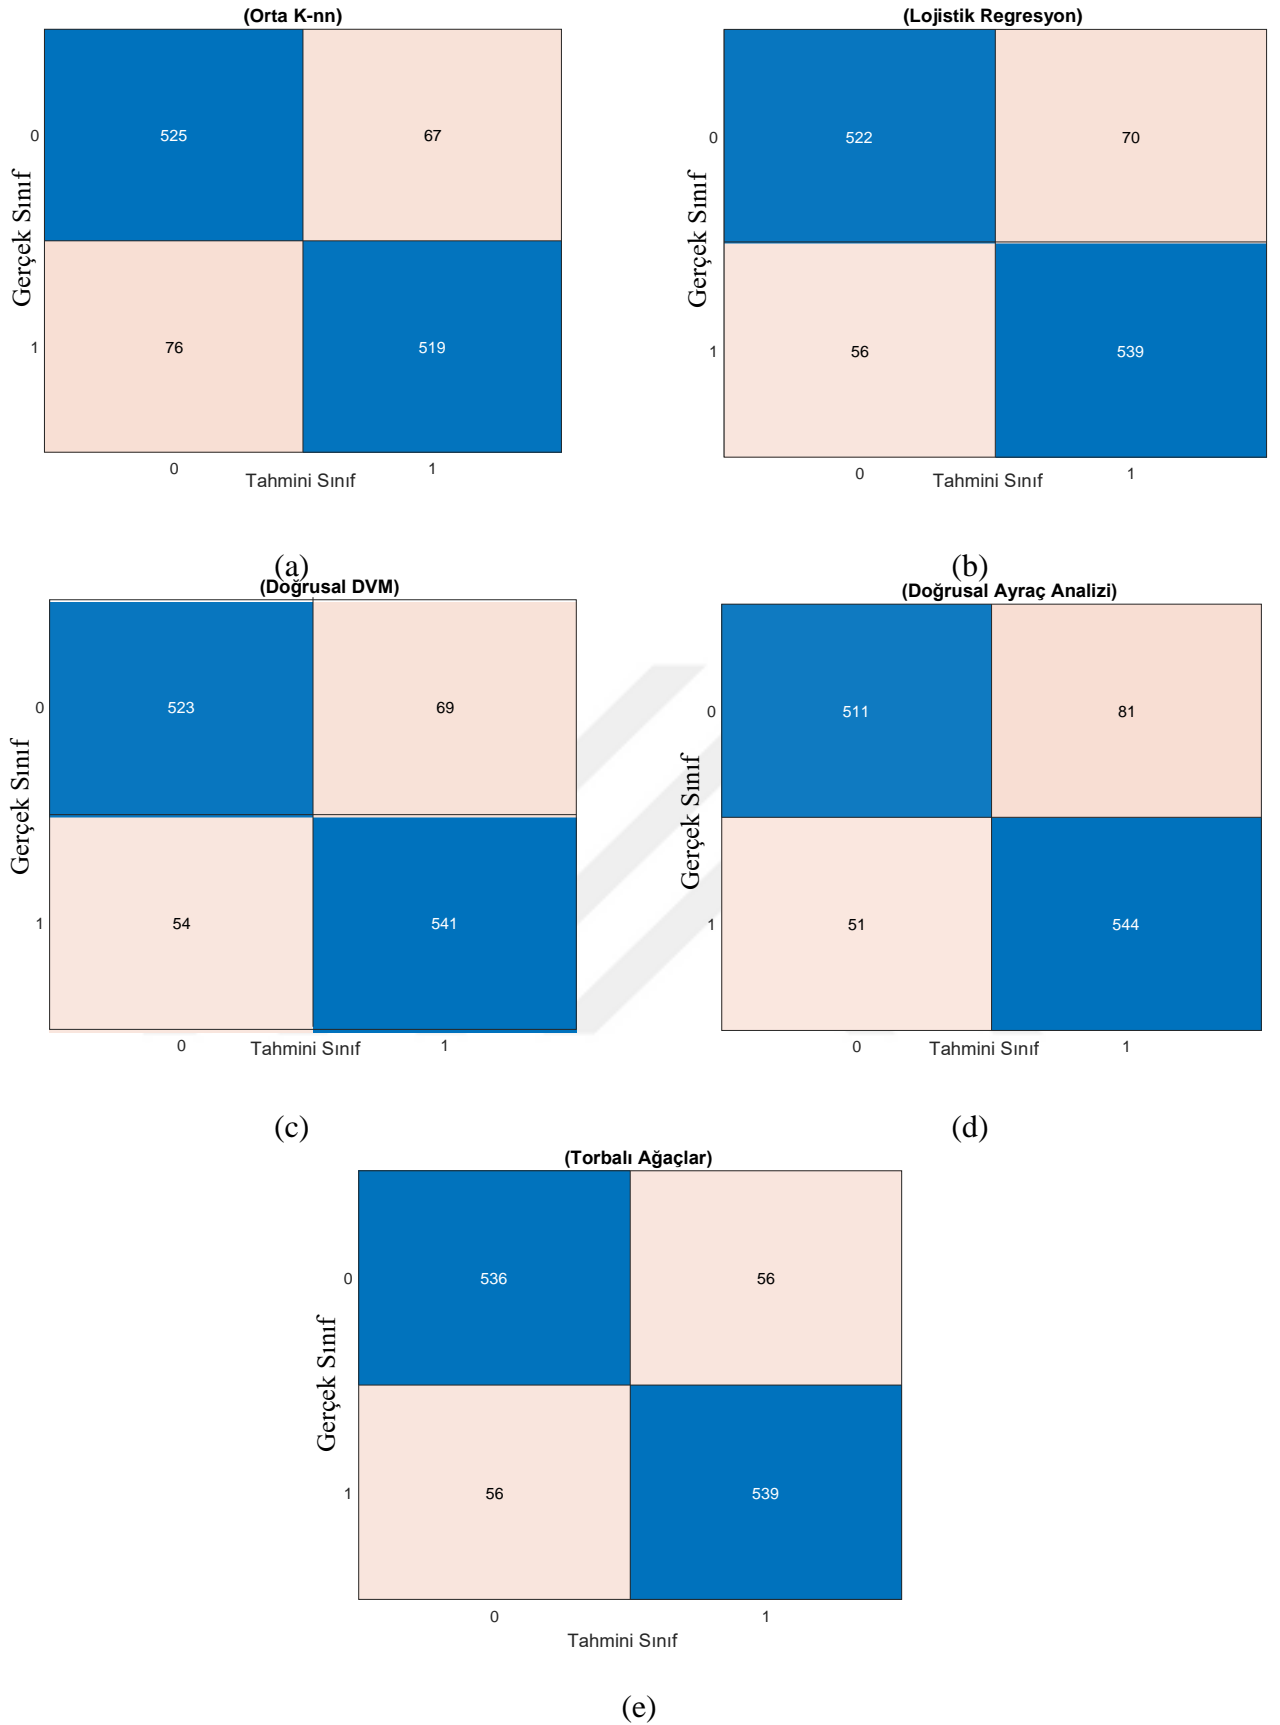
6.2.2 Sonuçlar

Bu çalışmanın sonucunda toplam 1187 kişiye bir veri seti elde mevcuttur. Daha önce de belirtildiği gibi bu verilerden 592 tanesi COVID-19(-)(0) kişilere 595 tanesi ise COVID-19(+)(1) kişilere aittir. Z-normalizasyon ile normalize edilen verilerden deneysel mod ayrıştırma yöntemi kullanılarak öznelilikler çıkarıldı. 10 katlı çapraz doğrulama yöntemiyle veriler test edildi. Toplu-Torbalı Ağaçlar algoritması kullanılarak %90,56'lık genel doğruluk değeri ve %90,54'lük F1 skoru değerleriyle en yüksek başarımlar elde edilmiştir. İkinci olarak DVM doğrusal sınıflandırma algoritmasıyla %89,64 genel doğruluk ve %89,48 F1 skoru elde edilmiştir. Üçüncü olarak Lojistik Regresyon algoritmasıyla %89,39 genel doğruluk ve %89,23 F1 skoru elde edilmiştir. Dördüncü olarak Lineer Diskriminant Analizi algoritmasıyla %88,88 genel doğruluk ve %88,56 F1 skoru elde edilmiştir. Son olarak ise K-nn algoritmasıyla %87,95 genel doğruluk ve %88,01 F1 skoru elde edilmiştir. Bütün bu sonuçlar Çizelge 6.3'te bütün kullanılan performans parametreleri ile birlikte verilmiştir. Bu sonuçlardan hareketle Toplu torbalı ağaçlar sınıflandırma algoritması kullanmak daha doğru sonuçlar vereceği ortaya konmuştur. Toplu-Torbalı Ağaçlar algoritması kullanılarak 592 COVID-19(-) kişiden 536 tanesi COVID-19(-) 56 tanesi COVID-19(+), 595 COVID-19(+) kişiden 539 COVID-19(+) 56

tanisi COVID-19(-) olarak tespit edilmiştir. DVM doğrusal sınıflandırma algoritması kullanılarak 592 COVID-19(-) kişiden 523 tanesi COVID-19(-) 69 tanesi COVID-19(+), 595 COVID-19(+)'tan 541 COVID-19(+) 54 tanesi COVID-19(-) olarak tespit edilmiştir. Lojistik regresyon sınıflandırma algoritması kullanılarak 592 COVID-19(-) kişiden 522 tanesi COVID-19(-) 70 tanesi COVID-19(+), 595 COVID-19(+)'tan 539 COVID-19(+) 56 tanesi COVID-19(-) olarak tespit edilmiştir. Lineer Diskriminant Analizi sınıflandırma algoritması kullanılarak 592 COVID-19(-) kişiden 511 tanesi COVID-19(-) 81 tanesi COVID-19(+), 595 COVID-19(+)'tan 544 COVID-19(+) 51 tanesi COVID-19(-) olarak tespit edilmiştir. Son olarak ise K-nn sınıflandırma algoritması kullanılarak 592 COVID-19(-) kişiden 525 tanesi COVID-19(-) 67 tanesi COVID-19(+), 595 COVID-19(+)'tan 519 COVID-19(+) 76 tanesi COVID-19(-) olarak tespit edilmiştir. Yukarıda açıklanan sınıflandırma algoritmalarına ait hata matrisleri şekil 6.3'te gösterilmiştir.

Çizelge 6.3 DMA tabanlı öznelikler için sınıflandırma yöntemlerinin performans karşılaştırması.

Yöntem/Algoritma	Performans Sonuçları (%)				
	Acc	Rec	Spe	Pre	F1
Toplu Torbalı Ağaçlar	90,56	90,54	90,59	90,54	90,54
DVM Doğrusal	89,64	88,34	90,92	90,64	89,48
Lojistik regresyon	89,39	88,18	90,59	90,31	89,23
Lineer Diskriminant Analizi	88,88	86,32	91,43	90,93	88,56
K-nn	87,95	88,68	87,23	87,35	88,01



Şekil 6.3 Sınıflandırma yöntemlerine ait hata matrisleri a) Orta K-nn b) Lojistik Regresyon c) Doğrusal DVM d) Doğrusal Ayraç Analizi e) Torbalı Ağaçlar (0, COVID-19(-), 1, COVID-19(+)).

6.3 Öksürük Akustik Sinyallerinde Geleneksel ve Derin Özelliklerle COVID-19 Tespiti

Bu çalışmada geleneksel makine öğrenmesi ve derin öğrenme yaklaşımları birlikte kullanılmıştır. Ön işleme kısmında z-normalizasyon yöntemi kullanılmıştır. Öznitelik çıkarımı kısmında deneysel mod ayrıştırma ve ayrık dalgacık dönüşümü yöntemlerinden yararlanılmıştır. Elde edilen öznitelikler üzerinden öznitelik seçimi işlemi için ReliefF algoritması kullanılmıştır. Derin öğrenme bölümünde ise elde edilen deneysel mod ayrıştırma ve ayrık dalgacık dönüşümü sinyalleri üzerinden skalogram görüntüleri elde edilmiştir. Sınıflandırma algoritması olarak ise destek vektör makineleri algoritmasının Lineer, Kuadratik ve Kübik algoritmaları tercih edilmiştir.

6.3.1 Veri Seti

COVID-19(+) ve COVID-19(-) ile ilgili öksürük akustik verileri, ücretsiz erişim sitesi <https://virufy.org/>'dan elde edilmiştir. Veriler, Stanford Üniversitesi tarafından geliştirilen bir mobil uygulama tarafından sağlandı. Veriler toplam 1187 kişiye aittir. Tüm veriler RT-PCR testinden elde edilen sonuçlara göre pozitif ve negatif olarak belirlendi. Test sonucunda 595 COVID-19(+) ve 592 COVID-19(-) kişinin verileri etiketlendi. Tüm veriler gürültüden arındırıldı. Ayrıca çalışma yapılmadan önce tüm veriler z-normalizasyon yöntemi ile normalize edilmiştir.

Çizelge 6.4 Makelede kullanılan veri sayıları.

Sınıf	Veri Sayısı
COVID-19(+)	595
COVID-19(-)	592

6.3.2 Sonuçlar

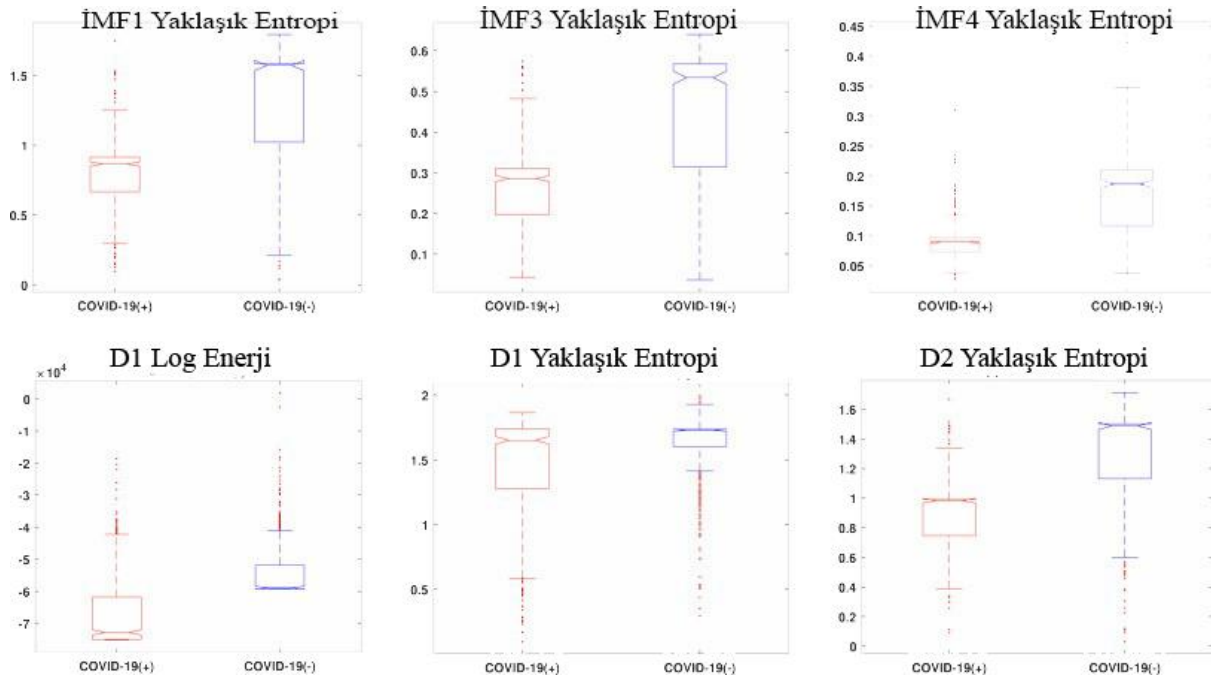
Bu çalışmanın sonucunda toplam 1187 kişiye bir veri seti elde mevcuttur. Veri seti kısmında belirtildiği üzere bu verilerden 592 tanesi COVID-19(-)(0) kişilere 595 tanesi ise COVID-19(+)(1) kişilere aittir. Bu çalışmada toplam 3 farklı öznitelik çıkarımı yöntemi denenmiştir. Bu verilere çalışmanın ilk kısmında ön işleme yöntemi olarak z-normalizasyon öznitelik çıkarımı için Deneysel Mod Ayrıştırma üzerinden 5 seviyeli İMF'ler elde edilmiştir. Standart Sapma, ortalama, karekök ortalama, Shannon Entropi, Log Enerji Entropi, Eşik Entropi, Zaman

Entropi, Norm Entropi, Yaklaşık Entropi olmak üzere toplam 9 öznitelik çıkarılmıştır. 5 adet İMF sinyali için toplam 45 adet öznitelik elde edilmiştir. Sınıflandırma algoritması olarak DVM Lineer, DVM Kuadratik ve DVM Kübik algoritmaları uygulanmıştır. En yüksek başarımlar DVM Lineer %86,0 olarak bulunmuştur. ReliefF algoritması ile öznitelik seçimi yapılmış başarımlar %91,6'ya çıkarılmıştır. Çalışmanın ikinci kısmında aynı işlemler ayrık dalgacık dönüşümü için tekrarlanmıştır. Ancak öznitelik çıkarımında 54 adet öznitelik elde edilmiştir. En yüksek performans DVM Lineer sınıflandırması algoritması kullanılarak %96,5 olarak elde edilmiştir. DVM Kuadratik ve ReliefF algoritması birlikte kullanılarak öznitelik seçimi yapılmış başarımlar %98,1'e çıkarılmıştır. Çalışmanın son kısmında ise DMA ve ADD algoritmaları birlikte kullanılarak toplam 99 adet öznitelik çıkarılmıştır. En yüksek başarımlar yine DVM Lineer algoritmasıyla % 97,6 olarak tespit edilmiştir. DVM Lineer ve ReliefF algoritması birlikte kullanılarak öznitelik seçimi yapılmış başarımlar %98,4'e çıkarılmıştır. Bütün sonuçlar Çizelge 6.5'te gösterilmiştir.

Çizelge 6.5 Tüm DMA ve tüm ADD tabanlı özniteliklerin ve ReliefF algoritması ile seçilen özniteliklerin performans karşılaştırması. Sol sütundaki performanslar tüm özniteliklerden seçilen, sağ sütundaki performanslar ReliefF tarafından seçilen özniteliklerdir. (Acc, doğruluk, Rec, hatırlama, Spe, özgüllük, Pre, kesinlik, F1, F1-skoru).

Yöntem/Algoritma	Tüm Öznitelikler için Performans Sonuçları (%)					Öznitelik Seçimi ile Performans Sonuçları (%)				
	Acc	Rec	Spe	Pre	F1	Acc	Rec	Spe	Pre	F1
DMA/DVM Lineer	86,0	88,9	83,2	84,0	86,4	89,5	91,6	87,4	87,8	89,7
DMA/DVM Kuadratik	84,7	87,5	81,8	82,7	85,1	87,3	89,2	85,4	85,9	87,5
DMA/DVM Kübik	83,7	86,5	80,8	81,8	84,1	86,5	89,0	84,0	84,7	86,8
ADD/DVM Lineer	96,5	97,5	95,5	95,5	96,5	97,2	98,3	96,1	96,2	97,2
ADD/DVM Kuadratik	94,4	96,3	92,6	92,8	94,5	98,1	99,0	97,3	97,3	98,2
ADD/DVM Kübik	93,9	95,8	91,9	92,2	94,0	97,0	98,0	96,0	96,0	97,0
DMA + ADD/DVM Lineer	97,6	98,6	96,5	96,5	97,6	98,4	99,5	97,3	97,4	98,6
DMA + ADD/DVM Kuadratik	96,2	97,5	95,0	95,1	96,2	98,1	99,3	97,0	97,1	98,2
DMA + ADD/DVM Kübik	95,3	96,6	93,9	94,1	95,3	98,0	99,2	96,8	96,9	98,1

Bu çizelgeye göre üç farklı DVM yaklaşımı ile belirlenmeye çalışılan COVID-19(+) ve COVID-19(-) sınıflarının belirlenmesinde DMA ve ADD ile elde edilen performanslar karşılaştırılmıştır. Aynı zamanda her iki yaklaşımın birleştirilmesiyle performanslar elde edilmiştir. DMA ile elde edilen sonuçlar, geleneksel yaklaşımla elde edilen sonuçlar arasında en düşük performansa sahiptir. ReliefF ile seçilen öznitelikler için performansın biraz arttığı gözlemlenmiştir. ADD ile elde edilen özniteliklerde aynı durum söz konusu değildir. Öznitelik seçimi yapılmadan bile çok yüksek sonuçlar elde edilmiştir. Aynı zamanda her iki yaklaşımın birleştirilmesiyle performanslar elde edilmiştir. DVM kuadratik ve DVM kübik algoritmalarda ReliefF ile seçilen özniteliklerin performansı önemli ölçüde artmıştır. DMA ve ADD öznitelikleri birlikte kullanılarak çok yüksek sonuçlar elde edilmektedir. Araştırmada bu öznitelikler ile en yüksek performans değerleri elde edilmiştir. DVM için lineer %98,4 doğruluk, %99,5 hatırlama, %97,3 özgüllük, %97,4 kesinlik ve %98,6 F1-skoru değerleri elde edildi. ReliefF ile seçilen DMA ve ADD özniteliklerinden üç adet yüksek performans özniteliğe ait kutu grafiği gösterimi Şekil 6.4'de verilmiştir. Burada yaklaşık entropi (İMF1, İMF3, İMF4, D1, D2), Log Enerji (D1) ölçümleri en yüksek ayırt ediciliğe sahip özniteliklerdir. Doğrusal olmayan kaotik yaklaşımlardan biri olan yaklaşık entropi ölçümünün DMA ve ADD öznitelikleri için COVID-19(+)/(-) durumlarını ayırt etmede oldukça etkili bir yöntem olduğu söylenebilir.



Şekil 6.4 DMA (üst) ve ADD (alt) için yüksek ayırt ediciliğe sahip özniteliklerin kutu grafiği gösterimi ($p < 0,001$).

İkinci çalışmada, 2B skalogram görüntülerinin girdi olarak verildiği KSA modellerinden elde edilen derin öznitelikler kullanılmıştır. ResNet50 ve MobileNet KSA modellerinin her biri için ayrı ayrı 1000 derin öznitelik elde edildi. Bu özniteliklerden elde edilen performans sonuçları ve ReliefF yöntemi yardımıyla seçilen öznitelikler Çizelge 6.6'da detaylı olarak sunulmuştur.

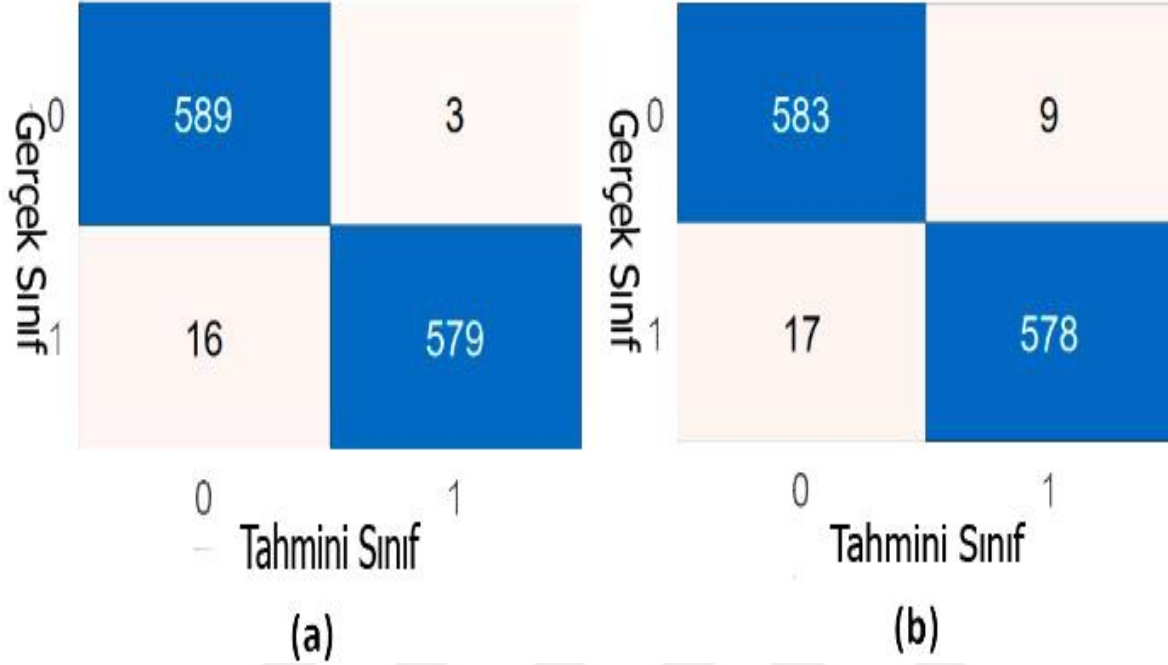
Çizelge 6.6 ReliefF algoritması ile seçilen derin öznitelikler ile derin özniteliklerin performans karşılaştırması. Sol sütundaki performansların tümü derin özniteliklerdir, sağ sütundaki performanslar ReliefF tarafından seçilen derin özniteliklerdir. (Acc, doğruluk, Rec, hatırlama, Spe, özgüllük, Ön, kesinlik, F1, F1-skoru).

Yöntem/Algoritma	Tüm Öznitelikler için Performans Sonuçları (%)					Öznitelik Seçimi ile Performans Sonuçları (%)				
	Acc	Rec	Spe	Pre	F1	Acc	Rec	Spe	Pre	F1
MobileNet/DVM Lineer	82.5	85.6	79.3	80.5	83.0	85.0	88.2	81.8	82.9	85.4
MobileNet/DVM Kuadratik	80,6	84,0	77,3	78,6	81,2	86,0	89,4	82,7	83,7	86,4
MobileNet/DVM Kübik	80,1	84,0	76,3	77,9	80,8	87,3	89,9	84,7	85,4	87,6
ResNet50/DVM Lineer	78,3	81,6	75,1	76,5	79,0	85,2	87,2	83,2	83,8	85,4
ResNet50/DVM Kuadratik	86,1	88,2	84,0	84,6	86,4	97,4	97,6	97,1	97,2	97,5
ResNet50/DVM Kübik	84,0	86,1	81,9	82,5	84,3	97,8	98,5	97,3	97,4	98,0

Bu Çizelgeye göre derin özniteliklerde öznitelik seçimi nedeniyle performansların önemli ölçüde arttığı görülmektedir. ResNet50 ile elde edilen özniteliklerin MobileNet ile elde edilen özniteliklere göre daha başarılı olduğu sonucuna varılmıştır. En yüksek performans değeri, ReliefF ile ResNet50 derin özniteliklerinin seçiminden elde edilmiştir. Bu performanslar %97,8 doğruluk, %98,5 hatırlama, %97,3 özgüllük, %97,4 kesinlik ve %98,0 F1-skoru değerleri olarak belirlendi.

Geleneksel makine öğrenimi yaklaşımlarıyla elde edilen sonuçlardan en yüksek performans sonucu için hata matrisi Şekil 6.5-(a)'da verilmiştir. COVID-19(+) sınıfındakilerden 16'sı yanlış tespit edilirken, COVID-19(-) sınıfındakilerden sadece 3'ünün yanlış tespit edildiği açıktır.

Derin özniteliklerin kullanıldığı çalışmada en yüksek performansa sahip hata matrisi Şekil 6.5-(b)'de verilmiştir. COVID-19(+) sınıfındakilerden 17'si yanlış tespit edilirken, COVID-19(-) sınıfındakilerin 9'unun yanlış tespit edildiği söylenebilir.



Şekil 6.5 En yüksek performanslara ait hata matrisleri a) geleneksel özniteliklerden b) derin özniteliklerden. (0, COVID-19(-), 1, COVID-19(+)).

Son olarak bu konuyla ilgili literatürde yapılan çalışmalar ortaya konmuş ve birçok farklı yöntem ve sınıflandırma algoritmasının denendiği görülmüştür. Bu çalışmaların birçoğunda yüksek başarımlar elde edilmiştir. Ancak bizim çalışmamız diğer yöntemlerden farklı olarak MFCC dışında farklı bir öznitelik çıkarımı yönteminin literatüre eklenmesini sağlamıştır. Bulunan sonuçlar bu çalışmanın yapıldığı zaman için literatürde bulunan çalışmalarla karşılaştırıldığında çok yüksek bir genel doğruluk sonucu vermiştir. Yapılan çalışmanın COVID-19'un tespitinde çok önemli bir yere sahip olduğu bir kez daha ortaya konulmuştur.



BÖLÜM 7

TARTIŞMA

Son yılların en çok konuşulan konularından biri de hiç şüphesiz COVID-19 vakalarıdır. Bu salgından kurtulmanın en önemli aşaması doğru tespit sürecidir. Bu nedenle literatürde makine öğrenmesi tabanlı birçok çalışma bulunmaktadır [12,13]. Farklı bir yaklaşım sunan öksürük akustik sinyalleri ile COVID-19(+) vakalarının tespiti mevcut alternatif yaklaşımlar arasında yer almaktadır. Bu çalışmalarda daha çok geleneksel makine öğrenmesi yaklaşımları kullanılmaktadır.

Pahar ve ark. ResNet50 KSA modeli ile %95 doğruluk elde edilmiştir. Laguarda ve ark. önceden eğitilmiş 3 paralel ResNet50 modelini kullanarak %98,5 duyarlılık değeri ve %94,2 özgüllük değeri elde etti. Sharma ve ark. Coswara adlı bir veri setinden rastgele orman sınıflandırıcı test verileri için %66,74'lük genel doğruluk değerini belirledi. Mouawad ve ark. 5 farklı sınıflandırma algoritması ile yüksek performans elde ettiklerini bildirmişlerdir. Öksürük sinyallerinden ortalama %97 doğruluk elde ettiler. Pal ve Sankarasubbu, TabNet adlı 4 sınıflı (COVID-19, Asthma, Bronchitis ve Healthy) yöntemle 95.04 ± 0.18 özgüllük ve 96.83 ± 0.18 doğruluk elde etti. İmran ve ark. DVM sınıflandırma algoritmasını kullanarak %95,6 genel doğruluk elde etti. Tüm bu çalışmalarda Mel Frekans Sepstral Katsayıları (MFCCs) yöntemi kullanılarak elde edilen öznitelikler ve görüntüler kullanılmıştır.

Tezde, COVID-19(+) ve COVID-19(-) sınıflarını ayırt etmek için 5 seviyeli deneysel mod ayrıştırma ve 5 seviyeli ayrık dalgacık dönüşümü ile öznitelik çıkarımı yapılmıştır. Her seviyedeki sinyallerden 9 ölçüm elde edilmiştir. ReliefF yöntemi ile öznitelik seçimi yapılarak performanslar analiz edilmiştir. En yüksek %98,4 Doğruluk ve %98,6 F1-skoru değerleri, DVM (doğrusal) ile DMA ve ADD ölçümleri ve ReliefF öznitelik seçimi kullanılarak elde edilmiştir. Derin özniteliklerin kullanıldığı diğer araştırmamızda, skalogram görüntüleri kullanılarak ResNet50 ve MobileNet'ten elde edilen öznitelikler ve ReliefF tarafından seçilen öznitelikler kullanılarak performanslar analiz edilmiştir. Sonuç olarak en yüksek %97,8 Doğruluk ve %98,0 F1-skoru değerleri tezde elde edilmiştir. Geleneksel öznitelik yaklaşımlarıyla elde edilen

özniteliklerin derin özniteliklere göre daha yüksek performans gösterdiği açıkça ifade edilebilir. Ayrıca, yaklaşık entropi ölçümleri, doğrusal olmayan ölçümlerden en yüksek ayrımcılığa sahip öznitelikler arasındadır. Tezi diğer çalışmalardan ayıran hususlar şu şekilde özetlenebilir:

1) Öksürük akustik sinyallerine dayalı COVID-19(+) hastalarının tespiti, geleneksel makine öğrenme yaklaşımları ve derin öğrenme yaklaşımları ile gerçekleştirilmiştir.

2) DMA ve ADD yöntemlerinin performansları analiz edildi.

3) 2B skalogram görüntülerinden elde edilen derin özniteliklerin performansları araştırıldı.

4) ReliefF yöntemi ile öznitelik seçimi yapılmıştır. Ayrımcılığı en yüksek olan öznitelikler belirlendi.

5) Çok yüksek doğrulukla çalışan alternatif bir hibrit yaklaşımla COVID-19(+) kişilerin belirlenmesi için uzmanlara bir karar destek sistemi önerilmiştir.

Görüntüleme tekniklerine alternatif olarak, COVID-19(+) hastalarının tespitinin öksürük akustik sinyallerine dayanabilmesi esastır. Bu yöntem, bir akıllı telefon uygulaması ve bir bilgisayar uygulaması olarak kolayca entegre edilebilir. Bu sayede salgını kontrol altına almak daha kolay hale gelebilir. Sonuç olarak bir kişiyi bile salgından koruyabilmek bu salgın sürecinde en faydalı görevlerden biridir. Tüm dünyayı etkisi altına alan bu salgında doğruluğu yüksek bu tür sistemlerin önemli katkı sağlayacağına inanıyoruz. Derin özniteliklerin geleneksel yöntemlere göre daha düşük performans göstermesinin nedenlerinden biri sınırlı sayıda veridir. Verilerin sınırlı sayıda olması çalışmanın dezavantajlarından biridir. Farklı merkezlerden alınan veri sayısının artırılması daha kararlı sistemler sağlayacaktır.

KAYNAKLAR

- [1] **Biscayart C, Angeleri P, Lloveras S, Chaves T, Schlagenhaut P, Rodriguez-Morales A J** (2020) The next big threat to global health? 2019 novel coronavirus (2019-nCoV): what advice can we give to travellers? - interim recommendations, from the Latin-American society for Travel Medicine (SLAMVI). *Travel Medicine and Infectious Disease*, 33: 101567.
- [2] **Rodriguez-Morales A J, Bonilla-Aldana D K, Balbin-Ramon G J, Paniz-Mondolfi A, Rabaan A, Sah R** (2020) History is repeating itself: Probable zoonotic spillover as the cause of the 2019 novel Coronavirus Epidemic. *Infez Med*, 28(1): 3-5.
- [3] **Liu W, Yue X** (2020) Response to the COVID-19 Epidemic : The Chinese Experience and Implications for Other Countries. *International Journal of Environmental Research and Public Health*, 17(7): 2304.
- [4] **Guan W, Liang W, Zhao Y, Liang H, Chen Z, Li Y, Ni Z** (2020) Comorbidity and its impact on 1590 patients with COVID-19 in China: a nationwide analysis. *European Respiratory Journal*, 55(5).
- [5] **Cascella M, Rajnik M, Cuomo A, Dulebohn S C and Di Napoli R** (2020) Features Evaluation and Treatment Coronavirus (COVID-19). Uniformed Services University Of The Health Sciences.
- [6] **Lai C C, Shih T P, Ko W C, Tang H J and Hsueh P R** (2020) Severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2) and coronavirus disease-2019 (COVID-19): The epidemic and the challenges. *International journal of antimicrobial agents*, 55(3): 105924.
- [7] **Menni C, Sudre C H, Steves C J, Ourselin S and Spector T D** (2020). Correspondence Quantifying additional will save lives. *The Lancet*, 395(10241): e107-e108.
- [8] **Zhang L, Pang R, Qiao Q, Wang Z, Xia X, Wang C and Xu X** (2020) Successful recovery of COVID-19-associated recurrent diarrhea and gastrointestinal hemorrhage using convalescent plasma. *Military Medical Research*, 7(1): 1-6.
- [9] **Lim J and Lee J** (2020) Current laboratory diagnosis of coronavirus disease 2019. *The Korean Journal of Internal Medicine*, 35(4): 741.
- [10] **Ardakani A, A, Kanafi A, R, Acharya U, R, Khadem N and Mohammadi A** (2020) Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks. *Computers in biology and medicine*, 121: 103795.
- [11] **He C, Wang D, Sun J, Gan W and Lu J** (2020) The Role of Imaging Techniques in Management of COVID-19 in China : From Diagnosis to Monitoring and Follow-Up.

KAYNAKLAR (devam ediyor)

Medical science monitor: international medical journal of experimental and clinical research, 26: e924582-1.

- [12] **Hariri W and Narin A** (2021) Deep neural networks for COVID-19 detection and diagnosis using images and acoustic-based techniques: a recent review. *Soft computing*, 25(24): 15345-15362.
- [13] **Shoeibi A, Khodatars M, Alizadehsani R, Ghassemi N and Jafari M** (2020) Automated Detection and Forecasting of COVID-19 using Deep Learning Techniques : A Review. *arXiv preprint arXiv:2007.10785*.
- [14] **Science N, Phenomena C, Swapnarekha H, Sekhar H, Nayak J and Naik B** (2020) Role of intelligent computing in COVID-19 prognosis: A state-of-the-art review. *Chaos, Solitons & Fractals*, 138: 109947.
- [15] **Ranjan S, Ranjan D, Sinha U and Arora V** (2021) Application of deep learning techniques for detection of COVID-19 cases using chest X-ray images: A comprehensive study. *Biomedical Signal Processing and Control*, 64: 102365.
- [16] **Islam M, M, Karray F, Alhadj R and Zeng J** (2021) A Review on Deep Learning Techniques for the Diagnosis of Novel Coronavirus (COVID-19). *Ieee Access*, 9: 30551-30572.
- [17] **Khan M A, Kadry S, Zhang Y, Akram T, Sharif M, Rehman A and Saba T** (2021) Prediction of COVID-19-pneumonia based on selected deep features and one class kernel extreme learning machine. *Computers & Electrical Engineering*, 90: 106960.
- [18] **Turkoglu M** (2021) COVIDetectionNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble. *Applied Intelligence*, 51(3): 1213-1226.
- [19] **Shiri I, Sorouri M, Geramifar P, Nazari M, Abdollahi M, Salimi Y, Zaidi H** (2021) Machine learning-based prognostic modeling using clinical data and quantitative radiomic features from chest CT images in COVID-19 patients. *Computers in biology and medicine*, 132: 104304.
- [20] **Xu W, Sun N, N, Gao H, N, Chen Z, Y, Yang Y and Ju B** (2021) Risk factors analysis of COVID - 19 patients with ARDS and prediction based on machine learning. *Scientific reports*, 11(1): 1-12.
- [21] **Bartlett D** (1989) Respiratory functions of the larynx. *Physiological reviews*, 69(1): 33-57.
- [22] **Shiba K** (2010) Functions of larynx in breathing, vocalization and airway protective reflexes. *Handbook of Behavioral Neuroscience*, 19: 373-381.
- [23] **Korpáš J, Sadloňová J ve Vrabec M** (1996) Analysis of the cough sound: An overview. *Pulmonary pharmacology*, 9(5-6): 261-268.

KAYNAKLAR (devam ediyor)

- [24] **Jernigan D B, COVID C and Team R** (2020) Update: public health response to the coronavirus disease 2019 outbreak—United States, February 24, 2020. *Morbidity and mortality weekly report*, 69(8): 216.
- [25] **Public Health Agency of Canada** (2020). Coronavirus disease 2019 (COVID-19): Epidemiology update.
- [26] **Smith J, Ashurst H, Jack S, Woodcock A and Earis J** (2006) The description of cough sounds by healthcare professionals. *Cough*, 2(1): 1-9.
- [27] **Auwaerter P G** (2020) Coronavirus COVID-19 (SARS-2-CoV). *Johns Hopkins ABX Guide*.
- [28] **Brenneis R** (2020) COVID-19 (Corona Virus Disease 2019): Pathophysiology and Clinical Findings. *The Calgary Guide to Understand. Disease*.
- [29] **Yilmaz I** (2019) Angiotensin-converting enzyme inhibitors induce cough. *Turkish thoracic journal*, 20(1): 36.
- [30] **Farzan S** (1990) Cough and sputum production. *Clinical Methods: The History, Physical, and Laboratory Examinations. 3rd edition*.
- [31] **Tian S, Xiong Y, Liu H, Niu L, Guo J, Liao M and Xiao S Y** (2020) Pathological study of the 2019 novel coronavirus disease (COVID-19) through postmortem core biopsies. *Modern Pathology*, 33(6): 1007-1014.
- [32] **Robertson S, Azizpour H, Smith K and Hartman J** (2018) Digital image analysis in breast pathology—from image processing techniques to artificial intelligence. *Translational Research*, 194: 19-35.
- [33] **Usman M, Latif S, Asim M, Lee B D and Qadir J** (2020) Retrospective motion correction in multishot MRI using generative adversarial network. *Scientific reports*, 10(1): 1-11.
- [34] **Usman M, Lee B D, Byon S S, Kim S H and Lee B** (2019) Volumetric lung nodule segmentation using adaptive roi with multi-view residual learning. *Scientific Reports*, 10(1): 1-15.
- [35] **Qin Z Z, Sander M S, Rai B, Titahong C N, Sudrungrot S, Laah S N, Adhikari L M, Carter E J, Puri L, Codlin A J** (2019) Using artificial intelligence to read chest radiographs for tuberculosis detection: A multi-site evaluation of the diagnostic accuracy of three deep learning systems. *Scientific reports*, 9(1): 1-10.
- [36] **Singh R, Kalra M K, Nitiwarangkul C, Patti J A, Homayounieh F, Padole A, Rao P, Putha P, Muse V V, Sharma A** (2018) Deep learning in chest radiography: detection of findings and presence of change. *PloS one*, 13(10): e0204155.
- [37] **Ai T, Yang Z, Hou H, Zhan C, Chen C, Lv W, Tao Q, Sun Z and Xia L** (2020) Correlation of chest CT and RT-PCR testing in coronavirus disease 2019 (COVID-19) in China: a report of 1014 cases. *Radiology*.

KAYNAKLAR (devam ediyor)

- [38] **Li Y and Xia L** (2020) Coronavirus disease 2019 (COVID-19): role of chest CT in diagnosis and management. *Ajr Am J Roentgenol*, 214(6): 1280-1286.
- [39] **Wang S, Kang B, Ma J, Zeng X, Xiao M, Guo J, Cai M, Yang J, Li Y, Meng X** (2021) A deep learning algorithm using CT images to screen for Corona Virus Disease (COVID-19). *European radiology*, 31(8): 6096-6104.
- [40] **Xu X, Jiang X, Ma C, Du P, Li X, Lv S, Yu L, Chen Y, Su J, Lang G** (2020) A deep learning system to screen novel coronavirus disease 2019 pneumonia. *Engineering*, 6(10): 1122-1129.
- [41] **Chen J, Wu L, Zhang J, Zhang L, Gong D, Zhao Y, Hu S, Wang Y, Hu X, Zheng B** (2020) Deep learning-based model for detecting 2019 novel coronavirus pneumonia on high-resolution computed tomography. *Scientific reports*, 10(1): 1-11.
- [42] **Zhou Z, Siddiquee M M R, Tajbakhsh N and Liang J** (2018) Unet++: A nested u-net architecture for medical image segmentation. *Deep learning in medical image analysis and multimodal learning for clinical decision support*, Stoyanov D(ed.)and Taylor Z(ed.),ISBN: 978-3-030-00889-5, Springer International Publishing, Cham, 3-11.
- [43] **Gozes O, Frid-Adar M, Greenspan H, Browning P D, Zhang H, Ji W, Bernheim A and Siegel E** (2020) Rapid AI development cycle for the coronavirus (COVID-19) pandemic: initial results for automated detection & patient monitoring using deep learning CT image analysis. *ArXiv, 2003*, v3.
- [44] **Li L, Qin L, Xu Z, Yin Y, Wang X, Kong B, Bai J, Lu Y, Fang Z, Song Q** (2020) Artificial intelligence distinguishes COVID-19 from community acquired pneumonia on chest CT. *Radiology*.
- [45] **Shan F, Gao Y, Wang J, Shi W, Shi N, Han M, Xue Z, Shen D and Shi Y** (2020) Lung infection quantification of COVID-19 in CT images with deep learning. *arXiv preprint arXiv:2003.04655*.
- [46] **Zhang J, Xie Y, Li Y, Shen C and Xia Y** (2020) Viral pneumonia screening on chest X-rays using confidence-aware anomaly detection. *IEEE transactions on medical imaging*, 40(3): 879-890.
- [47] **Barstugan M, Ozkaya U and S. Ozturk** (2020) Coronavirus (covid-19) classification using ct images by machine learning methods. *arXiv preprint arXiv:2003.09424*.
- [48] **Zhao J, Zhang Y, He X and Xie P** (2020) COVID-CT-dataset: a CT scan dataset about COVID-19. *arXiv preprint arXiv:2003.13865*.
- [49] **Gozes O, Frid-Adar M, Sagie N, Zhang H, Ji W and Greenspan H** (2020) Coronavirus detection and analysis on chest ct with deep learning. *arXiv preprint arXiv:2004.02640*.

KAYNAKLAR (devam ediyor)

- [50] **Asnaoui K E, Chawki Y and Idri A** (2021) Automated methods for detection and classification pneumonia based on x-ray images using deep learning. *Artificial Intelligence and Blockchain for Future Cybersecurity Applications. Studies in Big Data*,90: 257-284.
- [51] **Department of Health and Social Care** (2017) Ionising radiation (medical exposure) regulations 2017: guidance.
- [52] **El-Din Hemdan E, Shouman M A and 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*.
- [53] **Simonyan K ve Zisserman A** (2014) Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [54] **Howard A G, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T, Andreetto M and Adam H** (2017) Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- [55] **Wang L and 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.
- [56] **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.
- [57] **He K, Zhang X, Ren S, Sun J** (2016) Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 27 Haziran 2016, Las Vegas, Nevada, 770-778.
- [58] **Farooq M and Hafeez A** (2020) Covid-resnet: A deep learning framework for screening of covid19 from radiographs. *arXiv preprint arXiv:2003.14395*.
- [59] **Sethy P K and Behera S K** (2020) Detection of coronavirus disease (covid-19) based on deep features.
- [62] **Alqudah A M, Qazan S, Alquran H, Qasmieh I A and Alqudah A** COVID-2019 detection using X-ray images and artificial intelligence hybrid systems, 2:1.
- [63] **Ghoshal B and Tucker A** (2020) Estimating uncertainty and interpretability in deep learning for coronavirus (COVID-19) detection. *arXiv preprint arXiv:2003.10769*.
- [64] **Salman F M, Abu-Naser S S, Alajrami E, Abu-Nasser B S and Ashqar B A** (2020) Covid-19 detection using artificial intelligence.
- [65] **Li X and Zhu D** (2020) Covid-mobilexpert: On-device covid-19 screening using snapshots of chest x-ray. *arXiv preprint arXiv:2004.03042*.

KAYNAKLAR (devam ediyor)

- [66] **Karim M, Dohmen T, Reholz-Schuhmann D, Decker S, Cochez M, Beyan O** (2020) DeepCOVIDExplainer: Explainable COVID-19 diagnosis based on chest X-ray images. *arXiv preprint arXiv:2004.04582*.
- [67] **Apostolopoulos I D and 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.
- [68] **Song I** (2015) Diagnosis of pneumonia from sounds collected using low cost cell phones. *2015 International joint conference on neural networks (IJCNN)*, 12-17 Temmuz 2015, Killarney, Ireland, 1-8
- [69] **Schuller B W, Schuller D M, Qian K, Liu J, Zheng H and Li X** (2020) Covid-19 and computer audition: An overview on what speech & sound analysis could contribute in the sars-cov-2 corona crisis. *Frontiers in digital health*, 14.
- [70] **Rana R, Latif S, Gururajan R, Gray A, Mackenzie G, Humphris G and Dunn J** (2019) Automated screening for distress: A perspective for the future. *European journal of cancer care*, 28(4), e13033.
- [71] **Amiriparian S, Pugachevskiy S, Cummins N, Hantke S, Pohjalainen J, Keren G and Schuller B** (2017) CAST a database: Rapid targeted large-scale big data acquisition via small-world modelling of social media platforms. *2017 Seventh International Conference on Affective Computing and Intelligent Interaction (ACII)*, 23-26 Ekim 2017, San Antonio, TX, USA, 340-345.
- [72] **Moradshahi P, Chatzarrin H and Goubran R** (2012) Improving the performance of cough sound discriminator in reverberant environments using microphone array. *2012 IEEE International Instrumentation and Measurement Technology Conference Proceedings*, 13-16 Mayıs 2012, Graz, Austria, 20-23.
- [73] **Olubanjo T and Ghovanloo M** (2014) Tracheal activity recognition based on acoustic signals. *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 26-30 Ağustos 2014, Chicago, IL, USA, 1436-1439.
- [74] **Imran A, Posokhova I, Qureshi H N, Masood U, Riaz M S, Ali K, Nabeel M** (2020) AI4COVID-19: AI enabled preliminary diagnosis for COVID-19 from cough samples via an app. *Informatics in Medicine Unlocked*, 20: 100378.
- [75] **Laguarta J, Hueto F and Subirana B** (2020) COVID-19 artificial intelligence diagnosis using only cough recordings. *IEEE Open Journal of Engineering in Medicine and Biology*, 1: 275-281.
- [76] **Alsabek M B, Shahin I and Hassan A** (2020) Studying the Similarity of COVID-19 Sounds based on Correlation Analysis of MFCC. In *2020 international conference on communications, computing, cybersecurity, and informatics (CCCI)*, 03-05 Kasım 2020, Sharjah, United Arab Emirates, 1-5.

KAYNAKLAR (devam ediyor)

- [77] **Sharma N, Krishnan P, Kumar R, Ramoji S, Chetupalli S R and Ganapathy S** (2020) Coswara--a database of breathing, cough, and voice sounds for COVID-19 diagnosis. *arXiv preprint arXiv:2005.10548*.
- [78] **Mouawad P, Dubnov T and Dubnov S** (2021) Robust detection of COVID-19 in cough sounds. *SN Computer Science*, 2(1): 1-13.
- [79] **Pal A and Sankarasubbu M** (2021) Pay attention to the cough: Early diagnosis of COVID-19 using interpretable symptoms embeddings with cough sound signal processing. *Proceedings of the 36th Annual ACM Symposium on Applied Computing*, 12-26 Mart 2021, Virtual Event Republic of Korea, 620-628.
- [80] **Pahar M, Klopper M, Warren R and Niesler T** (2020) COVID-19 cough classification using machine learning and global smartphone recordings. *Computers in Biology and Medicine*, 135: 104572.
- [81] **Tena A, Claria F and Solsona F** (2022) Detecting Bulbar Involvement in Patients with Amyotrophic Lateral Sclerosis Based on Phonatory and Time-Frequency Features. *Sensors*, 22(3): 1137
- [82] **Brown C, Chauhan J, Grammenos A, Han J, Hasthanasombat A, Spathis D, Xia T, Cicuta P, Mascolo C** (2020) Exploring automatic diagnosis of COVID-19 from crowdsourced respiratory sound data. *arXiv preprint arXiv:2006.05919*.
- [83] **Despotovic V, Ismael M, Cornil M, Mc Call R, Fagherazzi G** (2021) Detection of COVID-19 from voice, cough and breathing patterns: Dataset and preliminary results. *Computers in Biology and Medicine*, 138: 104944.
- [84] **Islam R, Abdel-Raheem E, Tarique M** (2022) A study of using cough sounds and deep neural networks for the early detection of COVID-19. *Biomedical Engineering Advances*, 3: 100025.
- [85] **Rahman T, Ibtehaz N, Khandakar A, Hossain M S A, Mekki Y M S, Ezeddin M, Bhuiyan E H, Ayari M A Tahir A, Qiblawey Y** (2022) QUCoughScope: An Intelligent Application to Detect COVID-19 Patients Using Cough and Breath Sounds. *Diagnostics*, 12(4): 920.
- [86] **Erdoğan Y E ve Narin A** (2021) COVID-19 detection with traditional and deep features on cough acoustic signals. *Computers in Biology and Medicine*, 136: 104765.
- [87] **Erdoğan Y E ve Narin A** (2022) Comparison of COVID-19 Prediction Performances of Normalization Methods on Cough Acoustics Sounds, *International Conference of Applied Sciences and Mathematics(ICASEM 2021)*,3 Haziran 2021, Virtual IBU Campus, Skopje,16-22.

KAYNAKLAR (devam ediyor)

- [88] **Erdoğan Y E ve Narin A** (2022) Comparison of COVID-19 Prediction Performances of Normalization Methods on Cough Acoustics Sounds, *2021 5th International Conference on Engineering Technologies(ICENTE 2021)*, 18-20 Kasım 2021, Virtual Selçuk Üniversitesi, Konya, 62-67
- [89] **Huang N E, Shen Z, Long S R, Wu M C, Snin H H, Zheng Q, Liu H H** (1998) The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, 454(1971): 903-995.
- [90] **Melillo P, Izzo R, Orrico A, Scala P, Attanasio M** (2015) Automatic prediction of cardiovascular and cerebrovascular events using heart rate variability analysis. *PloS one*, 10(3): e0118504.
- [91] **Kaya C, ErKaymaz O, Ayar O ve Özer M** (2018) Impact of hybrid neural network on the early diagnosis of diabetic retinopathy disease from video-oculography signals. *Chaos, Solitons & Fractals*, 114: 164-174.
- [92] **Daubechies I** (1996) Where do wavelets come from? A personal point of view. *Proceedings of the IEEE*, 84(4): 510-513.
- [93] **Budu K** (2014) Comparison of wavelet-based ANN and regression models for reservoir inflow forecasting. *Journal of Hydrologic Engineering*, 19(7): 1385-1400.
- [94] **Narin A** (2022) Detection of focal and non-focal epileptic seizure using continuous wavelet transform-based scalogram images and pre-trained deep neural networks. *IRBM*, 43(1):22-31.
- [95] **Jadhav P, Rajguru G and Datta D** (2020) Original Automatic sleep stage classification using time-frequency images of CWT and transfer learning using convolution neural network. *Biocybernetics and Biomedical Engineering*, 40(1): 494-504.
- [96] **Tesauro G** (1991) Practical Issues in Temporal Difference Learning. *Proceedings of the 4th International Conference on Neural Information Processing Systems*, Moody JE(ed.) ,Lippman D S((ed.) and Hanson SJ(ed.), ISBN: 1558602224, Morgan Kaufmann Publishers Inc. San Francisco, CA, USA, 259-266.
- [97] **Lee T S and Mumford D** (2003) Hierarchical Bayesian inference in the visual cortex. *JOSA A*, 20(7): 1434-1448.
- [98] **BENGIO Y** (2009) Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1): 1-127.
- [99] **Fukushima K** (1983) Neocognitron: A neural network model for a mechanism of visual pattern recognition. *IEEE transactions on systems, man, and cybernetics*, 13(5): 826-834.

KAYNAKLAR (devam ediyor)

- [100] **Cireřan D, Meier U, Schmidhuber J** (2012) Multi-column deep neural networks for image classification. *2012 IEEE conference on computer vision and pattern recognition*, 16-21 June 2012, Providence, RI, USA, 3642-3649.
- [101] **He K, Zhang X, Ren S, Sun, J** (2016) Detecting affect states using VGG16, ResNet50 and SE-ResNet50 networks. *SN Computer Science*, 1(2): 1-7.
- [102] **Russakovsky, O, Deng J, Su H, Krause J, Satheesh S, Ma S, Huang Z, Karpathy A, Khosla A, Bernstein M, Berg A C, Fei Fei L** (2015) Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115(3): 211-252.
- [103] **Uçar M** (2021) Glokom Hastalığının Evriřimli Sinir Ağı Mimarileri ile Tespiti. *Dokuz Eylöl Üniversitesi Mühendislik Faköltesi Fen ve Mühendislik Dergisi*, 23(68): 521-529.
- [104] **Lecun Y ve Kavukcuoglu K** (2010) Convolutional networks and applications in vision. In *Proceedings of 2010 IEEE international symposium on circuits and systems*, 30 Mayıs 2010 - 02 Haziran 2010, Paris, France, 253-256.
- [105] **Wu Z, Shen C and van den Hengel A** (2019) Wider or deeper: Revisiting the resnet model for visual recognition. *Pattern Recognition*, 90: 119-133.
- [106] **Duda R O, Hart P E and Stork D G** (2000) *Pattern Classification*, 2nd Edition, ISBN: 978-0-471-05669-0, Wiley-Interscience, New York, 688 pp/s.
- [107] **Kira K ve Rendell L A** (1992) A Practical Approach to Feature Selection. *Machine Learning Proceedings 1992*, Sleeman D (ed.) and Edwards P (ed.), ISBN: 978-1-55860-247-2, Morgan Kaufmann Publishers Inc. San Francisco, CA, USA, 249-256.
- [108] **Kononenko I** (1994) Estimating attributes: Analysis and extensions of RELIEF. In *European conference on machine learning*, 784: 171-182.
- [109] **Staćzyk U and Jain L C** (2015) Feature selection for data and pattern recognition: an introduction. In *Feature Selection for Data and Pattern Recognition*, Staćzyk U(ed.), ISBN: 978-3-662-45620-0, Springer Berlin Heidelberg ,Berlin, Heidelberg,1-7.
- [110] **Martínez-Otzeta J M, Sierra B, Lazkano E and Astigarraga A** (2006) K Nearest Neighbor Edition to Guide Classification Tree Learning: Motivation and Experimental Results. *Data Mining: Theory, Methodology, Techniques, and Applications*, Williams G J (ed.), ISBN: 978-3-540-32548-2, Springer Berlin Heidelberg, Berlin, Heidelberg, 53-63.
- [111] **Parekh R, Yang J and Honavar V** (2000) Constructive neural-network learning algorithms for pattern classification. *IEEE Transactions on neural networks*, 11(2): 436-451.
- [112] **Vapnik V N** (1999) An overview of statistical learning theory. *IEEE transactions on neural networks*, 10(5), 988-999.

KAYNAKLAR (devam ediyor)

- [113] **Kang, S, Byun H and Lee S W** (2002) Real-time pedestrian detection using support vector machines. *International journal of pattern recognition and artificial intelligence*, 17(3): 405-416.
- [114] **Jain A K, Duin R P W and Mao J** (2000) Statistical pattern recognition: A review. *IEEE Transactions on pattern analysis and machine intelligence*, 22(1): 4-37.
- [115] **Osman M Z, Maarof M A, Rohani M F, Sjarif N N A and Zulkifli N S A** (2020) A multi-color based features from facial images for automatic ethnicity identification model. *Indonesian Journal of Electrical Engineering and Computer Science*, 18(3): 1383-1390.
- [116] **Adavi M, Salehi M and Roudbari M** (2016) Artificial neural networks versus bivariate logistic regression in prediction diagnosis of patients with hypertension and diabetes. *Medical journal of the Islamic Republic of Iran*, 30: 312.
- [117] **Banfield R E, Hall L O, Bowyer K W and Kegelmeyer W P** (2006) A comparison of decision tree ensemble creation techniques. *IEEE transactions on pattern analysis and machine intelligence*, 29(1): 173-180.
- [118] **Erdoğan Y E ve Narin A** (2021) Performance of empirical mode decomposition in automated detection of hypertension using electrocardiography. *2021 29th Signal Processing and Communications Applications Conference (SIU)*, 09-11 Haziran 2021, Istanbul, Turkey, 1-4.
- [119] **Isler Y, Narin A, Ozer M ve Perc M** (2019) Multi-stage classification of congestive heart failure based on short-term heart rate variability. *Chaos, Solitons & Fractals*, 118: 145-151.
- [120] **Erdoğan Y E ve Narin A** (2022) Elektrokardiyografi Yardımıyla Hipertansiyonun Otomatik Belirlenmesinde Ampirik Kip Ayırışımının Gürültülü ve Gürültüsüz Sinyaller Üzerindeki Performansının Karşılaştırılması. *El-Cezeri*, 9(2): 788-800.
- [121] **Rodríguez J D, Pérez A and Lozano J A** (2009) Sensitivity analysis of k-fold cross validation in prediction error estimation. *IEEE transactions on pattern analysis and machine intelligence*, 32(3): 569-575.
- [122] **Isler Y, Narin A ve Ozer M** (2015) Comparison of the effects of cross-validation methods on determining performances of classifiers used in diagnosing congestive heart failure. *Measurement Science Review*, 15(4): 196.

ÖZGEÇMİŞ

Yunus Emre ERDOĞAN 2013 yılında kazandığı Dokuz Eylül Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü'nden 2019 yılında mezun oldu. Daha sonra 2020 yılında Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. 2020 yılı Ocak ayından bu yana Ereğli Demir ve Çelik Fabrikaları T.A.Ş.(ERDEMİR) şirketinde mühendis olarak çalışmaktadır.