

**BİYOMEDİKAL GÖRÜNTÜLERİN SINIFLANDIRILMASI
İÇİN YENİ BİR EVRİŞİMLİ SINIR AĞI MİMARİSİ**

**A NOVEL CONVOLUTIONAL NEURAL NETWORK
ARCHITECTURE FOR CLASSIFICATION OF
BIOMEDICAL IMAGES**

ÖZNUR ÖZALTIN

PROF. DR. ÖZGÜR YENİAY

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

İstatistik Anabilim Dalı için Öngördüğü

DOKTORA TEZİ olarak hazırlanmıştır.

Ocak-2023

ÖZET

BİYOMEDİKAL GÖRÜNTÜLERİN SINIFLANDIRILMASI İÇİN YENİ BİR EVRİŞİMLİ SİNİR AĞI MİMARİSİ

Öznur ÖZALTIN

Doktora, İstatistik Bölümü

Tez Danışmanı: Prof. Dr. Özgür YENİAY

Eş Danışman: Uzm. Dr. Orhan COŞKUN

Ocak 2023, 107 sayfa

Evrışimli sinir ağları (CNN) derin öğrenmenin özelleştirilmiş hali olup son dönemde yaygın olarak kullanılan yapay zekâ algoritmalarındandır. Biyomedikal görüntüler gibi karmaşık verileri kolayca ayırt edebilmektedir. Bu çalışmada 34 katmanlı yeni bir CNN mimarisi önerilmiştir. Önerilen bu mimari OzNet olarak isimlendirilmiştir. OzNet, çeşitli biyomedikal verilerin sınıflandırılması için uygulanmış ve oldukça yüksek performans göstermiştir. Bu çalışmada ilk olarak tek boyutlu elektrokardiyogram (ECG) sinyal veri seti kullanılmıştır. Bu veriler, sürekli dalgacık dönüşümü (CWT) ile iki boyutlu görüntülere dönüştürülmüş ve OzNet ile sınıflandırılmıştır. OzNet aynı zamanda AlexNet ve SqueezeNet ile karşılaştırılmış ve bu önceden eğitilmiş mimarilerden daha etkili bir şekilde sınıflandırmıştır. Bu çalışmada, OzNet mimarisinin etkinliğini artırmak için destek vektör makineleri (SVM) ile OzNet birleştirilmiştir. Sonuç olarak ECG veri setinin sınıflandırılmasında, Oznet-SVM mimarisi ile %99.21'lik doğruluk oranı elde edilmiştir. Bu çalışmada ikinci olarak koronavirüs (COVID-19) bilgisayarlı tomografi (CT)

görüntüleri kullanılmıştır. Bu görüntüler, çeşitli ön işlem yöntemleri kullanılarak, OzNet ve önceden eğitilmiş mimariler ile sınıflandırılmıştır. Elde edilen sonuçlara göre ayırık dalgacık dönüşümü (DWT), mimarilerin sınıflandırma performansını artırmıştır. COVID-19 CT görüntülerinin sınıflandırılmasında, DWT-OzNet mimarisi %99.5'lik bir doğruluk oranı elde etmiştir. Bu çalışmada üçüncü olarak beyin kanama türlerini içeren CT görüntüleri kullanılmıştır. OzNet bu görüntüler üzerinde de yüksek sınıflandırma başarısı elde etmiştir. Fakat sonuçların daha başarılı olması ve çalışmanın güvenilirliğini artırmak için komşuluk bileşenler analizi (NCA) ve makine öğrenme algoritmalarıyla birleştirilmiştir. Burada OzNet, otomatik özellik çıkarıcı olarak kullanılmıştır. Tam bağlantılı katmandan her bir görüntü için 4096 özellikler elde edilmiştir. Bu özellikler, minimum kayıpla önemli ve bilgilendirici özelliklere sahip olacak şekilde NCA tarafından indirgenmiştir. Daha sonra bu önemli özellikler sınıflandırıcılar ile sınıflandırılmıştır. Deneysel sonuçlara göre, yapay sinir ağları (ANN) ile elde edilen OzNet-NCA-ANN yapısı %100 doğruluk oranı ile en iyi sınıflandırıcı modeli olmuştur.

Anahtar Kelimeler: Evrişimli sinir ağları, Görüntü işleme, Ön işleme, Özellik seçimi, Sınıflandırma, Makine öğrenmesi, Yapay zekâ.

ABSTRACT

A NOVEL CONVOLUTIONAL NEURAL NETWORK ARCHITECTURE FOR CLASSIFICATION OF BIOMEDICAL IMAGES

Öznur ÖZALTIN

Doctor of Philosophy, Department of Statistics

Supervisor: Prof. Dr. Özgür YENİAY

Co- Supervisor: Uzm. Dr. Orhan COŞKUN

January 2023, 107 pages

Convolutional neural networks (CNN) are a specialized version of deep learning and widely used among artificial intelligence algorithms recently. It can easily distinguish complex data such as biomedical images. In this study, a new CNN architecture which has 34 layers was proposed. This proposed architecture was named as OzNet. OzNet was applied for the classification of various biomedical data and obtained quite high performances. First, one-dimensional electrocardiogram (ECG) signal dataset was used in this study. The dataset was converted into two-dimensional images with continuous

wavelet transform (CWT) and classified with OzNet. In addition, OzNet was compared to AlexNet and SqueezeNet and classification results displayed that OzNet was more effective than these architectures. In this study, it was combined with support vector machines (SVM) to increase the efficiency of performance. As a result, Oznet-SVM architecture obtained an accuracy of 99.21% for the classification of the ECG dataset. Next, coronavirus (COVID-19) computerized tomography (CT) images were used in this study. These images were classified with OzNet and pre-trained architectures using various preprocessing methods. According to the findings, discrete wavelet transforms (DWT) increased the classification performance of architectures. Eventually, DWT-OzNet architecture achieved an accuracy of 99.5% in the classification of COVID-19 CT images. Finally, CT images which were including brain hemorrhage types were applied in this study. OzNet also achieved high classification success on these images. However, it was combined with neighborhood component analysis (NCA) and machine learning algorithms to obtain more successful results and increase the reliability of the study. In this part, OzNet was employed as an automatic feature extractor and 4096 features were acquired from the fully connected layer for each image. These features were reduced by using NCA to get significant and informative features with minimal loss. Then, reduced features were classified with classifiers. According to the experimental results, OzNet-NCA-ANN structure obtained through artificial neural networks (ANN) was the best classifier model with 100% accuracy.

Keywords: Artificial intelligence, Convolutional neural networks, Feature selection, Image processing, Machine learning, Pre-processing.

TEŐEKKÜR

Doktora eđitim sürecim boyunca desteđini esirgemeyen, bana her konuda yardımcı olan ve başarabileceđime olan inancı benden daha çok olan sevgili ve saygıdeđer danıőmanım Prof. Dr. Özgür YENİAY'a sonsuz teşekkürlerimi sunarım. Tez izleme sürecinde destekleri ve bana olan inançları için deđerli hocalarım Dr. Öğr. Üyesi Murat KÖKLÜ ve Dr. Öğr. Üyesi Onur TOKA'ya, desteđini esirgemeyen ve ikinci danıőmanım olan Uzm. Dr. Orhan COŐKUN'a, deđerli bilgilerini esirgemedен paylaşan ve beni destekleyen saygıdeđer hocam Prof. Dr. Abdulhamit SUBAŐI hocama, Hacettepe İstatistik bölümündeki tüm kıymetli hocalarıma ve mesai arkadaşlarıma teşekkürlerimi sunarım.

Beni her konuda destekleyen sevgili annem Hatice DOĐAN'a, babam Mehmet DOĐAN'a, kardeőim Ebru ŐENCAN'a ve eőim Mustafa ÖZALTIN'a saygı ve teşekkürlerimi sunarım. Hayatımın en önemli iki eseri olan sevgili ođullarım Kađan ÖZALTIN ve Yusuf ÖZALTIN'a sonsuz sevgi ve teşekkürlerimi sunarım.

Öznur ÖZALTIN

ANKARA-2023

İÇİNDEKİLER

ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER.....	vi
ÇİZELGELER DİZİNİ	x
KISALTMALAR	xii
1. GİRİŞ	1
1.1. Amaç ve Kapsam	1
1.2. Literatür.....	4
1.2.1. ECG Verilerinin Kullanıldığı Çalışmalar.....	4
1.2.2. COVID-19 CT Verilerinin Kullanıldığı Çalışmalar.....	9
1.2.3. Beyin Kanaması CT Verilerinin Kullanıldığı Çalışmalar	15
2. MATERYAL VE YÖNTEM	20
2.1. Veri Setleri	20
2.1.1. ECG Veri Seti.....	21
2.1.2. COVID-19 CT Veri Seti	22
2.1.3. Beyin Kanaması CT Veri Seti	24
2.2. Ön İşleme Yöntemleri	27
2.2.1. Dalgacık Dönüşümü	27
2.2.1.1. Sürekli Dalgacık Dönüşümü	28
2.2.1.2. Ayrık Dalgacık Dönüşümü.....	30
2.2.2. Yoğunluk Ayarlama Yöntemi	32
2.2.3. Griden Renkli RGB Dönüşümü	33
2.3. Evrişimli Sinir Ağları	34
2.3.1. Önceden Eğitilmiş Evrişimli Sinir Ağları	36
2.3.2. OzNet: Yeni bir CNN Mimarisi	39

2.4. Özellik Seçim Yöntemleri	42
2.4.1. Komşuluk Bileşenler Analizi (NCA) ile Özellik Seçimi.....	42
2.4.2. Ki-kare (χ^2) ile Özellik Seçimi.....	43
2.4.3. Minimum Fazlalık Maksimum İlişki (mRMR) ile Özellik Seçimi.....	44
2.5. Sınıflandırma Algoritmaları.....	44
2.5.1. Yapay Sinir Ağları (ANN).....	45
2.5.2. Karar Ağacı (DT).....	45
2.5.3. K-En Yakın Komşu (KNN)	46
2.5.4. Doğrusal Diskriminant Analizi (LDA)	46
2.5.5. Naive Bayes (NB).....	47
2.5.6. Destek Vektör Makineleri (SVM)	47
2.5.7. Adaboost	47
2.5.8. Torbalama	48
2.6. Veri Artırma.....	49
2.7. Çapraz Doğrulama	50
2.8. Performans Ölçütleri.....	50
3. DENEYSEL SONUÇLAR VE TARTIŞMA	52
3.1. ECG Veri Seti Sınıflandırma Sonuçları.....	52
3.2. COVID-19 CT Veri Seti Sınıflandırma Sonuçları.....	59
3.3. Beyin Kanaması CT Veri Setinde Sınıflandırma Sonuçları	68
3.4. Tartışma	86
4. SONUÇ	88
5. KAYNAKLAR	92
EKLER.....	108
EK 1 - Tezden Türetilmiş Yayınlar	108
EK 2 - Tezden Türetilmiş Bildiriler.....	109
EK 3 - Tez Çalışması Orjinallik Raporu.....	110
ÖZGEÇMİŞ	111

ŞEKİLLER DİZİNİ

Şekil 2.1.	ECG sinyallerinin sınıflandırılma aşamalarını gösteren akış şeması.	22
Şekil 2.2.	(a) Ham CT tarama görüntüsü. (b) Gri kanallı histogram grafiği.	23
Şekil 2.3.	CT taramalarının sınıflandırılma aşamalarını gösteren akış şeması.	23
Şekil 2.4.	Çalışmada kullanılan segmente edilmiş İntraparankimal Kanama örneği.	25
Şekil 2.5.	Beyin Kanama görüntülerini sınıflandırma şeması.	26
Şekil 2.6.	Dalgacık örnekleri [108, 109].....	28
Şekil 2.7.	1-D ECG sinyalinin CWT dönüşümü sonrası elde edilen skalogram örneği.	30
Şekil 2.8.	(a) Tek seviyeli DWT ile işlenmiş CT tarama görüntüsü. (b) DWT ile işlenmiş CT tarama görüntüsünün histogramı.....	31
Şekil 2.9.	COVID-19 CT veri setinde uygulanan ayrık dalgacık dönüşümünün akış şeması.	32
Şekil 2.10.	(a) Yoğunluk ayarlama yöntemi ile işlenmiş CT tarama görüntüsü..... (gama 2) (b) Yoğunluk ayarlama yöntemi ile işlenmiş CT taramasının görüntü histogramı.....	33
Şekil 2.11.	(a) Griden renkli RGB yöntemi ile işlenmiş CT tarama görüntüsü (b) Griden renkli RGB yöntemi ile işlenmiş CT taramasının görüntü histogramı.	34
Şekil 2.12.	Önerilen OzNet mimarisinin şeması.....	38
Şekil 3.1.	CNN mimarilerinin için farklı sinyal uzunlukları ve ana dalgacık fonksiyonları için sınıflandırma performansları.	53
Şekil 3.2.	OzNet mimarisinin, farklı sinyal uzunlukları ve ana dalgacık fonksiyonları için sınıflandırma performansları.	53
Şekil 3.3.	OzNet'in eğitim ilerlemesinin doğruluk oranı ve kayıp grafiği.	54
Şekil 3.4.	(a) Ham CT tarama görüntüleri, (b) DWT-CT tarama görüntüleri, (c) Yoğunluk ayarlama yöntemi ile işlenmiş CT tarama görüntüleri (d) Griden renkli RGB'ye dönüştürülmüş CT tarama görüntüleri.	60
Şekil 3.5.	Ham ve ön işlenmiş COVID-19 CT tarama verilerinde OzNet'in performans ölçütleri histogram grafiği.	65

Şekil 3.6.	Ham ve ön işlenmiş COVID-19 CT tarama verilerinde OzNet'in ROC eğrisi grafiği.	66
Şekil 3.7.	Çalışmada kullanılan beyin kanaması türlerinin CT görüntüleri.	68
Şekil 3.8.	OzNet'in eğitim, doğrulama ve kayıp grafiği.	69
Şekil 3.9.	OzNet'in üç farklı veri setleri üzerinden ROC eğrileri.	72
Şekil 3.10.	Tolerans değerine göre seçilen özellikler.	79

ÇİZELGELER DİZİNİ

Çizelge 1.1.	Son yıllarda yapılan ECG verileri sınıflandırma çalışmaları.....	7
Çizelge 1.2.	Son yıllarda yapılan COVID-19 CT görüntülerini sınıflandırma sonuçları.	13
Çizelge 1.3.	Son yıllarda Beyin CT görüntülerini sınıflandırma sonuçları.	19
Çizelge 2.1.	OzNet mimarisinin katmanlarının detayları.	40
Çizelge 2.2.	Karışıklık matrisi örneği [159]	50
Çizelge 3.1.	OzNet, AlexNet ve SqueezeNet mimarilerinin performans ölçütleri.	55
Çizelge 3.2.	ECG veri seti için 5 kez eğitilen OzNet'in performans ölçütleri.....	56
Çizelge 3.3.	OzNet-SVM algoritmasının performans sonuçları.....	56
Çizelge 3.4.	Tüm sınıflandırma algoritmalarının performans ölçütleri bakımından karşılaştırılması.....	57
Çizelge 3.5.	OzNet-SVM algoritmasının karışıklık matrisi.	58
Çizelge 3.6.	ECG çalışmalarının sınıflandırma performansları.....	58
Çizelge 3.7.	Ham COVID-19 CT tarama veri setini kullanan CNN mimarilerinin performans ölçütleri yönünden karşılaştırılması.	61
Çizelge 3.8.	DWT- COVID-19 CT tarama veri setinde kullanan CNN mimarilerinin performans ölçütleri yönünden karşılaştırılması.	61
Çizelge 3.9.	Yoğunluk ayarlama yöntemi- COVID-19 CT tarama veri setinde CNN mimarilerinin performans ölçütleri yönünden karşılaştırılması.	62
Çizelge 3.10.	Griden renkli RGB'ye dönüştürme yöntemi- COVID-19 CT tarama veri setinde CNN mimarilerinin performans ölçütleri yönünden karşılaştırılması.....	62
Çizelge 3.11.	Ham ve ön işlenmiş COVID-19 CT tarama verilerinde OzNet'in karışıklık matrisi.	63
Çizelge 3.12.	COVID-19 CT Tarama görüntülerinin önceki sınıflandırılma çalışmaları ile DWT-OzNet algoritmasının karşılaştırılması.....	67
Çizelge 3.13.	Üç farklı veri seti için OzNet'in performans ölçütleri.....	70
Çizelge 3.14.	OzNet'in üç farklı veri setleri için karışıklık matrisleri.	71
Çizelge 3.15.	Üç farklı veri seti için ResNet-18'in performans ölçütleri.	73

Çizelge 3.16. Üç farklı veri seti için MobileNetv2'nin performans ölçütleri.	73
Çizelge 3.17. Üç farklı veri seti için ShuffleNet'in performans ölçütleri.	73
Çizelge 3.18. Üç farklı veri seti için CNN-1'in performans ölçütleri.	73
Çizelge 3.19. Üç farklı veri seti için CNN-2'nin performans ölçütleri.	74
Çizelge 3.20. Üç farklı veri seti için hibrit algoritmaların performans ölçütleri.	76
Çizelge 3.21. Her bir deney için tolerans ve hata değerleri.	78
Çizelge 3.22. Üç farklı veri seti için NCA kullanılarak elde edilen hibrit algoritmaların performans ölçütleri.	81
Çizelge 3.23. OzNet hibrit algoritmalarının NCA kullanılarak farklı veri setleri için karışıklık matrisleri.	83
Çizelge 3.24. Üç farklı veri seti için OzNet-Ki-kare-ANN algoritmasının performans ölçütleri.	84
Çizelge 3.25. Üç farklı veri seti için OzNet-mRMR-ANN algoritmasının performans ölçütleri.	84
Çizelge 3.26. Önceki çalışmalar ile performans karşılaştırması.	85
Çizelge 3.27. Çeşitli biyomedikal verilerinin sınıflandırmasında OzNet mimarisinin performans sonuçları.	86

KISALTMALAR

Kısaltmalar

ANN	Yapay Sinir Ağları
ARR	Aritmi
AUC	Eğri Altında Kalan Alan
CNN	Evrişimli Sinir Ağları
CHF	Konjektif Kalp Yetmezliği
CT	Bilgisayarlı Tomografi
CWT	Sürekli Dalgacık Dönüşümü
COVID-19	Koronavirüs Hastalığı
DWT	Ayrık Dalgacık Dönüşümü
EDH	Epidural Kanama
ECG	Elektrokardiyogram
ICH	İntraserebral Kanama
IoT	Nesnelerin İnterneti
IPH	İntraparankimal Kanama
IVH	İntraventriküler Kanama
KNN	K-En Yakın Komşu
LDA	Doğrusal Diskriminant Analizi
MRI	Manyetik Rezonans Görüntüleme
mRMR	Minimum Fazlalık Maksimum İlişki
NB	Naive Bayes
NCA	Komşuluk Bileşenler Analizi
NSR	Normal Sinüs Ritmi
RGB	Kırmızı, Yeşil, Mavi

ROC	Alıcı İşlem Karakteristiđi
SAH	Subaraknoid Kanama
SDH	Subdural Kanama
STFT	Kısa Zamanlı Fourier Dönüşümü
SVM	Destek Vektör Makineleri
WHO	Dünya Sağlık Örgütü
WT	Dalgacık Dönüşümü
X-Ray	X Işımı

1. GİRİŞ

1.1. Amaç ve Kapsam

Biyomedikal sinyallerin, görüntülerin ve seslerin kaliteli bir şekilde işlenmesi, otomatik olarak sınıflandırılması hastalıkların bilgisayar sistemlerinden tespiti bakımından oldukça önemlidir. İnsan yaşamını kolaylaştırıcı algoritmaların geliştirilmesi, istenen ve beklenen durum haline gelmiştir. Yapay zekanın da (Artificial intelligence) ortaya çıkmasıyla birlikte bu konudaki gelişmeler hız kazanmıştır. İnsan nüfusunun artması, ekolojik dengenin değişimi ile birlikte çeşitli hastalıkların artması ve salgın hastalıkların ortaya çıkması sonucunda hastalıkların bilgisayar sistemlerinden otomatik olarak tespit edilebilmesi oldukça önem kazanmıştır. Bu çalışmanın temel amacı, biyomedikal sinyallerin ve görüntülerin kaliteli bir şekilde sınıflandırmasını sağlayacak bir algoritma geliştirmektir. Bu kapsamda Derin Öğrenme (Deep Learning) algoritmalarından yararlanılmıştır. Derin öğrenme algoritmaları yapay zekanın en önemli buluşlarından biridir. Derin öğrenmenin kademeli öğrenme sistemi sayesinde biyomedikal görüntüler gibi karmaşık yapıda olan veriler kolayca ayırt edilebilmektedir. Bu özelliği sebebiyle son yıllarda yapılan çalışmalarda oldukça yaygın bir şekilde kullanılmaktadır. Bu algoritmaların araştırmacılar tarafından bu kadar yaygın kullanılmasının bir başka sebebi ise otomatik özellik çıkarımı yapabilmesidir. Bu sayede uzman görüşüne gerek olmaksızın cihazlardan otomatik sınıflandırma sonuçları elde edilerek çeşitli hastalıkların erken teşhis edilmesi sağlanabilecektir. Sınıflandırmaların anlık ve başarılı sonuçlanabilmesinin kapılarını derin öğrenme algoritmaları aralamıştır.

Bu çalışmada, derin öğrenme algoritmalarından Evrişimli Sinir Ağlarından (Convolutional Neural Networks, CNN) yararlanılmıştır. CNN, iki boyutlu verinin analizi için tasarlanmış ve derin öğrenmenin özelleştirilmiş bir hali olarak ortaya çıkmıştır. Sadece iki boyutlu değil, tek boyut da dahil olmak üzere, çok boyutlu verilerin analizinde de yaygın olarak tercih edilen bir algoritmadır. Bu çalışmanın özgünlüğünü ortaya koymak için 34 katmandan oluşan OzNet isimli yeni bir CNN mimarisi tasarlanmıştır. Bu mimari ile çeşitli biyomedikal sinyaller ve görüntüler sınıflandırılmış ve oldukça başarılı sonuçlar elde edilmiştir. OzNet, biyomedikal görüntü işleme alanında yaygın olarak kullanılan önceden eğitilmiş (pretrained) güçlü

mimariler (AlexNet, DenseNet201, GoogleNet, NASNetMobile, ResNet50, SqueezeNet, VGG-16 vb.) ile karşılaştırılmış ve bu mimariler arasında yer almayı başarmıştır. Bu çalışmada sadece sınıflandırma çalışmaları yapılmamıştır. Aynı zamanda ön işlem ve özellik seçim yöntemlerinin sınıflandırma başarısını etkileyip etkilemediği de araştırılmıştır.

Biyomedikal sinyaller ve görüntülerde gürültüler bulunmaktadır. Bu gürültüler, zaman zaman sinyal ve görüntünün sınıfının ayırt edilememesine sebep olabilir. Ön işleme yöntemleri kullanılarak sinyal ve görüntü gürültülerinin filtrelenmesi sağlanabilir. Biyomedikal sinyalleri ve görüntüleri işlemek için birçok yöntem kullanılmaktadır. Bunlardan bazıları; Ayrık Fourier Dönüşümü, Kısa zamanlı Fourier Dönüşümü (STFT), Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform, CWT), Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform, DWT), Ayrık Kosinüs Dönüşümü (DCT), Walsh-Hadamart Dönüşümü, Yoğunluk Ayarlama Yöntemi (Intensity Adjustment), Renkli RGB (Red, Green, Blue, Kırmızı, Yeşil, Mavi)'den Griye Dönüşüm, Griden Renkli RGB'ye Dönüşüm vb. birçok yöntem literatürde yerini almıştır.

Son dönemde yapılan çalışmalarda derin öğrenme algoritmalarının otomatik özellik çıkarma özelliğinden de yararlanılmaktadır [1-3]. Görüntü vb. çok boyutlu verilerde özellik çıkarmak oldukça zordur ve konunun uzmanı kişilerden destek alınması da oldukça önemlidir. Derin öğrenme algoritmaları sayesinde bu sorunun üstesinden gelinmektedir. Bu çalışmada sunulan OzNet özellik çıkarıcı olarak da kullanılmıştır. Çıkarılan özelliklerden en anlamlı olanın seçilmesi algoritmanın etkinliğini artırmaktadır. Bu nedenle çalışmada, çeşitli özellik seçim yöntemleri kullanılarak özellikler indirgenmiş ve sınıflandırma sonuçları incelenmiştir. Bu çalışmada birden çok veri seti ile çalışılmış ve OzNet'in sınıflandırma başarısı incelenmiştir.

I. veri seti olarak, Massachusetts Teknoloji Enstitüsü (Massachusetts Institute of Technology, MIT)- Boston Beth İsrail Hastanesi (Boston's Beth Israel Hospital, BIH) (MIT-BIH) Aritmi veri tabanından alınan tek boyutlu elektrokardiyogram (ECG) verileriyle çalışılmıştır. İlk olarak ECG sinyallerinin gürültüden ayıklanması ve 1 boyutlu (1 dimensional, 1-D) sinyallerden CWT ile 2-D görüntülere (skalogram) dönüştürülmesi ile sağlanmıştır. Burada farklı sinyal uzunluklarının (360 Hertz (Hz), 500 Hz, 1000 Hz) sınıflandırma başarısını etkileyip etkilemeyeceği de araştırılmıştır. Yapılan karşılaştırmada, tek boyutlu sinyallerin iki boyutlu skalogramlara dönüştürülürken, dalga özelliklerinin 500 Hz sinyal uzunluğunda daha belirgin

hale geldiği ve sınıflandırma performansını iyileştirdiği görülmüştür. İkinci olarak, Amor, Bump ve Morse olmak üzere üç farklı ana dalgacık fonksiyonunun, sınıflandırma performansına etkisi araştırılmıştır. Üçüncü olarak da bu skalogramlar, OzNet mimarisi ve iki iyi bilinen önceden eğitilmiş mimari, AlexNet ve SqueezeNet kullanılarak aynı parametrelerle ayrı ayrı sınıflandırılmıştır. Bu çalışmada sadece CNN mimarileri kullanılarak sınıflandırma yapılmamıştır. Aynı zamanda görüntü sınıflandırmada çok yüksek başarıya sahip Destek Vektör Makineleri de (Support Vector Machines, SVM) incelenmiştir. CNN mimarilerinde aşırı öğrenmenin üstesinden gelebilmek için genellikle bırakma tekniği (Dropout technique) kullanılmaktadır. Fakat son çalışmalarda tek başına bırakma tekniğinin yeterli olmadığı görülmüştür. Güçlü makine öğrenme algoritmalarından olan SVM'nin sınıflandırma özelliği ve CNN mimarileri birleştirilerek bu sorunun üstesinden başarılı bir şekilde gelinmiştir. Çalışmanın bu bölümünde OzNet mimarisi SVM ile birleştirilerek yeni bir hibrit yapı oluşturulmuştur. Sınıflandırma performansını artırmak için sırasıyla maksimum havuzlama (MaxPool-7) ve tam bağlantılı (FC-8) katmanlardan elde edilen özellikler SVM ile sınıflandırılmıştır.

II. veri seti olarak, Koronavirüsün (COVID-19) otomatik sınıflandırması için erişime açık bilgisayarlı tomografi (Computed Tomography, CT) veri seti kullanılmıştır. Bu veri seti COVID ve COVID olmayan olmak üzere iki sınıftan oluşmaktadır. Bu çalışmada, COVID-19 CT veri setini sınıflandırmak için önceden eğitilmiş mimariler ve OzNet mimarisi kullanılmıştır. Buradaki amaç yine önerilen OzNet mimarisinin son dönemlerde yaygın olarak kullanılan önceden eğitilmiş mimariler arasında yer alıp almadığını araştırmaktır. İlk olarak sınıflandırma aşamasından önce ham COVID-19 CT veri setinden, üç farklı ön işlem yöntemini kullanarak, üç farklı veri seti elde edilmiştir. Ön işlem yönteminin sınıflandırmaya olan etkisinin araştırılması için ham veri seti sonuçları ile de karşılaştırılmıştır. Birinci veri seti, herhangi bir ön işlem yapılmadan ham formda kullanılmıştır. İkinci veri seti DWT (tek seviye), üçüncü veri seti yoğunluk ayarı, dördüncü veri seti ise maksimum -minimum (Maks-Min) normalleştirmeyle normalize edilmiş ve griden renkli RGB'ye dönüştürülmüştür. Elde edilen sonuçlar DWT ile işlenen COVID-19 CT görüntülerinin sınıflandırma başarısını artırdığı yönde olmuştur. Birçok araştırmacı ön işlem yöntemlerinden kaçınmaktadır. Çalışmanın bu bölümünde ön işlem yöntemleri uygulanarak yapılan sınıflandırmanın ne kadar başarılı olduğu ve ön işlem yöntemlerinden kaçınılması gerektiği vurgulanmıştır.

III. veri seti olarak, beyin kanama türlerini içeren CT veri seti kullanılmıştır. Bu veri setinden yaş dağılımına göre; çocuklar ve erişkinler olmak üzere iki farklı alt veri setleri ve tüm yaş gruplarının yer aldığı veri seti ile birlikte toplamda üç farklı veri seti oluşturulmuştur. Oluşturulan veri setleri OzNet ile sınıflandırılmış ve performansları değerlendirilmiştir. Sonuçlar kabul edilebilir düzeyde olsa da daha iyi performansı elde edebilmek için OzNet, Komşuluk Bileşenler Analizi (NCA) ve sınıflandırıcılar (ANN, Adaboost, Torbalama, Karar Ağacı (DT), K-En yakın komşu (KNN), Doğrusal Diskriminat Analizi (LDA), Naive Bayes ve SVM) ile birleştirilmiştir. Bu yeni yapılara OzNet hibrit algoritmaları adı verilmiştir. Bu hibrit algoritmalarda beyin CT görüntülerinden otomatik özellik çıkarımı için OzNet kullanılmıştır. OzNet'in tam bağlantılı katmanından elde edilen 4096 özellik, NCA yöntemi kullanılarak azaltılmıştır. Çalışmanın bu bölümünde de özellik seçim yöntemlerinin sınıflandırmaya olan etkisi araştırılmıştır. OzNet mimarisi ile sınıflandırılan, gerek tek boyutlu ECG veri setinde gerekse farklı boyutlarda olan CT görüntülerinde oldukça yüksek doğruluk oranları elde edilmiştir.

Çalışmanın devamında; literatürde yer alan çalışmalar, materyal ve yöntem, deneysel sonuçlar ve tartışma ve son olarak sonuç olmak üzere dört bölüm sunulmuştur.

1.2. Literatür

1.2.1. ECG Verilerinin Kullanıldığı Çalışmalar

İnsan vücudunun en önemli hayati organı olan kalbin elektriksel aktivitesinin sonucu ortaya çıkan sinyallere Elektrokardiyogram (Electrocardiogram, ECG) denir. Ani ölümlerin birçoğu kalp rahatsızlıkları sebebiyle gerçekleşmektedir. Bu nedenle kalpten alınan sinyallerin işlenmesi, analiz edilmesi teşhis ve tedavi için büyük önem taşımaktadır.

ECG sinyalleri doğrudan analiz edilememektedir. Ön işlem yaparak sinyalleri analize uygun hale dönüştürmek gerekmektedir. Uygun örnekleme yöntemi kullanılmalı ve sinyalin üzerindeki gürültüler temizlenmelidir. Ön işlem aşaması tamamlandıktan sonra öznelik belirleme aşamasına geçilmelidir. Bunun için de uzman görüşü almak oldukça önemlidir. Uzman görüşünü almak ise her zaman mümkün olmayabilir. Bu problemin çözümü için araştırmacılar yapay zekâ alanında oldukça popüler olan derin öğrenme algoritmalarından

yararlanmışlardır. CNN algoritması da bu konuda oldukça yüksek başarı göstermiştir. Çok boyutlu ve çok sınıflı sinyal verilerin sınıflandırılmasında CNN algoritması tercih edilmiştir. Son yapılan çalışmalarda kullanılan CWT-CNN ikili hibrit algoritma, ECG sinyallerinin sınıflandırmasında uygulanmıştır.

Günümüzde, ECG sinyallerini ve diğer biyomedikal sinyalleri sınıflandırmak için CNN mimarileri kullanılarak birçok çalışma yapılmıştır.

Khorrani ve Moavenian [4] ECG sinyallerinin dönüşümü için CWT, DWT ve DCT yararlanmışlardır. Sınıflandırma aşamasında ise SVM ve çok katmanlı algılayıcı (MLP) algoritmalarını kullanarak karşılaştırma yapmışlardır. Sinir Ağları algoritmalarından olan MLP ile oluşturulan kombinasyonların (CWT-MLP, DWT-MLP, DCT-MLP) SVM 'ye göre daha üstün olduğunu ifade etmişlerdir.

Golgowski ve Osowski [5] çalışmalarında ECG sinyallerindeki anomalileri belirlemek için sinyalleri ilk olarak DWT ve CWT ile dönüştürmüşlerdir. Sınıflandırma aşamasında ise çeşitli kümeleme, sınıflandırma ve sinir ağları algoritmalarını kullanarak en iyi sonucu veren yapıyı belirlemeye çalışmışlardır. DWT-Ekstra rasgele ormanlar ikilisinden %97.78 doğruluk oranı ile en iyi sınıflandırma başarısını elde etmişlerdir.

Rahhal ve diğerleri [6] çalışmalarında ECG sinyallerindeki aritmileri belirlemek için farklı veri setlerindeki sinyalleri ilk olarak CWT ile dönüştürmüşlerdir. Sınıflandırma aşamasında ise CNN algoritmasından yararlanmışlardır. CWT-CNN ikilisinden %99 doğruluk oranı elde etmişlerdir.

Acharya ve diğerleri [7] çalışmalarında gürültüden arındırılmış ve gürültülü ECG sinyallerini CNN algoritması kullanarak sınıflandırmışlardır. Önermiş oldukları eğitilmiş mimari sayesinde sinyalin gürültüden arındırılmasına gerek olmadan yüksek sınıflandırma başarısı elde ettiklerini ifade etmişlerdir. Gürültülü ve gürültüden arındırılmış ECG sinyalleri için elde ettikleri doğruluk oranları sırasıyla %93.53 ve %95.22'dir.

Huang ve diğeri [8] çalışmalarında ECG sinyallerini STFT ile dönüştürmüşler ve 2 boyutlu spektrumlar elde etmişlerdir. Elde ettikleri spektrumları CNN algoritmasıyla sınıflandırarak %99 doğruluk oranı elde etmişlerdir. ECG sinyallerini 1 boyutlu olarak da CNN algoritmasından yararlanarak sınıflandırmışlar ve %90.93 doğruluk oranı elde etmişlerdir.

Krak ve diğeri [9] çalışmalarında ECG sinyallerini CWT ve DWT ile dönüştürmüşlerdir. Sınıflandırma aşamasında ise Gradyan artırma ve CNN algoritmalarından yararlanmışlardır. CWT-CNN ikilisinden %96 doğruluk oranı elde etmişlerdir.

Baloğlu ve diğeri [10] tek boyutlu çok sınıflı ECG verilerinin sınıflandırılması için 10 katmanlı uçtan uca bir CNN mimarisi tasarlamışlar ve %99.78 doğruluk oranı elde etmişlerdir.

Mahmut ve diğeri [11] tek boyutlu çok sınıflı ECG verileri için bir CNN algoritması oluşturmuşlar ve %99.28 doğruluk oranı elde etmişlerdir.

Salem ve diğeri [12] iki boyutlu ECG verilerini sınıflandırmak için önceden eğitilmiş DenseNet mimarisini kullanmışlar ve %97.23 doğruluk oranına ulaşmışlardır.

Zhao ve diğeri [13] ECG verileri için 24 katmanlı bir CNN tasarlamışlar ve %87.1 doğruluk oranına ulaşmışlardır.

Xu ve Liu [14] bir Holter cihazından alınan ECG verilerini analiz etmek için bir CNN mimarisi tasarlamışlar ve %99.4 doğruluk oranı elde etmişlerdir.

Rajkumar ve diğeri [15] üstel doğrusal birim (ELU) aktivasyon katmanlarını kullanarak tek boyutlu ECG verileri için bir CNN mimarisi oluşturmuşlar ve %93.6 doğruluk oranı elde etmişlerdir.

Kiranyaz ve diğeri [16], gerçek zamanlı, hastaya özgü tek boyutlu ECG sınıflandırması için CNN mimarisi önermişler ve %96.4 doğruluk oranı elde etmişlerdir.

Chen ve diğeri [17], iki farklı ECG veri tabanını sınıflandırmak için CNN’i ve Uzun-Kısa Süreli Belleği (LSTM) kullanmışlar ve sırasıyla %99.32 ve %97.15 doğruluk oranları elde etmişlerdir.

Sandeep ve diğeri [18] ECG verilerini sınıflandırmak için CNN algoritmasını kullanmışlar ve %90.63’lük bir doğruluk oranı elde etmişlerdir. Ayrıca, Çizelge 1.1’de ECG veri setleri üzerine yapılan son çalışmalar sunulmuştur.

Çizelge 1.1. Son yıllarda yapılan ECG verileri sınıflandırma çalışmaları.

Çalışma	Veri Seti	Sınıf Sayısı	Yöntemler	Performans Ölçütleri	
Xing ve diğeri [19]	MIT-BIH (Aritmi Veri seti)	5	SNN (Artan Sinir Ağları, Spiking Neural Network)	Doğruluk	0.9826
				Duyarlılık	0.9475
				F1-Skor	0.8909
Chen ve diğeri [20]	KMUH Veri Seti (KMUH: Kaohsiung Tıp Fakültesi Üniversite Hastanesi)	9	DNN (Derin Öğrenme Ağları)	Doğruluk	0.9602
				Mikro-F1	0.8271
Pałczyński ve diğeri [21]	PTB Veri Seti (Fiziksel-Teknik Federal Enstitüsü, Physikalisch-Technische Bundesanstalt)	2	CNN (1D)	Doğruluk	0.9040
				Duyarlılık	0.8960
				F1-Skor	0.8990
		5	FSL (Birkaç adımlı Öğrenme, Few Shot Learning) +SVM	Doğruluk	0.7900
				Duyarlılık	0.7060
				F1-Skor	0.7060
20	CNN (1D)	Doğruluk	0.6710		
		Duyarlılık	0.3240		

				F1-Skor	0.3260
Cheng ve diğeri[22]	MIT-BIH (Aritmi Veri seti)	5	U-Net (1D)	Doğruluk	0.9550
				Duyarlılık	0.9555
				Özgüllük	0.9764
Jiao,Qi ve Wu [23]	MIT-BIH (Aritmi Veri seti)	5	Kapsül Ağı (LSTM+CNN)	Doğruluk	0.9930
				Duyarlılık	0.8310
				F1-Skor	0.8620
Sepahvand ve Mohammadi[24]	Chapman ECG Veri Seti (Chapman Üniversitesi ve Shaoxing Halk Hastanesi)	7	CNN	Doğruluk	0.9815
				Duyarlılık	0.9711
				F1-Skor	0.9755
Eltrass ve diğeri [25]	MIT-BIH Aritmi Veri Seti MIT-BIH Normal Sinus Ritmi Veri Seti BIDMC Veri Seti	3	CNN (AlexNet)	Doğruluk	0.9874
				Duyarlılık	0.9817
				Özgüllük	0.9900
Kumar ve diğeri [26]	IoT (Nesnelerin İnterneti) tabanlı Toplanan ECG Sinyalleri	2	CNN	Doğruluk	0.9505
				Duyarlılık	0.9464
				Özgüllük	0.9464
Meng ve diğeri [27]	MIT-BIH Aritmi Veri Seti	3	CNN	Doğruluk	0.9932

1.2.2. COVID-19 CT Verilerinin Kullanıldığı Çalışmalar

Dünya sağlık örgütü (WHO), COVID-19'un dünya çapında bir pandemi olarak ilan edildiği 11.03.2020 tarihinden itibaren dünya genelinde vaka sayılarını gün gün açıklamıştır. 30 Nisan 2021'de [28] 3.155.168 ölüm ve 149.910.744 doğrulanmış COVID-19 vakası olduğunu bildirmiştir. COVID-19'u teşhis etmek için birden fazla yöntem vardır. Bunlar viral test, kan testi ve görüntüleme cihazıdır. Bu testlerin en güvenilir olanı göğüs görüntülerini içeren CT görüntüleme cihazı sonuçlarıdır. CT, COVID-19 hastalarını diğerlerinden güçlü bir şekilde ayırır. Ancak görüntüleme cihazları radyoloji uzmanları tarafından tek tek manuel olarak incelenir. Artan vaka sayıları ve hastaneye yatış oranları dikkate alındığında ilgili uzmanların iş yükü tahmin edilemez ölçüde artmıştır. Tüm bu koşullar altında akıllı cihazlarla uzmanların iş yükünün azaltılması kaçınılmaz olmuştur.

Görüntü işleme, video işleme vb. işlemler derin öğrenme algoritmaları sayesinde otomatik olarak yapılabilmektedir. Özellikle derin öğrenme algoritmaları kullanılarak tıbbi görüntü analizi konusunda birçok çalışmada mükemmel sonuçlar elde edilmiştir. Bu konuda birçok araştırmacı çeşitli uygulamalarla çalışmalar yapmışlardır.

Wang ve diğerleri [29], sıra tabanlı ortalama havuzlama katman ile FGCNet'i sunmuşlardır. Aynı zamanda veri artırma yöntemini COVID-19 veri setine uygulamışlardır. Önermiş oldukları bu mimari, toplu normalleştirme katmanı ve bırakma katmanı ile bir tür derin öğrenme ağıdır. Elde ettikleri sonuçlar, performans ölçütlerinin %96.56'nın üzerinde olduğunu göstermiştir.

Aslan ve diğerleri [30], ANN aracılığıyla akciğer COVID-19 CT görüntülerinde segmentasyon işlemi gerçekleştirmiştir. Ayrıca, AlexNet'i içeren iki mimari oluşturmuşlardır. İlk olarak, AlexNet'in son katmanlarını transfer öğrenme yöntemiyle değiştirmişlerdir. İkinci olarak ise Çift Yönlü Uzun-Kısa Süreli Bellekler (BiLSTM) katmanı ile hibrit bir mimari oluşturmuşlardır. Önerdikleri ikinci mimaride %98.7 doğruluk oranı elde etmişlerdir.

Nayak ve diğerleri [31], COVID-19 göğüs röntgeni görüntülerinin sınıflandırılması için AlexNet, VGG-16, GoogleNet ve MobileNet-V2, SqueezeNet, ResNet-34, ResNet-50 ve

Inception-v3 gibi önceden eğitilmiş mimarileri karşılaştırmıştır. Ayrıca, seçenek parametreleriyle en iyi mimariyi önermek için, bu mimarileri yığın boyutu, öğrenme oranı, periyot sayısı ve farklı optimizasyon yöntemleri yönünden karşılaştırma yapmışlardır. Önermiş oldukları mimari, %98,33 doğrulukla ResNet-34 mimarisi olmuştur.

Yang ve diğerleri [32], CT'den COVID-19 teşhisi için yapay zeka tabanlı bir algoritma oluşturmuştur. Bu algorithmadan %89 doğruluk oranı elde etmişlerdir.

Babukarthik ve diğerleri [33], genetik derin öğrenme evrişimli sinir ağlarını kullanarak üç sınıflı COVID-19 X-Ray görüntülerini sınıflandırmış ve %98.84 doğruluk oranı elde etmişlerdir. Önermiş oldukları bu mimarinin, karşılaştırdıkları önceden eğitilmiş mimarilerden daha üstün olduğunu ifade etmişlerdir.

Fan ve diğerleri [34], COVID-19 akciğer segmentasyonu için Inf-Net'i önermişlerdir. Ayrıca, Inf-Net ile yarı denetimli (semi-supervised) bir yöntem de kullanmışlardır. Sonuç olarak yapmış oldukları segmentasyon için Inf-Net ve Semi-InfNet ile sırasıyla %87 ve %86.5 hassasiyet elde etmişlerdir.

Sharifrazi ve diğerleri [35], sobel filtresini kullanarak CNN füzyonu ve SVM ile CT görüntülerini sınıflandırmıştır. Önerilen CNN-SVM ile %99.02 doğruluk oranı elde etmişlerdir.

Subaşı ve diğerleri [36], COVID-19 CT taramalarının sınıflandırılması için önceden eğitilmiş olan VGG-16, VGG-19, ResNet152-V2, DenseNet-121, Inception-V3, MobileNet-V2 ve Xception mimarilerini kullanmıştır. Ek olarak, 1 katmanlı, 3 katmanlı ve 4 katmanlı bazı CNN mimarilerini sunmuşlardır. DenseNet-121 ile %85.95 doğruluk oranı elde etmişlerdir.

Barstugan ve diğerleri [37], gri düzeyli birlikte oluşum matrisi, yerel yönlü model, gri düzeyli çalışma uzunluğu matrisi, gri düzeyli boyut bölgesi matrisi (GLSZM) ve DWT algoritmalarını COVID-19 görüntüleri üzerine uygulamışlardır. Çıkarılan öznelikleri SVM'yi kullanarak sınıflandırmışlardır. En yüksek sınıflandırma başarısını GLSZM-SVM yöntemi ile %99.68 doğrulukla elde etmişlerdir.

Khan ve diğerklerinin [38] çalışması, iki aşamadan oluşmaktadır. İlk aşamada, iki seviyeli DWT ile CT taramalarından öznelikleri çıkarmışlardır. Ardından, önerdikleri derin CNN mimarisini kullanarak sınıflandırmışlardır. İkinci aşamada, CT taramalarının hastalık bölgelerini segmentasyon modelleri ile belirlemişlerdir. Ardından, önerdikleri derin CNN mimarisini kullanarak sınıflandırmışlardır. DWT-CNN mimarisinden %98 Matthew korelasyon katsayısı ölçümü elde etmişlerdir.

Vente ve diğerkleri [39], transfer öğrenme yöntemi ile 2-boyutlu (2D) CNN yerine 3-boyutlu (3D) CNN kullanmışlardır. COVID-19 CT taramalarının sınıflandırmasında 0.923 Alıcı İşletim Karakteristiği Eğrisi altında kalan alan (AUC) değeri elde etmişlerdir.

Pham [40], veri artırma olmadan COVID-19 CT taramalarının sınıflandırılması için önceden eğitilmiş 16 mimariyi kullanmıştır. Çalışmada, en iyi sınıflandırma başarısı elde eden mimarinin, altı eğitim periyoduyla %96.20 \pm 4.95 doğruluk oranı elde eden DenseNet-201 olduğunu ifade etmiştir.

Adebisi ve diğerkleri [41] transfer öğrenme yöntemiyle X-ray görüntülerinin sınıflandırılması için AlexNet, GoogleNet ve SqueezeNet'i kullanmışlardır. Sonuç olarak, AlexNet'in %98.31 doğruluk oranı elde ettiğini göstermişlerdir.

Güngör [42], çalışmasında oldukça gürültülü COVID-19 CT taramaları için DWT' de farklı dalgacık fonksiyonları üzerine bir karşılaştırma yapmıştır. Bu çalışmada ayrıca farklı dalgacık fonksiyonlarını ortogonalite, filtre sırası ve simetriklik bakımından da incelemiştir. Sonuç olarak, gürültülü COVID-19 CT taramalarını azaltmak için simetrik uzantı (sym) veya Daubechies (dB) fonksiyonunun kullanılabilirliğini ifade etmiştir.

Taşpınar ve diğerkleri [43], COVID-19 X-ray görüntülerini sınıflandırmak için VGG-19 mimarisini kullanmıştır. Ayrıca, bu mimariyi, güçlü sınıflandırma algoritmalarından olan ANN, SVM ve Lojistik Regresyon (LR) ile modifiye etmişlerdir. Çalışmalarında %96.9 doğruluk oranı elde etmişlerdir.

Subaşı ve diğeri [44], COVID-19'u tespit etmek için X-Ray görüntülerinden yararlanmıştır. Bu görüntüleri çeşitli önceden eğitilmiş CNN mimarileriyle sınıflandırmışlar ve VGG-19 mimarisi ile %97.56 doğruluk oranı elde etmişlerdir.

Jia ve diğeri [45], çalışmalarında COVID-19 teşhisi için X-Ray ve CT görüntülerini kullanmışlardır. CNN mimarilerini kullanarak dört farklı sağlık problemini sınıflandırmışlardır. Bu sınıflar: COVID, Bakteriyel Pnömoni, Viral Pnömoni, Tüberküloz ve normaldir. Sonuç olarak X-Ray görüntülerinin sınıflandırılmasında %99.6, CT görüntülerinin sınıflandırılmasında ise %99.3 test doğruluk oranı elde etmişlerdir.

Thakur ve Kumar [46], COVID-19'u belirlemek için X-Ray ve CT görüntülerini içeren veri setlerini kullanmıştır. Çalışmalarında, CNN mimarisini uygulamışlar ve ikili sınıflandırma için %99.64 doğruluk ve çok sınıflı sınıflandırma için ise %98.28 doğruluk oranı elde etmişlerdir. Ayrıca Narin ve diğeri [47], Ahuja ve diğeri [48], Akram ve diğeri [49], Li ve diğeri [50], Tuncer ve diğeri [51] ve Özşahin ve diğeri [52] de COVID-19 görüntüleri üzerine çalışmalar yapmıştır. Çizelge 1.2, COVID-19'un tespiti için yapılan son çalışmaları göstermektedir.

Çizelge 1.2. Son yıllarda yapılan COVID-19 CT görüntülerini sınıflandırma sonuçları.

Çalışma	Veri Seti	Sınıflar	Yöntemler	Performans Ölçütleri
Gour ve Jain[53]	X-ray görüntüleri	Covid: 546 Normal: 1139 Pnömoni 1355 Covid:127 Covid olmayan:500	CNN (Belirsizlik) EfficientNetB3 MonteCarlo-Bırakma	Doğruluk 0.9767 F1-Skor 0.9799 Duyarlılık 0.9815 Doğruluk 0.9936 G-Ortalama 0.9802
Dash ve Mohopatra [54]	X-ray görüntüleri	Covid: 147 Normal: 500 Pnömoni:600	VGG-16	Doğruluk 0.9712
Chakraborty ve diğerleri [55]	X-ray görüntüleri	Covid: 1184 Normal: 1319 Pnömoni:600	VGG-19	Doğruluk 0.9711 Kesinlik 0.9700 Duyarlılık 0.9700
Aslan ve diğerleri [56]	X-ray görüntüleri	Covid:219 Normal:1341 Pnömoni:1345	ANN-tabanlı Segmentasyon DenseNet201-SVM	Doğruluk 0.9629 F1-Skor 0.9641 Duyarlılık 0.9642
Saad ve diğerleri [57]	CT görüntüleri X-ray görüntüleri	Covid:2628 Covid olmayan:1620	Görüntü Segmentasyonuna Dayalı İlgi Alanı (ROI) Yöntemi CNN	Doğruluk 0.9890 Duyarlılık 0.9850 F1-Skor 0.9892 Doğruluk 0.9930 Duyarlılık 0.9880 F1-Skor 0.9930

Amin ve diğlerleri [58]	CT görüntüleri	Veri seti I: Covid:100 Covid olmayan:200	Deeplabv3 ve ResNet-18 Sematik Segmentasyon	Doğruluk	0.8647
		Veri seti II: Covid: 349 Covid olmayan:701		Doğruluk	1.000
		Veri seti III: Covid: 1500 Covid olmayan:1200	Oto-enkoder Yöntemi (Stack Sparse auto encoder, SSAE)	Doğruluk	0.9923
		Veri seti IV: Covid: 10		Doğruluk	0.9615

1.2.3. Beyin Kanaması CT Verilerinin Kullanıldığı Çalışmalar

İntraserebral kanama (ICH), yıkıcı bir hastalıktır. Dünya çapında yılda her 100.000 kişide yaklaşık 24.6 spontan ICH'nin genel insidansı, Amerika Birleşik Devletleri'nde ise yılda yaklaşık 40.000 ile 67.000 arasında ICH vakası görülmektedir [59]. Bu mortalitenin yaklaşık yarısı ilk 24 saat içinde meydana gelmektedir. Bu nedenle erken tanı ve tedavi çok önemlidir [60]. Altın standart tanı yaklaşımı, başlangıçta kontrastsız CT taraması (scan), ardından lomber ponksiyon (LP) ve CT negatif olduğunda beyin omurilik sıvısının (BOS) analizini yapmak olmuştur [61]. Kronik kanama ve akut kanama ayırımında tomografi bulguları da önemlidir. Hiperakut fazda kanamayı tanımlamak zor olabilir. Akut ve erken subakut fazda, progresif kan pıhtısı retraksiyonu ile birlikte serum bileşeninin ekstrüzyonu kanama yoğunluğunu hızla artıracaktır. Özellikle, hemoglobinin (globin) protein bileşeninin artan konsantrasyonu, CT' de daha yoğun (hiperdens) görünecektir. Sonraki geç subakut (3. Gün ile 3 haftadan az) faz sırasında, progresif Kırmızı Kan Hücresi (RBC) lizisi (hücre içi sıvıyı elde etmek için hücre zarını parçalama) ve globin proteininin proteolizi, kanama yoğunluğunun azalmasına neden olur. Geç subakut fazda kanama beyin parankimiyle yoğun (izodens) hale gelebilir [62]. Dolayısıyla bu beyin vakalarını teşhis etmede kesinlikle CT'nin doktorlara yardımcı olduğu ifade edilebilir [63, 64]. Çok hızlı bir değerlendirme hastalar için hayati önem taşır. Ayrıca ameliyat için beynin hangi bölgesinde kanama olduğunu belirlemek de çok önemlidir. Buradan yola çıkan araştırmacılar, yapay zekâ sayesinde manyetik rezonans görüntüleme (Magnetic Resonance Imaging, MRI) veya CT'den hızlı teşhis koymayı hedeflemektedir. Bu amaçla derin öğrenme algoritmaları birçok alanda birçok çalışmada yaygın olarak kullanılmaktadır [65-72].

Literatürde birçok araştırmacı Beyin Kanaması CT görüntülerini farklı uygulamalarla incelemiştir.

Shahangian ve Pourghassem [73], uzaklığı düzenlenmiş düzey kümesi evrimini (DRLSE) modifiye ederek bir sınıflandırma algoritması önermişlerdir. K-En yakın komşu (KNN), MLP, SVM ve hiyerarşik sınıflandırma gibi makine öğrenimi algoritmalarını kullanmışlardır. Epidural kanama (EDH), Subdural kanama (SDH) ve İntraserebral kanama (ICH) olmak üzere üç farklı kanama sınıfını sınıflandırdıklarında, SVM algoritması ile %94.13 doğruluk oranı elde etmişlerdir.

Kuo ve diğeri [64], San Francisco'daki California Üniversitesi'nden ve bağı hastanelerden sağlanan 4396 beyin CT taramasını tam bağlantılı bir CNN kullanarak incelemiştir. Ek olarak, algoritmalarının performansını uzmanların performansı ile karşılaştırdılar. Deneysel sonuçlara göre CT tarama sınıflandırması için 0.991 AUC değeri elde etmişlerdir. Sonuç olarak, tam bağlantılı CNN performansının uzmanların performansını aştığını ifade etmişlerdir.

Gautam ve diğeri [74], beyin kanaması lezyonunun doğru segmentasyonu için standart Bulanık C-Kümelemeyi (FCM), uzaysal FCM'yi, sağlam çekirdek tabanlı bulanık C-kümelemeyi (Robust Fuzzy C-Means ,RFCM) ve DRLSE'yi karşılaştırmışlardır. CT tarama görüntülerinden beyin lezyon bölgelerini belirlemek için en iyi sonucu RFCM ve DRLSE algoritmaları ile elde etmişlerdir.

Bhadauria ve Dewal [75], beyin kanaması CT görüntülerinden ICH'yi otomatik olarak saptamak için bulanık kümeleme ile bölge bazlı aktif kontur segmentasyon yöntemini birleştirmiştir. Ayrıca, önerdikleri bu yöntemi bulanık kümeleme ve bölge genişlemesi yöntemiyle de karşılaştırmışlardır. Sonuç olarak, önerdikleri yöntemle %79.48 duyarlılık ve %99.42 özgüllük elde etmişlerdir.

Maas ve diğeri [76], Marshall CT sınıflandırmasını kullanarak CT taramalarında altı farklı travmatik beyin hasarı morfolojik anormalliğini araştırmışlardır. Lojistik regresyon analizi ile Marshall CT sınıflandırmasını iyileştirdiklerinde 0.77 AUC sonucunu elde etmişlerdir.

Shahangian ve Pourghassem [77], Genetik Algoritmayı (GA) beyin CT görüntülerinden kanama bölgelerini otomatik olarak saptamışlardır. Çalışmalarında üç farklı kanama sınıfları olan EDH, ICH ve SDH'yi sınıflandırmışlardır. Sonuç olarak çok katmanlı sinir ağı ile %93.33 doğruluk oranı elde etmişlerdir.

Solorio-Ramirez ve diğeri [78], beyin kanaması CT görüntülerini sınıflandırmak için Minimalist Makine Öğrenmesi (MML) algoritması olarak adlandırdıkları yeni bir algoritma önermişlerdir. Çalışmalarında Normal (kanama olmadan) ve İntraventriküler (IVH) kanama

olmak üzere iki farklı sınıf kullanmışlardır. Ayrıca önerdikleri algoritmayı KNN, MLP, Naive Bayes (NB), SVM, Adaboost ve Hiyerarşik algoritmalar ile karşılaştırmışlardır. Sonuç olarak, Hiyerarşik algoritma ile %92.62 doğruluk oranı elde etmişlerdir. Önerdikleri yönteme üstünlük sağlanmış olsa da zaman açısından karşılaştırdıklarında en yüksek performansı önerdikleri algoritma ile elde etmişlerdir.

Balasoorya ve Perera [79], beyin CT görüntülerinden kanama lezyonlarını saptamak için havza yöntemini (watershed method) kullanmıştır. Çalışmasında MATLAB kullanılarak yapay sinir ağları ile ameliyatlara ve cerrahi simülasyonlar geliştirmeyi amaçlamıştır. Sonuç olarak araştırmacı bu çalışmasında kabul edilebilir bir sonuç aldığını ifade etmiştir.

Alawad ve diğerleri [80], Beyin Kanamasının Doğru Tanımlanması (Accurate Identification of Brain Hemorrhage, AIBH) adı verilen pratik bir yöntem geliştirmişlerdir. İlk olarak, Otsu yöntemini kullanarak ilgi alanı dışındaki (Region of Interest, ROI) mesafesi aracılığıyla beyin CT görüntülerinden kafatası bölgesini çıkarmışlardır. Ardından, ROI mesafesine göre görüntülerden özellikler çıkarmışlardır. Ayrıca, ilgili özellikleri seçmek için GA'yı kullanmışlardır. Ardından, çeşitli kanama türlerini tahmin etmek için 10 katlı çapraz doğrulama kullanarak yığınlama tabanlı makine öğrenme algoritmalarını uyguladılar. Önerilen AIBH yöntemi ile %99.5 doğruluk oranı elde etmişlerdir.

Gautam ve Raman [63], beyin CT görüntüleri için CNN mimarileri tabanlı ve görüntü birleştirme yöntemini önerdiler. Veri seti hemorajik, iskemik ve normal olmak üzere üç sınıf içermektedir. Ayrıca genel veri setinden başka bir veri seti daha oluşturmuşlardır. Bu veri setini veri seti 1 olarak adlandırmışlardır. Veri seti 1; hemorajik, iskemik olmak üzere yalnızca iki sınıf içermektedir. Genel veri setine de veri seti 2 adı vermişlerdir. Veri seti 1'i %80 eğitim seti ve %20 test seti olarak ayırdıklarında, %98.33 doğruluk oranı elde etmişlerdir. Aynı veri setine 10 katlı çapraz doğrulama uyguladıklarında ise %98.77 doğruluk oranı elde etmişlerdir. Benzer uygulamaları veri seti 2 için yaptıklarında sırasıyla %92.22 ve %93.33 doğruluk oranı elde etmişlerdir.

Mansour ve Aljehane [81], beyin CT görüntülerinden ICH'yi teşhis etmek için yeni bir derin öğrenme algoritması önerdiler. Çalışmaları; ön işleme, segmentasyon, özellik çıkarma ve sınıflandırma olmak üzere dört aşamadan oluşmaktadır. İlk aşamada görüntünün formatını JPEG'e çevirmişlerdir. İkinci aşamada, görüntü segmentasyonu için fil sürüsü optimizasyon (EHO) algoritması ile Kapur'un eşik değeri yöntemini kullanmışlardır. Ardından, özellik çıkarma aşaması için Inception-v4 mimarisini uygulamışlar ve MLP ile sınıflandırarak %95.06 doğruluk oranı elde etmişlerdir.

Toğaçar ve diğerleri [82], AlexNet mimarisini kullanarak beyin kanaması CT görüntülerini sınıflandırmışlar ve veri setindeki her görüntünün otomatik kodlayıcı ağ modelini ve ısı haritalarını kullanarak sınıflandırma başarısını geliştirmeyi amaçlamışlardır. Ek olarak, veri büyütme de uygulamışlar ve %98.57 doğruluk oranı elde etmişlerdir.

Anupama ve diğerleri [83], beyin kanaması CT görüntülerinin sınıflandırılması için bir derin öğrenme algoritması kullanmışlardır. Sınıflandırma aşamasından önce gürültüleri gidermek için Gabor filtreleme yöntemini uygulamışlardır. Ayrıca, hastalık bölgelerini belirlemek için sinerjik derin öğrenme (SDL) ile GrabCut tabanlı segmentasyon geliştirmişlerdir. Böylece %95.73 doğruluk oranı elde etmişlerdir.

Chawla ve Kishore [84], 15 hastanın 347 beyin CT kesitinde kontralateral simetriye dayalı olarak akut, kronik enfarktüsler ve kanamalar tespit etmişlerdir. Ek olarak, yoğunluk ve dalgacık alanında elde edilen özellikleri kullanarak anormallikleri tespit etmek için iki seviyeli bir sınıflandırma gerçekleştirmişlerdir. Önerilen yöntemi uyguladıklarında, sınıflandırma için %90 doğruluk oranı elde etmişlerdir.

Majumdar ve diğerleri [85], beyin CT görüntülerinden kanama lezyonlarını otomatik olarak saptamak için U-Net algoritmasını uygulamışlardır. Ek olarak, beş tip kanama sınıfı içeren 134 vakaya ait 4300 beyin CT görüntüsünü kullanmışlardır. Ayrıca model performansını iyileştirmek için rastgele sağ-sol çevirme ve ± 10 derece rastgele döndürme ile veri büyütme tekniği uygulamışlardır. Çalışmalarında, %81 duyarlılık ve %98 özgüllük oranı elde

etmişlerdir. Diğer birçok çalışmada farklı yaklaşımlarla kanama türleri bakımından beyin CT görüntüleri araştırılmaktadır [86-89]. Ayrıca, Çizelge 1.3'te Beyin CT veri setleri kullanarak yapılan son çalışmalar gösterilmektedir.

Çizelge 1.3. Son yıllarda Beyin CT görüntülerini sınıflandırma sonuçları.

Çalışma	Veri Seti	Yöntemler	Performans Ölçütleri
Uyar ve diğerleri [90]	2700 Beyin CT görüntüsü 3 sınıflı	Hızlı R-CNN	Doğruluk 0.9775
Ertuğrul ve Akıl [91]	15979 Beyin CT görüntüsü 27203 sınırlayıcı kutu 6 sınıflı	YOLOv4	Kesinlik 0.9400
Abramova ve diğerleri [92]	256 Beyin CT görüntüsü 2 sınıflı	3D U-Net	Dice Doğruluk 0.8620
Santhoshkumar ve diğerleri [93]	2526 Beyin CT görüntüsü 6 sınıflı	DenseNet- Aşırı Öğrenme	Doğruluk 0.9634
Barin ve diğerleri [94]	752803 Beyin CT görüntüsü 6 sınıflı	InceptionResNetv2- EfficientNetB3	Doğruluk 0.9859
Burduja ve diğerleri [95]	25272 Beyin CT görüntüsü 6 sınıflı	3D ResNeXt-BiLSTM	Doğruluk 0.9470 Duyarlılık 0.7560 Kesinlik 0.9720
Salehinejad ve diğerleri [96]	31277 Beyin CT görüntüsü 6 sınıflı	LightGBM ResNeXt-50- CatBoost XGBoost	AUC 0.9840 Doğruluk 0.9880 Özgüllük 0.9800

* YOLOv4: You Look Only Once

2. MATERYAL VE YÖNTEM

Bu çalışmada, biyomedikal görüntülerin sınıflandırılması için uçtan uca yapısı sayesinde otomatik özellik çıkarımı yapabilen, yüksek sınıflandırma performansına sahip bir CNN mimarisi önerilmiştir. Önerilen bu CNN mimarisi OzNet olarak adlandırılmıştır. OzNet, önceden eğitilmiş iyi bilinen mimariler ile farklı veri setleri kullanılarak karşılaştırılmıştır. Bu bölümde, kullanılan veri setleri, ön işleme yöntemleri, yeni bir CNN mimarisi olan OzNet, önceden eğitilmiş mimariler, özellik seçim yöntemleri, sınıflandırıcılar, veri artırma, çapraz doğrulama ve performans ölçütlerine yer verilmiştir.

2.1. Veri Setleri

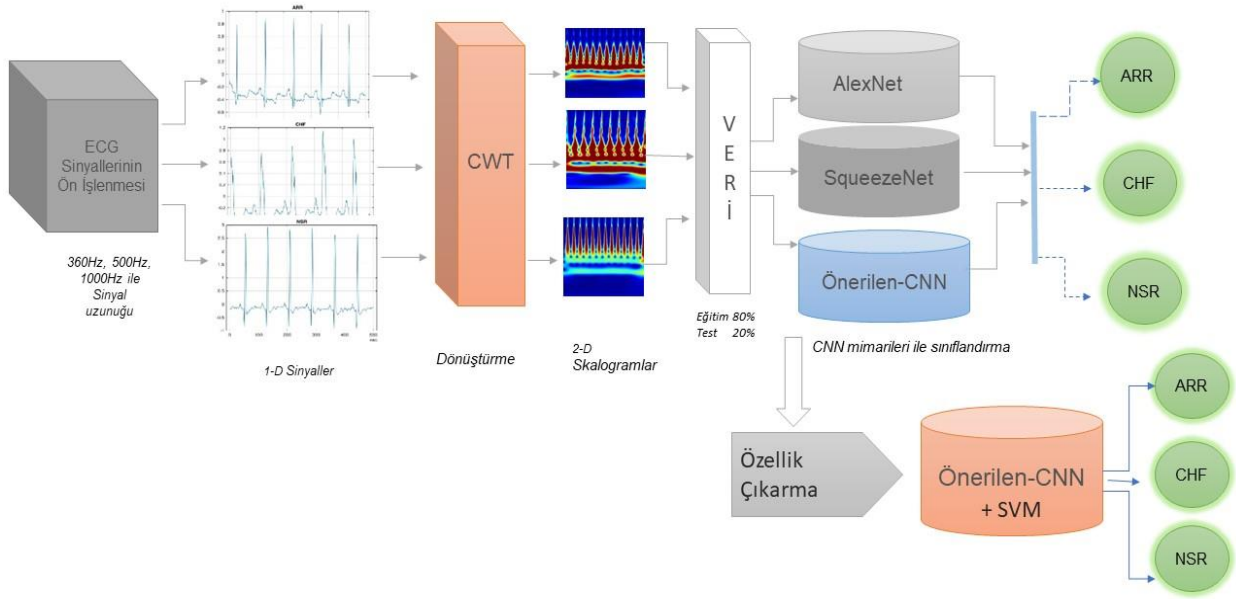
I. veri seti, MIT-BIH Aritmi veri tabanından alınan ECG verileridir. Ön işleme aşamasında, tek boyutlu sinyal verileri “Sürekli Dalgacık Dönüşümü (CWT)” ile iki boyutlu görüntülere (skalogram) dönüştürülmüştür. Farklı dalgacık fonksiyonları kullanılarak, sınıflandırma performansını artıracak en iyi sinyal uzunluğu belirlenmiştir. Sınıflandırma aşamasında, önerilen mimari OzNet ile AlexNet ve SqueezeNet karşılaştırılmıştır. OzNet, diğer CNN mimarileri gibi entropi yaklaşımını kullanan SoftMax katmanı ile oluşturulmuştur. Özellik çıkarma ve sınıflandırma başarısı oldukça güçlü olan makine öğrenme algoritmaları ile CNN mimarisini birleştirmenin sınıflandırma performansını daha da iyileştireceği düşünülerek OzNet, SVM ile birleştirilmiştir.

II. veri seti, github.com [97] adresinden alınan, COVID-19 teşhisinde yaygın olarak kullanılan, akciğer CT verileridir. Ön işlem aşamasında, üç farklı ön işleme yöntemi kullanılarak görüntüler işlenmiştir. Birinci ön işleme yöntemi olarak “Ayrık Dalgacık Dönüşümü (DWT)”, ikinci ön işleme yöntemi olarak “Yoğunluk Ayarlama Yöntemi (Intensity Adjustment Method)” ve üçüncü ön işleme yöntemi olarak Maks-Min normalizasyonu ile “Griden Renkliye (RGB) Dönüştürme Yöntemi” kullanılmıştır. Sınıflandırma aşamasında işlenmiş olan üç farklı veri seti ve ham veri seti; OzNet, AlexNet, DenseNet201, GoogleNet, NASNetMobile, ResNet50, VGG-16 ve SqueezeNet mimarileri kullanılarak sınıflandırılmıştır.

III. veri seti ise, beyin kanama görüntülerinin yer aldığı CT verileridir. Veri seti Irak Al Hilla Eğitim Hastanesi'nden 2018 yılında toplanmıştır. Veri seti, Irak Sağlık Bakanlığı Babil Ofisi araştırma ve etik kurulu tarafından onaylanmıştır. Hssayeni tarafından paylaşılan bu veri seti Pysinet.org [98-100] ve Kaggle [101] adreslerinde açık erişimlidir. Veri setinde yer alan görüntüler 650x650 boyutundan 227x227 boyutuna indirgenmiştir. Daha sonra, orijinal veri setinden çocuk, erişkin ve karma veri setleri elde edilmiştir. Bu çalışmada herhangi bir ön işlem yöntemi uygulanmamıştır. Buradaki amaç, OzNet performansını ham veriler üzerinden değerlendirmek olmuştur. Bu bölümde de OzNet, bilinen önceden eğitilmiş mimarilerden MobileNetv2, ResNet-18 ve ShuffleNet ile performans açısından karşılaştırılmıştır. OzNet'in performansı oldukça iyi olsa da söz konusu beyin kanaması olduğundan sınıflandırma sonuçlarının çok daha iyi olması gerekmektedir. Bu amaçla, OzNet Giriş bölümünde bahsedilen bazı önemli makine öğrenme algoritmaları ile birleştirilmiştir.

2.1.1. ECG Veri Seti

Bu çalışmada, 162x65536 boyutunda ve üç sınıftan oluşan ECG veri seti kullanılmıştır [102, 103]. Bu çalışmanın amacı, aritmi (ARR), konjestif kalp yetmezliği (CHF) ve normal sinüs ritmini (NSR) en iyi şekilde sınıflandırabilen algoritmayı geliştirmektir. Birinci sınıf, MIT - BIH Aritmi veri tabanından alınan, 48 hastanın iki öncül ECG kaydı olan ve "ARR" olarak adlandırılan, 96 satır içermektedir [104, 105] . İkinci sınıf, BIDMC Konjestif Kalp Yetmezliği veri tabanından alınan, 15 hastanın iki öncül ECG kaydı olan ve "CHF" olarak adlandırılan, 30 satır içermektedir [106]. Son sınıf ise MIT -BIH Normal Sinüs Ritmi veri tabanından alınan, 18 hastanın iki öncül ECG kaydı olan ve "NSR" olarak adlandırılan, 36 satır içermektedir [102, 103, 105]. Dengeli bir dağılım sağlamak için, her sınıftan rastgele 30 satır seçilmiştir. Böylece veri seti dönüşüme ve sınıflandırmaya uygun hale gelmiştir. Bu çalışmada, CWT ile üç farklı sinyal uzunluğu ve üç farklı dalgacık fonksiyonu kullanılarak, 9 farklı veri seti oluşturulmuştur. Her bir veri setinde 900 (her sınıftan 300) görüntü bulunmaktadır. Şekil 2.1, ECG sinyallerinin sınıflandırmasına ilişkin bir akış şemasını ve bu sürecin işleyişini göstermektedir.




Şekil 2.1. ECG sinyallerinin sınıflandırılma aşamalarını gösteren akış şeması.

2.1.2. COVID-19 CT Veri Seti

Bu çalışmada, COVID-19'un otomatik sınıflandırması için erişime açık CT veri seti kullanılmıştır. Veri seti COVID ve COVID olmayan olmak üzere iki sınıftan oluşmaktadır. COVID için 349 CT taraması ve COVID olmayan için 397 CT taraması vardır [32, 97]. 349 CT taraması, 216 hastadan alınan COVID-19 klinik bulgularını içermektedir [97]. Bu veri setini kullanmanın avantajı, Ocak ve Nisan ayları arasında bu hastalığın hızla yayıldığı dönemde, çok sayıda COVID hastasının tanı ve tedavisini uygulayan Çin'in Wuhan kentindeki Tongji Hastanesi'ndeki kıdemli bir radyolog tarafından onaylanmış olmasıdır [97]. Şekil 2.2, CT tarama görüntüsünü ve gri kanallı histogram grafiğini göstermektedir. Şekil 2.3 ise CT taramalarının sınıflandırılma aşamalarını gösteren akış şemasını göstermektedir.




(a)



(b)

Şekil 2.2. (a) Ham CT tarama görüntüsü. (b) Gri kanallı histogram grafiği.



Şekil 2.3. CT taramalarının sınıflandırılma aşamalarını gösteren akış şeması.


2.1.3. Beyin Kanaması CT Veri Seti

Veriler Irak Al Hilla Eğitim Hastanesi'nden 2018 yılında toplanmıştır. Veri seti, Irak Sağlık Bakanlığı Babil Ofisi araştırma ve etik kurulu tarafından onaylanmıştır. Hssayeni tarafından paylaşılan veri seti, çevrimiçi olarak Pysinet.org [98-100] ve Kaggle [101] adreslerinde açık erişimlidir.

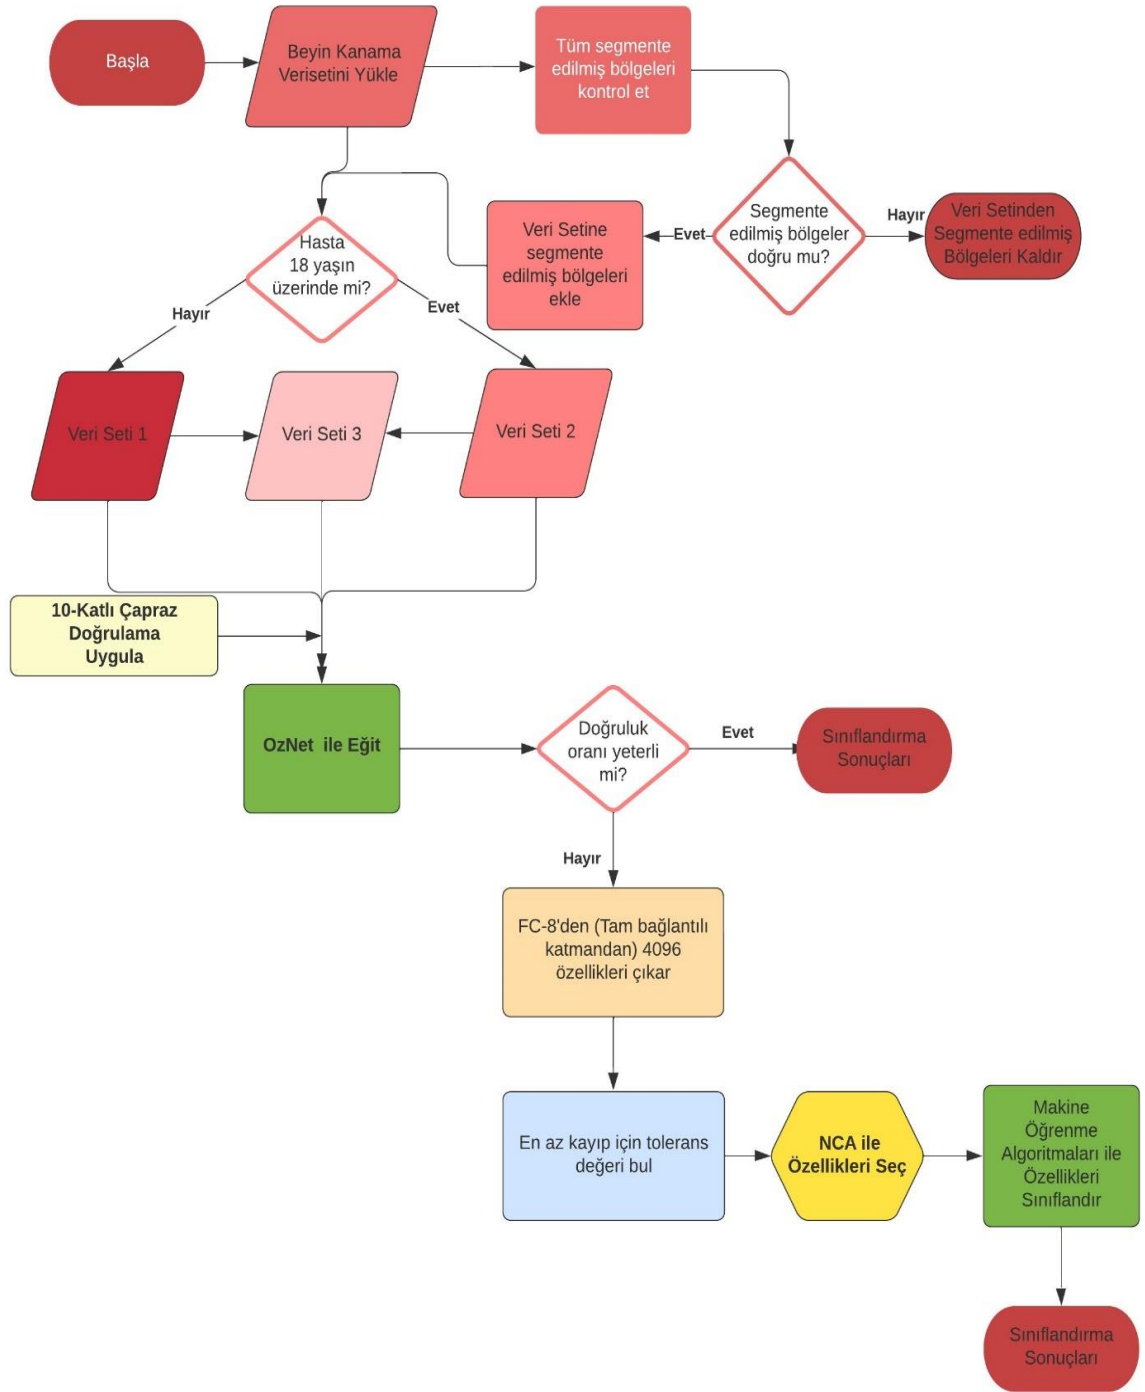
Veri seti, 650x650 boyutlu jpg formatında hem beyin hem de kafatası CT görüntülerini içermektedir. Veri seti toplamda 82 hastadan oluşturulmuştur. Hasta demografisi açısından incelediğinde, 0-72 yaş aralığında olan 46 erkek ve 36 kadın hasta vardır. Ayrıca IVH (intraventricüler kanama), IPH (intraparankimal kanama), SAH (subaraknoid kanama), EDH (epidural kanama) ve SDH (subdural kanama) olmak üzere beş farklı beyin kanaması türü bulunmaktadır. Hssayeni ve diğerleri [100, 107], 5 katlı çapraz doğrulama yoluyla U-Net mimarisi ile kanama bölgelerini elde etmişlerdir.

Bu çalışmada, beyin CT veri setinde yer alan, Hssayeni ve diğerleri[100, 107] tarafından segmentlere ayrılmış her bir bölgenin doğruluğu kontrol edilmiş ve bunların çoğunlukla doğru segmentler olduğu belirlenmiştir. Bu otomatik olarak segmente edilen görüntüler, veri setine dahil edilerek OzNet mimarisi ile sınıflandırmak için kullanılmıştır. Şekil 2.4, IPH bölgesini göstermektedir. Orijinal yapılandırılmamış veri setinde hem beyin hem de kafatası CT görüntüleri yer almaktadır. Bu çalışmada, sadece beyin CT görüntüleri kullanılmıştır. Bu görüntülerden yaş dağılımına göre; çocuklar ve erişkinler olmak üzere iki farklı veri seti ve tüm yaş gruplarının yer aldığı üçüncü veri seti oluşturulmuştur. İlk olarak, 18 yaş altı bireylerin beyin CT görüntülerinden Veri seti 1 oluşturulmuştur. Bu veri setinde 300 EDH görüntüsü, 300 SDH + IPH Kanama görüntü ve 250 Normal (N) görüntü olmak üzere 3 sınıf yer almaktadır. SDH ve IPH 'in aynı sınıfa alınmasının nedenleri: SDH tanısı alan çocuk hastaların da IPH tanısı alması ve IPH tanısı alan çocuk hasta sayısının tüm veri setinde yeterli olmamasıdır. Veri Seti 2 ise erişkinlerin beyin CT görüntülerinden oluşturulmuştur. Bu veri seti, 265 EDH görüntüsü, 150 IPH + SDH Kanama görüntüsü ve 330 N görüntü olmak üzere 3 sınıf içermektedir. Çocuklardaki durumun aksine, IPH tanısı alan erişkin hastalara genellikle SDH tanısı da konulmuştur ve SDH tanısı alan erişkin hasta sayısı tüm veri setinde yeterli değildir. Son olarak, Veri seti 3, tüm yaş gruplarını ve tanıları içeren veri seti olarak oluşturulmuştur.

Genel olarak veri setinde IVH, IPH, SAH, EDH ve SDH olmak üzere beş farklı kanama türü bulunsa da sınıflandırma için yeterli görüntü olmaması nedeniyle IVH ve SAH tanısı konulan beyin görüntüleri oluşturulan veri setlerine dahil edilememiştir. Bu nedenle OzNet' in performansı üç sınıflı ve dört sınıflı veri setleri üzerinden ölçülmüştür. Şekil 2.5, çalışmanın akış şemasını göstermektedir.



Şekil 2.4. Çalışmada kullanılan segmente edilmiş İntraparankimal Kanama örneği.



Şekil 2.5. Beyin Kanama görüntülerini sınıflandırma şeması.

2.2. Ön İşleme Yöntemleri

2.2.1. Dalgacık Dönüşümü


Dalgacık Dönüşümü (Wavelet Transform, WT), sinyalin zaman ve frekans domenlerinin birlikte analiz edilmesini sağlayan dönüşüm yöntemidir. Özellikle durağan olmayan ve sınırsız sinyallerin işlenmesinde WT'den oldukça fazla yararlanılmaktadır. WT'nin çıkış noktası sismik verilerin analizinin yapılması aşamasında olmuştur [108].

Kısa zamanlı Fourier dönüşümünde (STFT) olduğu gibi WT'de de pencere fonksiyonu kullanılmaktadır. WT'de pencere fonksiyonu “ana dalgacık (mother wavelet)” olarak adlandırılır. Dalgacık olarak ifade edilmesinin sebebi, sinyalin çok küçük yapılar olarak ele alınmasındandır. Ana dalgacığın en önemli ayırt edici özelliği ise dönüşüm süreci boyunca hem ölçeklenebilir hem de ötelenebilir olmasıdır [109]. Ölçekleme, frekans ekseninde dalganın genişleyip daralması, öteleme ise zaman ekseninde dalganın kaydırılması işlemidir. STFT'de pencere fonksiyonunun genişliği sabit iken WT' de değişkendir. Bu özellik de hem frekans hem de zaman eksenindeki çözünürlüğü artırmaktadır. Özetle, WT'nin STFT'ye göre kullanım avantajının daha fazla olduğu söylenebilir.

Dalgacık dönüşümü (WT):

1. Sürekli Dalgacık Dönüşümü (CWT)
2. Ayrık Dalgacık Dönüşümü (DWT)

olmak üzere iki başlık altında incelenecektir. Şekil 2.6, bazı dalgacık örneklerini göstermektedir [108, 109].



Şekil 2.6. Dalgacık örnekleri [108, 109].

2.2.1.1. Sürekli Dalgacık Dönüşümü

Sürekli dalgacık dönüşümü (CWT), 1-D sinyali 2-D skalograma dönüştürebilen, sinyalin zaman ekseninde haritalanmasını sağlayarak frekans bileşenlerinin rahatlıkla analiz edilmesini sağlayan dönüşüm yöntemidir. Eşitlik (2.1) ve Eşitlik (2.2),

$$CWT(a,b) = \langle f, \psi_{a,b}^* \rangle = \int_{-\infty}^{+\infty} f(t) \psi_{a,b}^*(t) dt \quad (2.1)$$

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2.2)$$

biçimindedir. Burada,

*: kompleks eşlenik

$f(t)$: sürekli bir sinyal fonksiyonu

$\psi_{a,b}(t)$: ana dalgacık (mother wavelet) fonksiyonu

a : ölçek parametresi

b : öteleme parametresi

olmak üzere, Eşitlik (2.1)'de yer alan $\langle f, \psi_{a,b} \rangle$, $\psi_{a,b}(t)$ ile $f(t)$ 'nin skaler çarpımlarının bir fonksiyonu olarak ifade edilmektedir. Burada, $CWT(a,b)$ düzenlenirse, Eşitlik (2.3)'e ulaşır:

$$CWT(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt \quad (2.3)$$

Elde edilen $CWT(a,b)$ 'nin ters fonksiyonunu alarak $f(t)$ sinyali, Eşitlik (2.4)'te gösterildiği biçiminde olur:

$$f(t) = \frac{1}{C} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} CWT(a,b) \frac{\psi_{a,b}(t)}{|a|^{3/2}} da db \quad (2.4)$$


Burada C , ana dalgacık seçimine bağlı olan normalizasyon sabitini gösterir [110]. Bazı dalgacık dönüşümü fonksiyonları Eşitlik (2.5)-Eşitlik (2.7)'de ifade edilmiştir.

$$\psi_{Morl}(t) = e^{2\pi i t} e^{-\frac{t^2}{2\sigma^2}} = (\cos 2\pi t + i \sin 2\pi t) e^{-\frac{t^2}{2\sigma^2}} \quad (2.5)$$

$$\psi_{Mexh}(t) = \left(1 - \frac{t^2}{\sigma^2}\right) e^{-\frac{t^2}{2\sigma^2}} \quad (2.6)$$

$$\psi_{Bump}(ab) = e^{\left(1 - \frac{1}{1-ab-\mu/\sigma^2}\right)} \chi[\mu - \sigma, \mu + \sigma] \quad (2.7)$$

Burada $\psi_{Morl}(t)$, Morlet; $\psi_{Mexh}(t)$, Meksika şapka; $\psi_{Bump}(ab)$, Bump ana dalgacık fonksiyonunu göstermektedir [110]. Şekil 2.7 bir boyutlu ECG sinyalinin iki boyutlu görüntü örneğini göstermektedir.



Şekil 2.7. 1-D ECG sinyalinin CWT dönüşümü sonrası elde edilen skalogram örneği.

2.2.1.2. Ayrık Dalgacık Dönüşümü

WT' de, CWT'nin hesaplama zorluğundan dolayı genellikle Ayrık Dalgacık Dönüşümü (DWT) kullanılmaktadır [111]. Olası her ölçekte dalgacık katsayısının hesaplanması, iş yükünü önemli ölçüde artıracaktır. Bu durumun oluşması engellemek için belirli ölçekte gruplar oluşturulur. Matematiksel olarak CWT' den farklı değildir. Ölçek ve öteleme parametrelerinin genellikle ikinin kuvveti alınmaktadır. Analiz uzmanının tercihine bağlı olarak sınırlarda değişiklik gösterebilmektedir. DWT' ye ve dalgacık fonksiyonuna ilişkin genel ifade Eşitlik (2.8) ve Eşitlik (2.9)'da gösterilmiştir:

$$DWT(m, n) = \langle f, \psi_{m, n} \rangle = a_0^{-\frac{m}{2}} \sum_{-\infty}^{+\infty} f(k) \psi^*(a_0^{-m}k - nb_0) \quad (2.8)$$

$$\psi_{m, n}(k) = a_0^{-\frac{m}{2}} \psi(a_0^{-m}(k - nb_0 a_0^m)), \quad m, n \in \mathbb{Z} \quad (2.9)$$


Burada, CWT fonksiyonunda karşılık gelen parametreler: $a = a_0^m$, ($a_0 > 1$) ölçek parametresi, $b = nb_0 a_0^m$, ($b_0 > 0$) öteleme parametresi şeklinde ifade edilmiştir. Zaman-frekans konumlarının iyi belirlenebilmesi için $a_0 = 2$, $b_0 = 1$ olarak alındığı durumda ana dalgacık fonksiyonu $\psi_{m, n}(k)$ Eşitlik (2.10)'da gösterilmiştir [4, 9]:

$$\psi_{m, n}(k) = 2^{-\frac{m}{2}} \psi(2^{-m}k - n), \quad m, n \in \mathbb{Z} \quad (2.10)$$

Şekil 2.8, çalışmada kullanılan COVID-19 CT görüntüsünün tek seviyeli DWT dönüşüm örneğini göstermektedir.



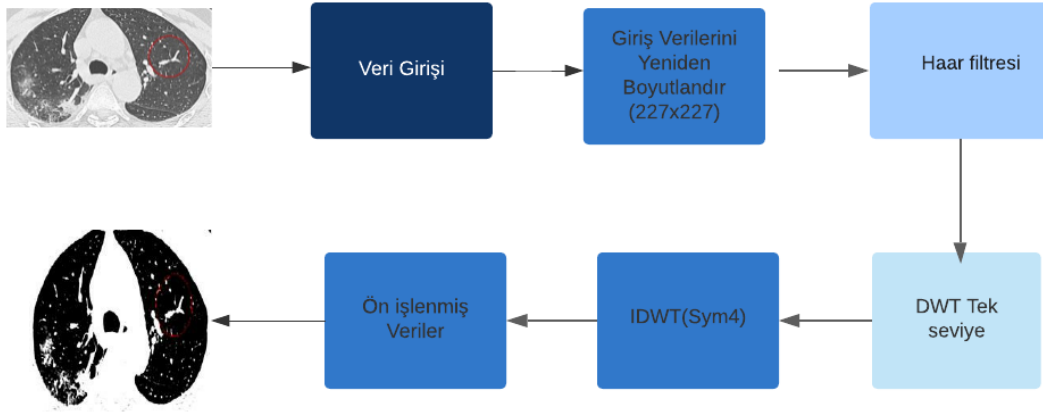
(a)



(b)

Şekil 2.8. (a) Tek seviyeli DWT ile işlenmiş CT tarama görüntüsü. (b) DWT ile işlenmiş CT tarama görüntüsünün histogramı.


Bu çalışmada, COVID-19 CT taramalarının gürültüsünü azaltmak için, dB veya Haar filtresi olarak ifade edilen filtreleme yöntemi ile DWT uygulanmıştır. DWT, bir giriş taramasını; Düşük-Düşük (LL), Düşük-Yüksek (LH), Yüksek-Düşük (HL) ve Yüksek-Yüksek (HH) olmak üzere dört alt gruba ayırmıştır. Bu çalışmada, Güngör'ün [42] çalışma bulgularından yola çıkarak, gürültüyü azaltmak için sym aracılığıyla tek seviyeli ayrıştırma uygulanmıştır. Son olarak, taramaların birleştirilmesi, Ters DWT (Inverse DWT, IDWT) aracılığıyla eski haline getirilmiştir [112]. Şekil 2.9, COVID-19 CT taramasında uygulanan DWT aşamalarını göstermektedir.



Şekil 2.9. COVID-19 CT veri setinde uygulanan ayrık dalgacık dönüşümünün akış şeması.

2.2.2. Yoğunluk Ayarlama Yöntemi

Yoğunluk Ayarlama yöntemi, iyi bilinen kontrast geliştirme yöntemlerinden biridir [113]. Görüntü kalitesini artırmak için geliştirilmiştir [114]. Bu yöntem, doğrusal olarak düşük girdiden düşük çıktıya ve yüksek girdiden yüksek çıktıya eşlenir. Ayrıca, bu yöntem gama düzeltme algoritması olarak da kabul edilmiştir. Gama değerine bağlı olarak, giriş ve çıkış görüntüleri doğrusal olmayan bir şekilde de haritalanabilir. Gama değerine göre görüntülerin kontrastı değiştirilebilir. Yani gama 1 alındığında görüntü doğrusal olarak haritalanır. Gama 1'den küçük alındığında görüntü doğrusal olmayan bir şekilde haritalanır ve daha parlak görüntü elde edilir. Gama 1'den büyük alındığında görüntü doğrusal olmayan bir şekilde haritalanır ve daha koyu görüntü elde edilir [115]. Şekil 2.10, Gama değeri 2 alınarak yoğunluk ayarlama yöntemi ile işlenmiş CT tarama görüntüsünü ve histogram grafiğini göstermektedir.



(a)

(b)


Şekil 2.10. (a) Yoğunluk ayarlama yöntemi ile işlenmiş CT tarama görüntüsü (gama 2)

(b) Yoğunluk ayarlama yöntemi ile işlenmiş CT taramasının görüntü histogramı.


2.2.3. Griden Renkli RGB Dönüşümü

Griden renkli RGB (Red, Green, Blue: Kırmızı, Yeşil, Mavi) dönüşümü, görüntü işlemede çok önemli bir görselleştirme yöntemidir. Özellikle siyah beyaz biyomedikal görüntülerin insan gözü tarafından kolay anlaşılacak şekilde söylenebilir [116]. Bu dönüşüm yöntemi, genellikle doktor, radyolog vb. uzmanların, görüntüyü daha net bir şekilde ayırt edebilmesini amaçlar [117]. Bu çalışmada, gri kanallarda yer alan COVID CT tarama görüntüleri bu dönüşüm aracılığı ile renkli hale getirilmiştir. Amaç, renkli görüntülerin insan gözü ile ayırt edilmesi daha kolayken sınıflandırma algoritmalarında da aynı etkinin olup olmadığını araştırmaktır.

Literatürde, birçok farklı renk uzayı kullanılmaktadır. Bu çalışmada RGB renk uzayı uygulanmıştır. Birçok çalışmada mavi-yeşil veya kırmızı-turuncu renklendirme çalışmaları yapıldığından bu çalışmada mor renk kullanılmıştır. Ayrıca, görüntülerdeki gürültüyü azaltmak için Maks-Min normalleştirilmesi gerçekleştirilmiştir. CT tarama görüntülerinin boyutu 227x227x3 olarak yeniden boyutlandırılmıştır. Şekil 2.11, dönüştürülmüş RGB CT tarama görüntüsünü ve histogram grafiğini göstermektedir.



(a)



(b)

Şekil 2.11. (a) Griden renkli RGB yöntemi ile işlenmiş CT tarama görüntüsü (b) Griden renkli RGB yöntemi ile işlenmiş CT taramasının görüntü histogramı.

2.3. Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (Convolutional Neural Networks, CNN), iki boyutlu verinin analizi için tasarlanmış ve derin öğrenmenin özelleştirilmiş bir hali olarak ortaya çıkmıştır. Sadece iki boyutlu değil, tek boyutta dahil olmak üzere, çok boyutlu verilerin analizinde de yaygın olarak tercih edilen bir algoritmadır. Diğer sınıflandırma ve kümeleme algoritmalarının hesaplama karmaşıklığı nedeniyle gerçek zamanlı verilere uygulanması oldukça zordur [118]. Bu karmaşıklığın üstesinden gelebilen derin öğrenme teknolojisi, ham verileri kullanarak uçtan uca yapıda olma özelliği ile doğrudan özellik çıkarımı ve sınıflandırma yapabilmektedir. Bu açıdan derin öğrenme algoritmaları yapay zekâ alanında oldukça popülerdir. Özellikle de büyük veri içeren araştırmalar için çok iyi sonuçlar verdiği ifade edilmiştir. CNN algoritması sayesinde, biyomedikal sinyallerin ve görüntülerin analizinde, uzman görüşü olmadan akıllı telefonlarda, saatlerde, holter cihazları vb. cihazlarda rahatlıkla teşhis konulabilir, her kişi kendi sağlığını rahatlıkla kontrol edebilir hale gelecektir [8].

CNN algoritması, bir görüntüyü tüm özelliklerine ayırarak çeşitli katmanlarda işlemektedir. En yaygın olarak kullanılan katmanlar:

1. Evrişim katmanı
2. Doğrusal olmayan katman
3. Havuzlama katmanı
4. Düzleştirme katmanı
5. Tam bağlantılı katman

biçiminde ifade edilmektedir [7, 110, 119].

1. Evrişim Katmanı (Convolutional Layer): Evrişim işlemi, görüntünün özelliklerinin belirlendiği katmandır. Birden fazla özellik belirlemek için evrişim katman sayısı aynı oranda artacaktır. Bu katman CNN'nin ana yapıtaşıdır.
2. Doğrusal Olmayan Katman (Non-Linear Layer): Bu katman aktivasyon katmanı olarak da bilinir. Sistemin doğrusal olmayan fonksiyonlar ile aktivasyonunun gerçekleştirilmesi amaçlanır. Aktivasyon için Doğrusal, SoftMax, Sigmoid, Hiperbolik Tanjant (Tanh), ve Doğrultulmuş doğrusal (Rectifier Linear Unit, ReLU) fonksiyonları kullanılmaktadır. Son yıllarda hızlı olması sebebiyle sıklıkla ReLU fonksiyonu ($f(x) = \max(0, x)$) tercih edilmektedir.
3. Havuzlama Katmanı (Pooling Layer): Mevcut girdinin özellikleri korunarak daha küçük matrisler elde edilir. Bu sayede hesaplama karmaşıklığı azaltılmış olur.
4. Düzleştirme Katmanı (Flattening Layer): Bir önceki aşamadan elde edilen matris formatındaki veri, tam bağlantılı katmana uygun olarak hazırlanır.
5. Tam Bağlantılı Katman (Fully-Connected Layer): Evrişimli sinir ağları katmanlarının en önemlisidir. Veriler düzleştirme katmanından alınır, sinir ağı yoluyla eğitilir ve öğrenme işlemi gerçekleştirilir.

2.3.1. Önceden Eğitilmiş Evrişimli Sinir Ağları

Önceden eğitilmiş CNN mimarileri (pre-trained CNN architectures), transfer öğrenme yöntemi aracılığı ile ilgili veri setlerinin sınıflandırılması için kullanılmıştır. Transfer öğrenme yöntemi ile önceden öğrenilen parametreler yeni CNN mimarisine transfer olmaktadır. Bu yöntemde genellikle son katmanlar ile yeni belirlenen katmanlar yer değiştirmektedir. Bu çalışmada, AlexNet [120], DenseNet201 [121], GoogleNet [122], MobileNetv2 [123], NASNetMobile [124], ResNet-18 [125], ResNet50 [125], ShuffleNet [126], SqueezeNet [127] ve VGG-16 [128] gibi önceden eğitilmiş mimarilerden yararlanılmıştır. Bu mimarilere ilişkin detaylar aşağıda verilmiştir.

AlexNet [120], beş evrişim katmanına, üç tam bağlantılı katmana, aşırı uyumu azaltmak için bir bırakma katmanına ve bir SoftMax katmana sahip CNN mimarilerinden biridir. İlk çıkan önceden eğitilmiş mimarilerden olsa da oldukça yüksek performansa sahip olan bu mimari, günümüzde de oldukça yaygın olarak kullanılmaktadır. Bu mimarinin toplam parametre sayısı 62.3 milyondur. Girdi görüntü boyutu ise $227 \times 227 \times 3$ 'tür.

DenseNet201 [121], yüksek verimlilikle hesaplama yapabilen güçlü belleğe sahip 201 derin katmanlı olan CNN mimarilerinden biridir. DenseNet201'de her katman önceki tüm katmanlarla ilişkilidir. Özellik haritalarını oluştururken, özellikleri birleştirir ve bir sonraki katmana iletirler. Geleneksel CNN mimarileri L katmana ve L bağlantıya sahiptir. Burada ise L katmanlı mimari $L(L+1)/2$ bağlantıya sahiptir. Bu mimarinin toplam parametre sayısı yaklaşık 20 milyondur. Girdi görüntü boyutu ise $224 \times 224 \times 3$ 'tür.

GoogleNet [122], iki evrişim katmanına, dört maksimum havuzlama katmanına, dokuz başlangıç katmanına, bir küresel ortalama havuzlama katmanına, bir bırakma katmanına, bir doğrusal katmana ve bir Softmax katman ile 22 katmanlı CNN mimarilerinden biridir. Ayrıca bu mimaride yer alan her evrişim katmanı ReLU aktivasyon fonksiyonu ile etkinleştirilir. Bu mimarinin toplam parametre sayısı 7 milyondur. Girdi görüntü boyutu ise $224 \times 224 \times 3$ 'tür.

MobileNetv2 [123], parametre sayısı diđer mimarilere gre daha az olan, mobil cihazlar iin tasarlanmıř bir mimaridir. ˆzellikleri filtrelemesi iin ayrılabilir evriřimli katmanlar kullanılmıřtır. Bylece modelin derinliđi indirgenerek, hızlı sonu vermesi sađlanmıřtır. Evriřim katmaları, darbođaz (bottleneck) iřlemleri ve ortalama havuzlama katmanlarından oluřmaktadır. Bu mimari toplamda 154 katmana ve 3,5 milyon parametre sayısına sahiptir. Girdi grnt boyutu ise 224x224x3'tr.

NASNetMobile [124], pekiřtirmeli đrenme tekniđi aracılıđıyla optimum CNN mimarisi bulmayı hedeflemiřtir. Nral Mimari Arama (NAS), Google Beyin Ekibi (Google Brain team) tarafından geliřtirilmiřtir [129]. Farklı boyutlarda NAS mimarileri geliřtirilmiřtir. NASNetMobile, tařınabilir cihazlar ile uyumlu boyut azaltılmıř bir srmdr. Bu mimarinin toplam parametre sayısı yaklařık 4,5 milyondur. Girdi grnt boyutu ise 224x224x3'tr.

ResNet-18 [125], 18 derin katmana sahip toplamda 72 katmandan oluřan bir mimaridir. Bu mimari, etkin bir Őekilde iřlemleri gerekleřtirmek iin ok sayıda evriřim katmanından yararlanmıřtır. ResNet'in temel amacı atlama yoluyla kısayol bađlantıları gerekleřtirmektir. Bu atlama iřleminde, bađlantılar mimariye baskı yapar ve ardından ađ daha hızlı đrenir. Mimari, karmařık katmanlı formu nedeniyle bir DAG (Ynlendirilmiř Asiklik Grafik; DAG-Directed Acyclic Graph) ađı olarak ifade edilir [130]. Bu mimarinin toplam parametre sayısı 11 milyonun zerindedir. Girdi grnt boyutu ise 224x224x3'tr.

ResNet50 [125], 48 evriřim katmanına, bir maksimum havuzlama katmanına ve bir ortalama havuzlama katmanına sahip 50 katmanlı CNN mimarilerinden biridir. Artık blokları olduđu iin klasik bir CNN mimarisi deđildir. Katmanlar zerindeki ađırlıkları yarı yarıya azaltabilme zelliđi sayesinde sađlam mimariler arasında yer almaktadır. Bu mimarinin toplam parametre sayısı 23 milyonun zerindedir. Girdi grnt boyutu ise 224x224x3'tr.


ShuffleNet de [126] az sayıda parametre sayısı ile tasarlanmıř, mobil cihazlarda kullanılabilen mimarilerdendir. 50 darbođaz (bottleneck) iřlemlerine sahip artık yapıda olan bir mimaridir. Bu

mimarinin toplam parametre sayısı yaklaşık 1.5 milyondur. Girdi görüntü boyutu ise 224x224x3'tür.

SqueezeNet [127], bağımsız bir evrişimli katman (conv1) ile başlayan, ardından sekiz ateşleme modülü ve son evrişimli katman (conv10) ile biten önceden eğitilmiş CNN mimarilerinden biridir. Toplamda, özellikle de son sunulan sürümde, on evrişimli katmandan, maksimum havuz katmanlarından ve bir SoftMax katmanından oluşmaktadır.

VGG-16 [128], 13 evrişim katmanına, beş maksimum havuzlama katmanına, üç tam bağlantılı katmana ve bir Softmax'a sahip önceden eğitilmiş CNN mimarilerinden biridir. Ayrıca, her gizli katman, ReLU aktivasyon fonksiyonu ile etkinleştirilir. Bu mimarinin toplam parametre sayısı 138 milyondur. Girdi görüntü boyutu ise 224x224x3'tür.

Bu çalışmada, 34 katmandan oluşan ve farklı veri setleri kullanılarak çok kez eğitilmiş yeni bir CNN mimarisi sunulmuştur. Bu önerilen CNN, OzNet olarak adlandırılmıştır. OzNet ile ilgili veri setleri üzerinden sınıflandırma çalışmaları yapılarak etkinliği ispatlanmış olan önceden eğitilmiş mimariler arasında olup olmadığı araştırılmıştır. Şekil 2.12, sunulan OzNet' in şemasını göstermektedir.



Şekil 2.12. Önerilen OzNet mimarisinin şeması.

2.3.2. OzNet: Yeni bir CNN Mimarisi

Çağın artan ihtiyaçları ile birlikte yapay zekâ da hızla ilerlemektedir. Derin öğrenme de bu ihtiyaçtan doğan algoritmalarından biridir. Birçok araştırmacı, farklı konularda derin öğrenme algoritmalarından yararlanmaktadır. Burada derin öğrenme algoritmalarından biri olan yeni bir CNN mimarisi, OzNet tanıtılmaktadır. OzNet olarak isimlendirme nedeni: LeNet [131] gibi tasarımcının isminin ilk iki harfinin kullanılmasıdır. Amaç, aşırı uyumdan kaçınan ve biyomedikal veriler üzerinde sağlam test sonuçları veren bir mimari sunmaktır.

OzNet, 34 katmandan oluşan yeni bir CNN mimarisidir. 7 evrişim katmanı, 7 maksimum havuzlama katmanı, 2 tam bağlantılı katman, bir bırakma katmanı, bir SoftMax katmanı ve bir sınıflandırma katmanı vardır. Ayrıca, her evrişim katmanı, toplu normalleştirme katmanı ve aktivasyon katmanı ile birleştirilir. Bu çalışmada diğer aktivasyon fonksiyonlarına göre daha hızlı olması nedeniyle ReLU aktivasyon fonksiyonunu tercih edilmiştir. Aslında OzNet'in mimari yapısı VGG'ye benzese de farklıdır. Çünkü burada farklı evrişim katmanları, filtre numaraları, filtre boyutları ve tam bağlantılı katmanlar kullanılmıştır. Minimum bir VGG (VGG-11) 11 evrişimli katmana sahipken, OzNet 7 evrişimli katmana sahiptir. VGG'de filtre boyutu her katman için 3x3 olarak alınır. Ancak, OzNet sadece 3x3'ü değil, Çizelge 2.1'de detaylandırıldığı gibi farklı filtre boyutlarını da kullanır. Ayrıca, VGG'de ilk evrişimli filtre sayıları 64 ile başlar, daha sonra 512'ye ulaşana kadar sonraki katmanlardaki filtre sayıları iki katına çıkar [128, 132]. OzNet' te ise ilk filtre sayısı 64 ile başlar, sonraki iki katmandaki filtre sayısı 128'dir. Ardından 256'ya ulaşır. Sonraki üç katmanın filtre sayısı yine 128'dir. Ayrıca tam bağlantılı katmanlar da farklıdır. OzNet, bir bırakma katmanına sahip tam bağlantılı iki katman içerirken, VGG'nin farklı filtre boyutlarına sahip üç tam bağlantılı katmanı vardır. Dolayısıyla, OzNet, VGG'den ve diğerlerinden farklı bir yapıya sahiptir.

Burada OzNet, ilk olarak çapraz entropi yaklaşımıyla bir sınıflandırma algoritması olarak kullanılmıştır. Sınıflandırma performansının yanı sıra ECG ve beyin kanaması veri setlerinden özellikler çıkarmak için de OzNet' ten yararlanılmıştır. OzNet, çok sayıda evrişim katmanı sayesinde veri kümesinden özellikleri etkin bir şekilde çıkarır. Çizelge 2.1'de farklı filtre boyutları, filtre numaraları, dolgu ve adım ile OzNet'in parametre detaylarına yer verilmiştir.

Ayrıca, optimizasyon yöntemi olarak stokastik gradyan inişi, 0.95 momentum parametresi ve 0.0001 öğrenme oranı eğitim için seçenek parametreleri olarak belirlenmiştir.

Bu çalışmada OzNet mimarisi hem sınıflandırıcı hem de derin özellik çıkarıcı olarak görevlendirilmiştir. Bu mimari temelde biyomedikal veri kümelerinin sınıflandırılması için tasarlanmıştır ve en iyi sonuçların sunulması için, OzNet çeşitli algoritmalarla (NCA, ANN, Adaboost, Torbalama, Karar Ağacı, K-NN, LDA, Naive Bayes, SVM) birleştirilmiştir. Bu yeni yapılara, OzNet hibrit algoritmaları adı verilmiştir. Bu hibrit algoritmalarda görüntülerden otomatik özellik çıkarımı için OzNet kullanılmaktadır. OzNet'in tam bağlantılı katmanından elde edilen 4096 özellikten yararlanılmıştır.

Çizelge 2.1. OzNet mimarisinin katmanlarının detayları.

Katman İsmi	Türü	Katman Parametreleri	Çıktı Boyutu
Girdi	Görüntü girdisi	$227 \times 227 \times 3$	$227 \times 227 \times 3$
Conv-1	Evrişim 2D	Filtre sayısı =64, Filtre boyutu= [5 5], Adım = [1 1], Dolgu= [1 1 1 1], Toplu Normalleştirme, ReLU	$225 \times 225 \times 64$
MaxPool-1	Maks Havuzlama	Havuz boyutu = [3 3], Adım = [2 2], Dolgu = [0 0 0 0]	$112 \times 112 \times 64$
Conv-2	Evrişim 2D	Filtre sayısı =128, Filtre boyutu = [3 3], Adım = [1 1], Dolgu = [1 1 1 1], Toplu Normalleştirme, ReLU	$112 \times 112 \times 128$
MaxPool-2	Maks Havuzlama	Havuz boyutu = [3 3], Adım = [2 2], Dolgu = [0 0 0 0]	$55 \times 55 \times 128$
Conv-3	Evrişim 2D	Filtre sayısı =128, Filtre boyutu = [13 13], Adım = [1 1], Dolgu = [0 0 0 0], Toplu Normalleştirme, ReLU	$55 \times 55 \times 128$

MaxPool-3	Maks Havuzlama	Havuz boyutu = [3 3], Adım = [2 2], Dolgu = [0 0 0 0]	27x27x128
Conv-4	Evrişim 2D	Filtre sayısı =256, Filtre boyutu = [7 7], Adım = [1 1], Dolgu = [1 1 1 1], Toplu Normalleştirme, ReLU	27x27x256
MaxPool-4	Maks Havuzlama	Havuz boyutu = [2 2], Adım = [2 2], Dolgu = [0 0 0 0]	13x13x256
Conv-5	Evrişim 2D	Filtre sayısı =128, Filtre boyutu= [3 3], Adım = [1 1], Dolgu = [1 1 1 1], Toplu Normalleştirme, ReLU	13x13x128
MaxPool-5	Maks Havuzlama	Havuz boyutu = [3 3], Adım = [2 2], Dolgu = [0 0 0 0]	6x6x128
Conv-6	Evrişim 2D	Filtre sayısı =128, Filtre boyutu = [3 3], Adım = [1 1], Dolgu = [1 1 1 1], Toplu Normalleştirme, ReLU	6x6x128
MaxPool-6	Maks Havuzlama	Havuz boyutu = [3 3], Adım = [2 2], Dolgu = [0 0 0 0]	3x3x128
Conv-7	Evrişim 2D	Filtre sayısı=128, Filtre boyutu= [3 3], Adım = [1 1], Dolgu = [1 1 1 1], Toplu Normalleştirme, ReLU	3x3x128
MaxPool-7	Maks Havuzlama	Havuz boyutu = [2 2], Adım = [2 2], Dolgu = [0 0 0 0]	1x1x128
FC-8	Tam bağlantılı	4096	1x1x4096
Drop-8	Bırakma	50%	
FC-9	Tam bağlantılı	3 (sınıf sayısı)	1x1x3
Softmax	Softmax		1x1x3
Çıktı	Sınıflandırma	Çapraz entropi	

2.4. Özellik Seçim Yöntemleri

2.4.1. Komşuluk Bileşenler Analizi (NCA) ile Özellik Seçimi

Yüksek boyutlu verilerde uygun bir özellik seçimi öne çıkmaktadır [72, 133]. Birçok araştırmacı boyut küçültmeye odaklanır. Bununla birlikte, boyut küçültme sırasında önemli özellikler kaybolabilir [72, 133, 134]. Temel bileşenler analizi (PCA), klasik bir doğrusal özellik seçim yöntemidir. Bu yöntem yaygın olarak boyut küçültme için kullanılır. Ancak, veri boyutu küçük olduğunda PCA ile önemli özellikler kaybolabilir [135]. Doğrusal Diskriminant Analizi de (LDA) özellik seçimi için klasik ve parametrik bir yöntemdir. LDA, sınıf etiketlerinin ayırt edici bilgilerini korumak için özelliklerin doğrusal bir kombinasyonu hakkında bilgi edinen bir yöntemdir [135]. LDA, tüm sınıfların aynı Gauss olasılık yoğunluğundan geldiğini ve aynı kovaryans matrisine sahip olduğunu varsayar. Bununla birlikte LDA, sınıf içi dağılım matrisi neredeyse tekil olduğunda, yüksek boyutlu verilerle uğraşıldığı zaman küçük örneklem boyutu sorunu ile karşılaşır [136]. Ayrıca, Sıralı Özellik Seçimi de (SFS) popüler bir yöntemdir. Ancak diğer özellikler eklendikten sonra önemsiz hale gelen özellikleri çıkaramamaktadır [133, 134]. Tüm bu koşulların tersine, NCA herhangi bir varsayımda bulunmaz. Boyut küçültme işlemi sırasında hiçbir anlamlı bilgi kaybolmaz. NCA'nın bu özelliği sayesinde hiçbir önemli özelliğin kaybolmaması avantajından yararlanır [133].

NCA, bir dışarıda bırakma (LOO) ile denetimli K-En yakın komşu algoritmasında Mahalanobis uzaklık ölçüsünü kullanan bir yöntemdir [136]. Bu yöntem, eğitim setindeki K-en yakın komşu puanının stokastik bir varyantını LOO ile hızlı bir şekilde maksimize eder [136]. NCA, bir düzleştirme terimiyle beklenen sınıflandırma doğruluğunu LOO ile maksimize ederek bir özellik ağırlıklandırma vektörü öğrenir [133]. NCA'nın ayrıntılı açıklaması için Goldberger ve diğerleri [136], Yang ve diğerleri [137] ve Shang ve diğerlerinin [133] çalışmaları incelenebilir.

NCA yöntemi, önemli özellikleri seçebilen güçlü bir ayırıcıdır. Bu çalışmada, beyin CT görüntülerini sınıflandırma performansını iyileştirmek için bu parametrik olmayan özellik

seçim yönteminden yararlanılmıştır. Bu çalışmada oluşturulan üç farklı veri seti için de bu yöntem kullanılmıştır. Ayrıca NCA, diğer yaygın olarak kullanılan iki parametrik olmayan Ki-kare ve minimum Fazlalık Maksimum İlişki (mRMR) yöntemleriyle karşılaştırılmıştır. Sonuç olarak, NCA'nın diğerlerinden daha etkili bir yöntem olduğu ve sınıflandırma performansını arttırdığı söylenebilir.

2.4.2. Ki-kare (χ^2) ile Özellik Seçimi

Ki-kare, istatistikte sıklıkla kullanılan hem parametrik hem de parametrik olmayan özelliğe sahip kuramsal dağılımlardan biridir. Bir bilgi hakkında sıralama yapabilen ve Ki-kare testi olarak bilinen, son dönemlerde özellik seçim yöntemi olarak da kullanılan yöntemlerdendir [1]. Ki-kare testinde sıra, bir gözenin beklenen değeri ile gerçek değeri arasındaki fark kullanılarak belirlenir [1, 138, 139]. Ki-kare değeri Eşitlik (2.11) ile hesaplanır [138, 139]:

$$\chi^2 = \sum_{i=1}^R \sum_{j=1}^C \frac{(f_{ij} - e_{ij})^2}{e_{ij}} \quad (2.11)$$

Burada f_{ij} : gözlenen sıklık, e_{ij} : beklenen sıklık, R : satır sayısı, C : sütun sayısı, $i = 1, 2, \dots, R$, $j = 1, 2, \dots, C$, ve χ^2 : hesaplanan Ki-kare değerini göstermektedir. İlk olarak beklenen sıklık her göze için hesaplanır. Daha sonra, her göze için göze sıklık ile beklenen sıklık farkının karesi beklenen sıklığa bölünür. Böylece her göze için hesaplanan bu değerler toplanarak Ki-kare değeri (χ^2) elde edilir. p-değerini elde etmek için bu toplam olasılık yoğunluk fonksiyonunda kullanılır [1]. Bu aşamaya başlamadan önce serbestlik derecesi Eşitlik (2.12) de ifade edildiği biçimde hesaplanmalıdır:

$$\nu = (R - 1) \times (C - 1) \quad (2.12)$$

Eşitlik (2.13) gösterilen olasılık yoğunluk fonksiyonu [140]:

$$f(x, \nu) = \begin{cases} \frac{1}{2^{\nu/2} \Gamma\left(\frac{\nu}{2}\right)} x^{\nu/2-1} e^{-x/2}, & x > 0 \\ 0 & , \text{öteki değerler için} \end{cases} \quad (2.13)$$

biçimindedir. p-değeri, Eşitlik (2.14) ile hesaplanır [1].

$$p - \text{değeri} = \int_{\chi^2}^{\infty} f(x, \nu) dx \quad (2.14)$$

p- değerinin bu şekilde hesaplanması kolay değildir. Bunun yerine, istatistikte yaygın olarak kullanılan Ki-kare tablosuna başvurulur. Bu değer tablodan kolaylıkla elde edilir [1].

Bu yöntem özellik seçimi için kullanıldığında, sınıf ile hedef arasındaki hesaplanan Ki-kare değeri kullanılarak en iyi m tane özellik seçilir [1]. Böylece birbiri ile ilişki miktarı yüksek olan önemli özellikler seçilerek boyut indirgeme işlemi gerçekleştirilir. Bu yöntem beyin CT görüntülerinin analizinde kullanılmıştır.

2.4.3. Minimum Fazlalık Maksimum İlişki (mRMR) ile Özellik Seçimi

Minimum fazlalık maksimum ilişki (minimum Redundancy Maximum Relevance, mRMR) yönteminde sınıf ile ilişki miktarı en yüksek özellikler seçilirken özellikler arasındaki fazlalığı minimum yapmaya çalışan özellik seçim yöntemidir [141]. İlişki düzeyi genellikle ya korelasyon katsayısı ya da ortak bilgi (mutual information) ile karakterize edilir [142]. Bu yaklaşıma göre en yüksek ilişkiye sahip m tane özellik her zaman en iyi m özellik olmayabilir. m tane özelliğin fazlalıkları da incelenmesi gerekmektedir. Aynı zamanda bu fazlalıkları minimum yapan özellikler seçilmelidir. Bu yöntem, beyin CT görüntülerinin analizinde kullanılmıştır.

2.5. Sınıflandırma Algoritmaları

Bu bölümde, Yapay Sinir Ağları (ANN), Karar Ağacı (DT), K- En yakın komşu (KNN), Doğrusal Diskriminant Analizi (LDA), Naive Bayes (NB), Destek Vektör Makineleri (SVM), Adaboost ve Torbalama (Bagging) sınıflandırıcıları kısaca sunulmaktadır. Ayrıca, en iyi sınıflandırma sonuçları için deneme yanılma yoluyla belirlenen parametreleri de verilmektedir.

2.5.1. Yapay Sinir Ağları (ANN)

Yapay Sinir Ağları (Artificial Neural Networks, ANN), doğrusal olmayan modellerin zengin bir ailesidir [143]. Son zamanlarda ANN, makine öğrenmesinde, özellikle de denetimli öğrenmede başarıyla uygulanmaktadır. İlk olarak, McCulloch and Pitts [144] tarafından 1943 yılında tanıtılmıştır. ANN, hayvanların ve insanların nöron ağlarından esinlenerek ortaya çıkarılmış ve teoride güçlü matematiksel yapı ile desteklenmiştir [143]. Daha sonra, Rumelhart, et al. [145] tarafından geliştirilen ANN'in uygulamalarda yaygın olarak kullanımını artmıştır. ANN'in esnek yapısı sayesinde çeşitli gerçek verilere rahatlıkla uygulanabilmektedir [143]. Daha detaylı bilgiler için H. Jiang [143] önerilebilir.

Bu çalışmada, ReLU aktivasyon fonksiyonu ve Softmax katmanı ile birlikte 10 gizli katman kullanılmıştır. Eğitimci olarak sınırlı bellekli Broyden-Fletcher-Goldfarb-Shanno yarı-Newton algoritmasından yararlanılmıştır. Burada her deney için maksimum yineleme sayısı, 1000 olarak belirlenmiştir. Bu çalışmada, ANN için belirlenen parametreler en iyi sınıflandırma performansını vermektedir.

2.5.2. Karar Ağacı (DT)

Karar ağacı (Decision Tree, DT), genellikle regresyon veya sınıflandırma amacıyla kullanılır ve parametrik olmayan makine öğrenme algoritmalarından biridir [143, 146]. Algoritma, Ross Quinlan tarafından C4.5 programıyla tasarlanmıştır. 1970'lerin sonlarında başlanan algoritma, 20 yıl boyunca geliştirilmiştir [147]. DT sınıflandırma problemi için uygulandığında hiyerarşik bir yapıya sahiptir. Giriş ağacı düğümleri, alanı bölmelere ayırır ve uç düğümler, yeterince küçük veya yeterince tek biçimli olmalarına bağlı olarak alanlara sınıf etiketleri atar. Bölünmeler, iki veya daha fazla sonucu olabilen seçili özelliklere dayalı bazı ilişki koşullarıyla tanımlanır [148]. DT'de, iki boyutlu bir özellik vektörü, $\mathbf{x} = [x_1 \ x_2]^T$ olarak düşünüldüğünde, son düğüm dışındaki her düğüm, x_i özelliği ile ilgili verilecek olan karar, ikili bir soru ve $x_i \leq t_j$ formu alan bir eşik t_j değeri ile ilişkilidir [143]. Burada, her yaprak düğümü, girdi uzayında bir alanı belirtir. Algoritma kök düğüm gibi herhangi bir giriş özelliği olarak başlar ve düğüm ile ilgili soruyu sorgular. Cevap, sol alt düğüme düşer. Aksi takdirde, cevap, sağ alt düğüme düşer. Bu işlem bir yaprak düğüme ulaşana kadar devam eder [143].

Bu çalışmada, tahmin edicilerin seçimi için standart CART kullanılmış ve bir ayırma kriteri olarak Gini'nin çeşitlilik indeksi seçilmiştir. Bu çalışmada DT için bölmelerde maksimum kategori, 10 olarak belirlenmiştir.

2.5.3. K-En Yakın Komşu (KNN)

K-En Yakın Komşu (K-Nearest Neighbor, KNN) algoritması emek gerektiren algoritmalarından biri olmuştur ve daha fazla bilgi, işlem gücü sağlanana kadar da popülerlik kazanamamıştır. Algoritmanın isminde en yakın ifadesinin kullanılma sebebi, Öklid uzaklığı gibi bir uzaklık metriği ile hesaplanmasındandır [147]. En yakın komşu algoritmasının temeli, sınıflandırması bilinmeyen bir girdi örneklem vektörünü, en yakın komşu sınıfına atamasıdır [149, 150]. Bu durum, vektörün K-en yakın komşu arasında daha büyük bir sayı ile sembolize edilen sınıfa atanmasıyla K-en yakın komşuya kadar genişletilebilir [149]. Birden fazla komşu göz önüne alındığında, K-en yakın komşu grubunda en fazla komşuya sahip sınıflar arasında bir bağlantı olasılığı vardır. Bu sorunu çözenin basit bir yolu, olası k değerlerini sınırlamaktır [149]. Burada minimum hata oranını oluşturan k değeri seçilir. Genel olarak, k değerinin artması eğitim sayısını artırmaktadır [151].

Bu çalışmada uzaklık metriği olarak Öklid uzaklığı seçilmiştir. Ayrıca, en iyi sınıflandırma performansına göre eşit uzaklık ağırlığı ve en yakın 10 komşu belirlenmiştir.

2.5.4. Doğrusal Diskriminant Analizi (LDA)

Doğrusal Diskriminant Analizi (Linear Discriminant Analysis, LDA), 1936'da Ronald Fisher tarafından önerilmiştir [152]. LDA, sınıf içi varyansı azaltan ve sınıfların ortalamaları arasındaki uzaklığı maksimuma çıkaran, izdüşüm hiperdüzleminin belirlenmesiyle meydana gelir [152]. Bu iki hedef, ilgili hiper düzlemi tanımlayan özvektörlerle ilişki kurarak ve özdeğer sorununu ele alarak çözülebilir [152]. Bu durum PCA'da da benzerdir. Verilen özelliklerin önemini açıklamak, sınıflandırmak ve boyutu azaltmak için bu hiperdüzlem uygulanabilir [152].

Bu çalışmada diskriminant türü, doğrusal olarak seçilmiştir. Bilindiği gibi diskriminant türü doğrusal olduğunda her sınıf aynı kovaryans matrisine sahiptir.

2.5.5. Naive Bayes (NB)

Naive Bayes (NB) algoritması, çeşitli özelliklerin üstesinden gelmede çok esnekler. Bir x_i özelliğinin dağılımına göre, koşullu dağılım $p(x_i|y)$ seçilebilir [143]. Yani bir özellik ikili, multinominal ve sürekli iken, Bernoulli, multinominal ve Gauss dağılımları sırasıyla seçilebilir. Algoritmada özellik sayısı parametre sayısı ile tamamen doğrusaldır [143]. Algoritmanın öğrenmesi ve çıkarımı, çeşitli özelliklerin sayısında da doğrusal olan bazı kapalı form çözümleriyle gerçekleştirilebilir [143]. Sonuç olarak, bu algoritma çok sayıda farklı özellik içeren ana sorunlara karşı oldukça kolay ölçeklenebilmektedir [143].

Bu çalışmada, veri setlerinin çok terimli sınıflara sahip olması nedeniyle multinominal dağılım seçilmiş ve doğrusal bir çekirdek fonksiyonu kullanılmıştır.

2.5.6. Destek Vektör Makineleri (SVM)

Destek Vektör Makineleri (Support Vector Machines, SVM), veri kümelerini sınıflandırma veya regresyon için çekirdek tabanlı bir yöntemle etkili bir şekilde ayırabilen bir makine öğrenme algoritmasıdır [153]. Cortes ve Vapnik [154] tarafından iki sınıflı veriler için geliştirilmiştir. Ardından algoritma, çok sınıflı ve doğrusal olmayan veri kümeleri için geliştirilmiş ve genelleştirilmiştir. Genel olarak, veri kümesi yüksek boyutlu özellik uzayında bir çekirdek işlevi ile ayrılabilir [37]. Ayrıca SVM, karışık veri kümelerini ayrıştırmanın ve aşırı öğrenmenin üstesinden gelebilmektedir. En yaygın gösterilen SVM fonksiyonu $f(x) = w^T \phi(x) + b$ biçimindedir. Burada, $w \in R^n$, $b \in R$ ve $\phi(x)$ bir özellik haritasıdır.

2.5.7. Adaboost

Adaptif Yükseltme (Adaptive Boosting) algoritması, sınıflandırma için tasarlanmıştır. Torbalama, topluluk öğrenme algoritmaları gibi herhangi bir sınıflandırma yönteminde

uygulanabilmektedir. Bu algoritma, eğitim verilerindeki tüm örneklere eşit ağırlık atayarak başlar. Ardından, sınıflandırıcının çıktısına dayalı olarak veriler ve her örnek için bir sınıflandırıcı oluşturmak üzere öğrenme algoritmasını çağırır. Doğru sınıflandırılan örneklerin ağırlığı azaltılır ve yanlış sınıflandırılanların ağırlığı artar. Bu durum, düşük ağırlıklı bir “kolay” örneklem grubu ve yüksek ağırlıklı bir “sert” örneklem grubu oluşturur. Sonraki aşamada ve sonraki aşamaların tamamında, yeniden ağırlıklandırılmış veriler için bir sınıflandırıcı ayarlanır ve bu, son olarak sert örneklem grubunda yer alan örnekleri doğru bir şekilde sınıflandırmaya uyarlanır. Ardından, bu yeni sınıflandırıcının çıktısı dikkate alınarak örneklerin ağırlıkları değiştirilir. Sonuç olarak, pratikte birçok olasılık gerçekleşebilir. Örneğin, bazı zor örnekler daha kolay ve daha kolay olanlar daha zor olabilir. Tüm bunlardan sonra ağırlıklar, örneklerin şimdiye kadar üretilen sınıflandırıcılar tarafından ne sıklıkla yanlış sınıflandırıldığını gösterir. Bu uygulama, her örnekteki bir “sertlik” ölçümünü sürdürürken tamamlayıcı bir uzmanlar grubu oluşturmak için zarif bir yol sağlar [147, 155]. Bu çalışmada, bölme kriteri olarak Gini'nin çeşitlilik indeksi ve bölmelerdeki maksimum kategori 10 olarak seçilmiştir. Ayrıca, tahmin edicilerin seçiminde standart CART kullanılmıştır.

2.5.8. Torbalama

Torbalama (Bagging), farklı modellerin kararlarının birleştirilmesi, çeşitli çıktılarının tek bir tahminde bütünleştirilmesi anlamına gelir. Bunu sınıflandırma statüsünde gerçekleştirmenin en basit yolu oy kullanmaktır. Torbalama ve yükseltme, bu prosedürü kullansa da uygulamaları farklılık göstermektedir. Torbalamada örnekler eşit ağırlığa sahipken, yükseltmede örneklerin başarı durumuna göre belirlenen etkin ağırlıklar kullanılır. Ağaçlar, yeni keşfedilen eğitim setleri için kurulur ve onların tahminleri de oylamaya katılır [147]. Genellikle, topluluk sınıflandırıcısının elde ettiği sonuç, bir karar ağacı sonucundan daha doğru olacaktır [147]. Torbalamada, öğrenme yöntemlerinin kararsızlığını devre dışı bırakmak için her seferinde yeni, bağımsız bir eğitim veri kümesini örneklemek yerine bazı örnekleri çıkararak ve diğerlerini çoğaltarak gerçek eğitim verilerini değiştirir [147]. Burada, gerçek veri kümesiyle aynı boyutta yeni örnekler oluşturmak için bunlar değiştirilerek rastgele örneklenir. Üretilen farklı veri kümeleri, genellikle tek bir gerçek veri kümesine dayandıklarından bağımlıdır.

Torbalama diđer tek sınıflandırıcılar ile karşılaştırıldığında, performansının diđerlerinden daha iyi olduđu sıklıkla görölmektedir. Ayrıca torbalamanın birincil avantajı, model varyansını önemli ölçüde azaltmasıdır [156]. Karmaşık sınıflandırıcılar kullanıldığında, bu özellik ile aşırı uyum hafifletebilir [143]. Bu çalışmada öğrenici olarak bir karar ağacı seçilmiş ve öğrenme döngüsü sayısı, 50 olarak belirlenmiştir.

2.6. Veri Artırma

Veri setleri her zaman sınıflandırma algoritmalarının eğitimi için yeterli sayı ve bilgiye sahip olmayabilir. Bu durumun önüne geçebilmek için “Veri Artırma (data augmentation)” yöntemi genellikle tercih edilmektedir. Özellikle CNN mimarileri için girdi boyutu oldukça önemlidir. Veri artırma yöntemi ile boyutlar mimarilerin varsaydığı görüntü boyutuna rahatlıkla dönüştürülebilir. Bu yöntem kullanılarak ham verilerden çeşitli parametreler aracılığı ile yeni yapay görüntüler elde edilerek görüntü çeşitliliği artırılmaktadır. Böylece veri setlerinden elde edilen özellikler sayesinde sınıflandırma algoritmalarının performansı artmaktadır.

Bu çalışmada, ham ve işlenmiş COVID-19 CT tarama veri setlerine veri artırma yöntemi uygulanmıştır. II. veri setinde, ön işleme yöntemlerinden önce görüntüler yeniden boyutlandırılmış olsa da her mimarinin uygun girdi boyutu diđerinden farklı olduđu için veri artırma yöntemi ile boyut uyumsuzluğunun giderileceği düşünülmüştür. Böylece, CNN mimarileri eğitilirken aşırı öğrenmenin önüne geçilmiştir. Bu çalışmada kesme, yansıma ve döndürme veri artırma seçenekleri kullanılmıştır. Sürekli düzgün dağılımdan rastgele seçilen yatay kayma aralığı $[-0.05, 0.05]$ olarak uygulanmıştır. Aynı şekilde, sürekli düzgün dağılımdan rastgele seçilen düşey kesme aralığı $[-0.05, 0.05]$ olarak uygulanmıştır. Rastgele yansıma 1 olasılık olarak alınmıştır. Rastgele döndürme hem yatay hem de dikey aralıklarda $[-5, 5]$ olarak uygulanmıştır.

2.7. Çapraz Doğrulama

Çapraz Doğrulama (Cross Validation), veri setini ayırma yöntemlerinden biridir [157]. Son dönemlerde, makine öğrenmesi algoritmalarında sıklıkla tercih edilmektedir. Bu yöntemde farklı uygulamalar mevcut olsa da en çok kullanılanlar arasında k-katlı çapraz doğrulama (k-folds cross validation) yer almaktadır. k-katlı çapraz doğrulamada veri seti, rastgele olarak tanımlanmış (k) sayıda kata bölünür [153]. Herhangi bir alt kat, test katı olarak kabul edilir, kalan katlarla eğitim gerçekleştirilir. Bu işlem tüm katlar sırasıyla test katı olana kadar tekrarlanır [158]. Bu tekrarlar ile eğitilmiş modelin aşırı uyum problemi olup olmadığı ölçülebilir. Bu çalışmada, II. veri seti ve III. veri setini ayırmada k-katlı çapraz doğrulama kullanılmış ve k değeri 10 olarak belirlenmiştir.

2.8. Performans Ölçütleri

Sınıflandırma algoritmalarının performansını ölçmek için bazı ölçütler kullanılmaktadır. Bu ölçütler sayesinde hangi algoritmanın daha yüksek performans gösterdiği veya daha az hata yaptığı belirlenebilmektedir. Performans ölçütlerini hesaplamamanın temeli ise karışıklık matrisine (confusion matrix) dayanmaktadır [159]. Bu matrisin her satırı gerçek sınıflandırma değerlerini her sütunu ise tahmin sınıflandırma değerlerini göstermektedir. Çizelge 2.2, iki sınıflı veri setine ait karışıklık matrisi örneğini göstermektedir.

Çizelge 2.2. Karışıklık matrisi örneği [159].

Model		TAHMİN	
GERÇEK	Sınıf	Pozitif	Negatif
	Pozitif	<i>DP</i>	<i>YN</i>
	Negatif	<i>YP</i>	<i>DN</i>

Çizelge 2.2’de,

DP: Doğru Pozitif (True Positive), algoritmanın gerçekte pozitif sınıfı doğru sınıflandırma sayısını,

YP : Yanlış Pozitif (False Positive), algoritmanın gerçekte negatif sınıfı yanlış (pozitif) sınıflandırma sayısını,

DN : Doğru Negatif (True Negative), algoritmanın gerçekte negatif sınıfı doğru sınıflandırma sayısını,

YN : Yanlış Negatif (False Negative), algoritmanın gerçekte pozitif sınıfı yanlış (negatif) sınıflandırma sayısını göstermektedir. Karışıklık matrisinden yararlanarak, Eşitlik (2.11)-(2.16)'da ifade edildiği gibi doğruluk (Accuracy), duyarlılık (Sensitivity), özgüllük (Specificity), kesinlik (Precision), F1 skor ve geometrik ortalama (G-Mean, G-ort) gibi performans ölçütleri hesaplanabilir [14, 118]:

$$Doğruluk = \frac{DP + DN}{DP + DN + YP + YN} \quad (2.11)$$

$$Duyarlılık = \frac{DP}{DP + YN} \quad (2.12)$$

$$Özgüllük = \frac{DN}{DN + YP} \quad (2.13)$$

$$Kesinlik = \frac{DP}{DP + YP} \quad (2.14)$$

$$F1 = \frac{2 \times Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (2.15)$$

$$G - Ort = \sqrt{Duyarlılık \times Özgüllük} \quad (2.16)$$


Sınıflandırma performansını ölçmenin bir diğer yolu “Alıcı İşlem Karakteristiği (Receiver Operating Characteristic, ROC)” eğrisini görselleştirmektir [160]. ROC eğrisi altında kalan alan ise AUC (Area Under Curve) olarak ifade edilmiştir. Bu performans ölçütü sınıflandırmadaki pozitif ayırt etme gücünü göstermektedir. ROC eğrisinde yatay eksen yanlış pozitif oranını, dikey eksen ise doğru pozitif oranını göstermektedir. Her nokta için doğru pozitif ve yanlış pozitive karşılık gelen noktalar birleştirilerek ROC eğrisi çizilir [160, 161]. AUC’ nin 1’e çok yakın olması ise sınıflandırma performansının oldukça güçlü olduğunu ifade etmektedir.

3. DENEYSEL SONUÇLAR VE TARTIŞMA


Bu çalışmada, Intel Core i7-7500U CPU, NVIDIA GeForce GTX 950M, 16 GB RAM, 64-bit İşletim Sistemi ile MATLAB R2021b programından yararlanılmıştır. Çeşitli biyomedikal veri setleri kullanılarak önerilen OzNet mimarisinin sınıflandırma performansı araştırılmıştır. Sonuçlar kullanılan veri setleri üzerinden elde edilmiştir.

3.1. ECG Veri Seti Sınıflandırma Sonuçları

Bu çalışmada, farklı sinyal uzunlukları (360Hz, 500Hz ve 1000Hz) ile rastgele alınan tek boyutlu ECG sinyalleri, CWT ile iki boyutlu skalograma dönüştürülmüştür. Ayrıca her uygulama için skalograma dönüştürülmeden önce Amor, Bump ve Morse olmak üzere üç farklı ana dalgacık fonksiyonu kullanılmıştır. Ayrıca AlexNet, SqueezeNet ve OzNet mimarileri için skalogramların boyutu 227x227x3 ve .jpg formatına dönüştürülmüştür. ARR, CHF ve NSR' ye sahip sınıfların her biri için 300 örneklem oluşturulmuştur. Eğitim öncesi her bir sınıflandırma algoritması için toplamda 900 adet veri oluşturulmuştur. Ayrıca %80'i eğitim ve %20'si test için rastgele belirlenen bu veri seti, her mimari için ayrı ayrı uygulanmıştır. Ayrıca her eğitim aşaması için aynı periyotlar, aynı öğrenme oranı, aynı toplu iş büyüklüğü ve aynı optimizasyon yöntemi kullanılmıştır. AlexNet, SqueezeNet ve OzNet, 476 yineleme boyunca üç sınıfın tüm skalogramları için ayrı ayrı eğitildiğinde, sınıflandırma başarısı için genel doğruluk sonuçları Şekil 3.1 ve Şekil 3.2'de gösterilmektedir. Momentum parametresi için 0.95 oran ile stokastik gradyan inişi yöntemi seçilmiş ve başlangıç öğrenme oranı da sabit olacak şekilde 0.0001 olarak belirlenmiştir.




Şekil 3.1. CNN mimarilerinin için farklı sinyal uzunlukları ve ana dalgacık fonksiyonları için sınıflandırma performansları.



Şekil 3.2. OzNet mimarisinin, farklı sinyal uzunlukları ve ana dalgacık fonksiyonları için sınıflandırma performansları.

Karşılaştırmalar, OzNet mimarisinin doğruluk oranı ve diğer performans ölçütleri bakımından başarılı sonuçlar verdiğini göstermektedir. Çizelge 3.1, en yüksek doğrulukla gerçekleştirilen her bir karşılaştırmanın ayrıntılarını göstermektedir. OzNet mimarisi için tüm performans çıkarımları %96'nın üzerindedir. Özellikle NSR'nin özgüllük ve hassasiyetle ilgili performansları %100'dür. Ayrıca diğer çıkarımlara göre performansları %98'in üzerindedir. Sınıflandırma başarısı için Çizelge 3.1 incelendiğinde, OzNet'in F1-Skor değerinin daha üstün olduğu göze çarpmaktadır. Ayrıca, Şekil 3.3, sinyal uzunluğu 500 Hz ve dalgacık işlevi "Amor" iken önerilen CNN, OzNet için doğruluk oranı ve kayıp grafiğini göstermektedir.



Şekil 3.3. OzNet'in eğitim ilerlemesinin doğruluk oranı ve kayıp grafiği.

Çizelge 3.1. OzNet, AlexNet ve SqueezeNet mimarilerinin performans ölçütleri.

CNN mimarisi	Sınıf	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	Doğruluk
OzNet ^a	ARR	0.9796	0.9802	0.9600	0.9697	0.9800
	CHF	0.9800	0.9902	0.9800	0.9800	0.9800
	NSR	0.9804	1.0000	1.0000	0.9901	0.9800
OzNet ^b	ARR	0.9388	0.9604	0.9200	0.9293	0.9533
	CHF	0.9615	1.000	1.0000	0.9804	0.9533
	NSR	0.9592	0.9801	0.9400	0.9495	0.9533
AlexNet ^a	ARR	0.9231	0.9796	0.9600	0.9412	0.9467
	CHF	0.9787	0.9612	0.9200	0.9485	0.9467
	NSR	0.9412	0.9860	0.9600	0.9505	0.9467
SqueezeNet ^a	ARR	0.9434	1.000	1.0000	0.9709	0.9467
	CHF	0.9057	0.9794	0.9600	0.9320	0.9467
	NSR	1.0000	0.9605	0.8800	0.9362	0.9467

^aECG Sinyal uzunluğu 500Hz ,^bECG Sinyal Uzunluğu 1000Hz

Çizelge 3.1 incelendiğinde en iyi performansın OzNet ile elde edildiği görülmektedir. Mimarilerin performanslarının detayları sırasıyla aşağıda sunulmuştur.

Bu çalışmada AlexNet için en iyi sonucun, ana dalgacık fonksiyonları bakımından, “Amor” dalgacık fonksiyonu ile elde edildiği görülmüştür. Ancak sinyal uzunluğu 360 Hz olarak alınırsa, en iyi sonuç “Morse” dalgacık fonksiyonu ile elde edilmiştir. Sonuç olarak, AlexNet için hemen hemen aynı sonuçları veren “Amor” veya “Morse” ana dalgacık fonksiyonu olarak seçilebilir. Ancak, SqueezeNet için en iyi sonucun, belirlenen üç farklı sinyal uzunluğunda da “Bump” ana dalgacık fonksiyonu olduğu görülmüştür. OzNet için ise en iyi sonuç, %98 doğruluk oranıyla, “Amor” ana dalgacık fonksiyonu ile elde edilmiştir. Ayrıca, bu çalışmada, sinyal veya örnekleme uzunluğu açısından da sonuçlar verilmiştir. Sinyal uzunluğu 360 Hz olarak alınırsa sınıflandırma kalitesi düşmektedir. Özellikle tek boyutlu sinyallerden iki boyutlu skalogramlara dönüşüm için en uygun sinyal uzunluğunun 500 Hz olduğu söylenebilir. En iyi dalgacık fonksiyonu ve en iyi sinyal uzunluğu, çalışmanın şimdiye kadarki bölümünde en iyi

mimari ile birlikte belirlenmiştir. Bunun üzerine, Çizelge 3.2’ de ayrıntıları verilen OzNet mimarisi bir döngüde 5 kez eğitilmiştir.

Çizelge 3.2. ECG veri seti için 5 kez eğitilen OzNet’in performans ölçütleri.

Eğitim sayısı	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	Doğruluk
1	0.9486	0.9760	0.9467	0.9466	0.9467
2	0.9553	0.9772	0.9533	0.9533	0.9533
3	0.9605	0.9812	0.9600	0.9600	0.9600
4	0.9806	0.9903	0.9801	0.9799	0.9800
5	0.9868	0.9945	0.9867	0.9867	0.9867
Ortalama	0.9664 ±	0.9838 ±	0.9654 ±	0.9653 ±	0.9653 ±
+ Standart sapma	0.0165	0.0082	0.0172	0.0173	0.0173

Çizelge 3.2’de verilen tüm performans ölçütleri için ortalama değer ve standart sapma hesaplanmıştır. Tüm bu ortalama performans ölçütlerinin %96.53’ün üzerinde olduğu ve maksimum standart sapma değerinin 0.0173 olduğu görülmektedir. Bu nedenle, önerilen mimari geleneksel olarak eğitilmiş ve skalogramları sınıflandırmak için kaydedilmiştir. Daha sonra, MaxPool-7 katmanı ve Tam bağlantılı (FC-8) katmanlarından özellikler elde edilmiştir. Elde edilen özelliklerin %30’u eğitim ve %70’i test için ayrılmış ve sınıflandırma için SVM’ den yararlanılmıştır. Bu yeni hibrit algoritmaya OzNet-SVM adı verilmiştir. Eğitim ve test oranlarının bu şekilde belirlenme sebebi, algoritmanın performansının yüksek bir oran ile test edilmek istenmesidir. Çizelge 3.3’te OzNet-SVM’nin performans sonuçları gösterilmiştir.

Çizelge 3.3. OzNet-SVM algoritmasının performans sonuçları.

Katman İsmi	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	Doğruluk
MaxPool-7	0.9921	0.9966	0.9921	0.9921	0.9921
FC-8	0.9872	0.9950	0.9875	0.9873	0.9873

Çizelge 3.3 incelendiğinde, her iki katmandan elde edilen özelliklerin sınıflandırılması sonucunda tüm performans sonuçlarının arttığı görülmektedir. Ancak tüm performans ölçütleri bakımından en yüksek başarı oranı, MaxPool-7 katmanından elde edilen özelliklerin SVM ile sınıflandırılması ile elde edilmiştir.

Bu çalışmada sadece CNN mimarileri kullanılarak sınıflandırma yapılmamış, aynı zamanda görüntü sınıflandırma başarısı çok yüksek olan SVM ile de çalışılmıştır. Aynı ayrı yüksek başarıları olan bu iki yöntemin kombinasyonu çok iyi sonuç vermiştir. Çizelge 3.4, performans ölçütleri bakımından tüm yöntemlerin bir karşılaştırmasını göstermektedir. Ayrıca, Çizelge 3.5, tüm performans ölçütleri açısından en yüksek performansa sahip olan OzNet-SVM'nin karışıklık matrisini göstermektedir.

Çizelge 3.4. Tüm sınıflandırma algoritmalarının performans ölçütleri bakımından karşılaştırılması.

Algoritma	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	Doğruluk
OzNet	0.9664	0.9838	0.9654	0.9653	0.9653
SVM	0.8556	0.9368	0.8556	0.8551	0.8556
OzNet-SVM	0.9921	0.9966	0.9921	0.9921	0.9921

Çizelge 3.4'ten performans ölçütleri bakımından hem OzNet'in hem de OzNet-SVM'nin sonuçlarının SVM'den üstün olduğu görülmektedir. OzNet, sınıflandırıcı olarak kullanıldığında ortalama %96.53 doğruluk oranı elde etmiştir. Özellik çıkarıcı olarak kullanıldığında ve SVM ile birleştirildiğinde %99.21 doğruluk oranı elde etmektedir.

Aritmi (ARR), konjestif kalp yetmezliği (CHF) ve normal sinüs ritmi (NSR) veri setlerinin sınıflandırılması için birçok yaklaşım kullanılmaktadır. Esasen başarılı bir sınıflandırma, teşhis ve tedavi için oldukça önemlidir. Çizelge 3.1 incelendiğinde, her sınıf için başarının ne kadar yüksek olduğu görülmektedir. Ancak bu çalışmada toplu sınıflandırmanın önemi

düřünüldüğünden, genel (overall) dođruluk başarısına göre deđerlendirilmiş ve sonuçlar Çizelge 3.2-3.4'te detaylandırılmıştır.

Çizelge 3.5. OzNet-SVM algoritmasının karışıklık matrisi.

OzNet-SVM		TAHMİN		
GERÇEK	Sınıf	ARR	CHF	NSR
	ARR	206	3	1
	CHF	0	209	1
	NSR	0	0	210

OzNet-SVM'nin karışıklık matrisi Çizelge 3.5'te sunulmuştur. Her bir sınıfa ait görüntü sayısının 300 olduğu ifade edilmişti. Toplamda 900 görüntüden elde edilen özelliklerin (4096x görüntü sayısı) %30'u eğitim ve %70'i test için ayrılmıştır. Karışıklık matrisi incelendiğinde, oluşturulan hibrit algoritmanın başarılı sonuç verdiği görülmektedir. Algoritma, NSR sınıfını %100, CHF sınıfını %99.5 ve ARR sınıfını ise %98.1 dođru sınıflandırmıştır. Çizelge 3.6'da ECG sınıflandırılması ile ilgili yapılmış çalışmaların karşılaştırma sonuçları verilmiştir.

Çizelge 3.6. ECG çalışmalarının sınıflandırma performansları.

Çalışma	Ön İşleme Yöntemi	Algoritma	Dođruluk
Çınar ve Tuncer[162]	STFT	CNN (AlexNet-SVM)	0.9677
Eltras ve diđerleri [163]	CQ-NSGT*	CNN(AlexNet)	0.9882
Gaddam ve diđerleri [164]	CWT	CNN(AlexNet)	0.9567
Golgowski ve Osowski [5]	CWT	CNN	0.8206
	DWT	Ekstra Rasgele Orman	0.9778
Krak ve diđerleri [9]	CWT	CNN	0.9600
Krishnakumar ve diđerleri [165]	CWT	CNN (GoogleNet)	0.9688
Kumari ve diđerleri [166]	DWT	SVM	0.9592


Nahak ve Saha [167]	RR	SVM	0.8677
	AR ile Dalgacık	SVM	0.9222
	Özelliklerin birleşimi	SVM	0.9333
Olanrewaju ve diğerleri [168]	CWT	CNN(AlexNet)	0.9870
Rahuja ve Valluru [169]	CWT	CNN(AlexNet)	0.9730
OzNet [3]	CWT	CNN	0.9653
OzNet-SVM [3]	CWT	CNN-SVM	0.9921

Çizelge 3.6 incelendiğinde, OzNet mimarisinin doğruluk oranı bakımından en yüksek performans elde ettiği görülmektedir. Çalışmanın bu bölümünde ECG verilerinin sınıflandırılmasında %99.21 doğruluk elde edilmiştir. Önerilen OzNet mimarisi bu alanda oldukça yüksek performans elde etmiştir. Çalışmanın devamında COVID-19 çalışması sunulmuştur.

3.2. COVID-19 CT Veri Seti Sınıflandırma Sonuçları

Bu çalışmada, COVID-19 CT veri setini sınıflandırmak için AlexNet, DenseNet201, GoogleNet, NASNetMobile, ResNet-50, SqueezeNet, VGG-16 ve OzNet mimarileri kullanılmıştır. Buradaki amaç, önerilen OzNet mimarisinin son dönemlerde yaygın olarak kullanılan güçlü mimari yapılar olduğu ispat edilmiş önceden eğitilmiş mimariler arasında yer alıp almadığını araştırmaktır. İlk olarak sınıflandırma aşamasından önce COVID-19 CT veri setinden üç farklı ön işleme yöntemini kullanarak dört farklı veri seti elde edilmiştir. Oluşturulan veri setleri üzerinden yukarıdaki popüler mimarilerin sınıflandırma performansları ölçülmüştür. Birinci veri seti, herhangi bir ön işleme yapılmadan ham formda kullanılmıştır. İkinci veri seti DWT (tek seviye) ile işlenmiş ve 227x227 .jpg formatına dönüştürülmüştür. Üçüncü veri seti yoğunluk ayarı ile işlenmiş ve yine 227x227 .jpg formatında dönüştürülmüştür. Dördüncü veri seti ise Maks-Min normalleştirmeyle normalize edilmiş ve 227x227 .jpg formatı ile griden renkli RGB'ye dönüştürülmüştür. Şekil 3.4, ham ve işlenmiş veri kümelerinin sırasıyla bir örneğini göstermektedir. Bir sonraki adımda, hazırlanan tüm COVID-19 CT veri setine 10 katlı çapraz doğrulama uygulanmıştır. Böylece çalışmanın güvenilirliği sağlanmıştır.

Ayrıca, önceden eğitilmiş mimariler ve OzNet, rastgele döndürme [-5,5], yansıma 1, kesme [-0.05,0.05] seçenekleri olan veri büyütme ile eğitilmiş ve veri setleri eğitilirken aşırı öğrenme engellemiştir. Sonuç olarak, kullanılan her mimari için Çizelge 3.7, Çizelge 3.8, Çizelge 3.9 ve Çizelge 3.10'da ayrıntılı olarak açıklanan sınıflandırma performans ölçüt sonuçları gösterilmiştir.



Şekil 3.4. (a) Ham CT tarama görüntüleri, (b) DWT-CT tarama görüntüleri, (c) Yoğunluk ayarlama yöntemi ile işlenmiş CT tarama görüntüleri (d) Griden renkli RGB'ye dönüştürülmüş CT tarama görüntüleri.

Çizelge 3.7. Ham COVID-19 CT tarama veri setini kullanan CNN mimarilerinin performans ölçütleri yönünden karşılaştırılması.

CNN Mimarileri	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort	Doğruluk	AUC
AlexNet	0.6476	0.8161	0.7559	0.6975	0.7270	0.7373	0.8054
DenseNet201	0.8969	0.8438	0.8347	0.8646	0.8699	0.8686	0.9489
GoogleNet	0.8020	0.8262	0.8023	0.8023	0.8142	0.8151	0.8902
NASNetMobile	0.7708	0.7935	0.7664	0.7686	0.7820	0.7828	0.8498
OzNet	0.7736	0.8010	0.7736	0.7736	0.7872	0.7882	0.8712
ResNet-50	0.9226	0.7985	0.8010	0.8575	0.8583	0.8565	0.9430
SqueezeNet	0.8367	0.8287	0.8111	0.8237	0.8327	0.8324	0.9063
VGG-16	0.8195	0.8791	0.8563	0.8375	0.8488	0.8512	0.9266

Ham COVID-19 CT tarama veri seti, AlexNet, DenseNet201, GoogleNet, NASNetMobile, ResNet-50, SqueezeNet, VGG-16 ve OzNet ile sınıflandırılmıştır. Çizelge 3.7 incelendiğinde, en iyi performansı %86.86 doğruluk oranı ile DenseNet201 mimarisi göstermiştir. Aynı zamanda bu mimari, %89.69 duyarlılığa, %84.38 özgüllüğe ve %86.46 F1 skoruna sahiptir. OzNet mimarisi performans ölçüt sonuçları AUC, doğruluk, duyarlılık, özgüllük, kesinlik ve F1 skoru için sırasıyla; %87.12,78.82, %77.36, %80.1, %77.36 ve %77.36'dır.

Çizelge 3.8. DWT- COVID-19 CT tarama veri setinde kullanan CNN mimarilerinin performans ölçütleri yönünden karşılaştırılması.

CNN Mimarileri	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort	Doğruluk	AUC
AlexNet	0.9857	0.9874	0.9857	0.9857	0.9865	0.9866	0.9996
DenseNet201	1.0000	0.9924	0.9915	0.9957	0.9962	0.9960	0.9999
GoogleNet	0.9971	0.9950	0.9943	0.9957	0.9961	0.9960	0.9999
NASNetMobile	0.9914	0.9824	0.9802	0.9857	0.9869	0.9866	0.9933
OzNet	0.9886	0.9950	0.9943	0.9913	0.9918	0.9950	0.9999
ResNet-50	1.0000	0.9949	0.9943	0.9971	0.9975	0.9973	0.9999
SqueezeNet	1.0000	0.9949	0.9943	0.9971	0.9975	0.9973	0.9999
VGG-16	1.0000	0.9949	0.9943	0.9971	0.9975	0.9973	0.9999

Çizelge 3.8 incelendiğinde, önceden eğitilmiş mimarilerin ve OzNet'in sınıflandırma performansının arttığı görülmüştür. Bu veri setinde, OzNet'in çok yüksek performans ölçütleri

vardır. AUC, doğruluk, duyarlılık, özgüllük, kesinlik ve F1 skoru sırasıyla; 0.999, %99.5, %98.86, %99.5, %99.4 ve %99.1'dir. Buradan yola çıkarak ön işlem yöntemi olan DWT'nin sınıflandırma başarısını artırdığı söylenebilir.

Çizelge 3.9. Yoğunluk ayarlama yöntemi- COVID-19 CT tarama veri setinde CNN mimarilerinin performans ölçütleri yönünden karşılaştırılması.

CNN Mimarileri	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort	Doğruluk	AUC
AlexNet	0.7679	0.7254	0.7109	0.7383	0.7464	0.7453	0.8272
DenseNet201	0.9255	0.7985	0.8015	0.8590	0.8597	0.8579	0.9408
GoogleNet	0.7478	0.8287	0.7933	0.7699	0.7873	0.7909	0.8668
NASNetMobile	0.7966	0.7481	0.7355	0.7648	0.7719	0.7708	0.8415
OzNet	0.7393	0.8061	0.7702	0.7544	0.7719	0.7748	0.8629
ResNet-50	0.9513	0.6801	0.7233	0.8218	0.8044	0.8069	0.9202
SqueezeNet	0.8166	0.7758	0.7620	0.7884	0.7959	0.7949	0.8774
VGG-16	0.8769	0.8010	0.7948	0.8338	0,8380	0.8365	0.9249

Çizelge 3.9 incelendiğinde, önceden eğitilmiş mimarilerin ve OzNet'in performansının ne iyi ne de kötü olduğu görülmüştür. Bu veri setinde, OzNet' in performans ölçütleri: AUC, doğruluk, duyarlılık, özgüllük, kesinlik ve F1 skoru sırasıyla; 0.8629, %77.48, %73.93, %80.6, %77.01 ve %75.44'tür. Ön işlem yöntemi olan yoğunluk ayarlama yönteminin (gama=2) sınıflandırma başarısını artırmadığı söylenebilir.

Çizelge 3.10. Griden renkli RGB'ye dönüştürme yöntemi- COVID-19 CT tarama veri setinde CNN mimarilerinin performans ölçütleri yönünden karşılaştırılması.

CNN Mimarileri	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort	Doğruluk	AUC
AlexNet	0.7794	0.7657	0.7452	0.7619	0.7725	0.7721	0.8457
DenseNet201	0.9226	0.7834	0.7892	0.8507	0.8502	0.8485	0.9393
GoogleNet	0.8023	0.8086	0.7865	0.7943	0.8054	0.8056	0.8888
NASNetMobile	0.7994	0.7557	0.7420	0.7697	0.7772	0.7761	0.8358
OzNet	0.7593	0.7935	0.7637	0.7615	0.7762	0.7775	0.8597
ResNet-50	0.9112	0.7607	0.7699	0.8347	0.8326	0.8311	0.9288
SqueezeNet	0.8395	0.7834	0.7731	0.8050	0.8109	0.8097	0.8974
VGG-16	0.8539	0.8111	0.7989	0.8255	0.8322	0.8311	0.9238

Çizelge 3.10 incelendiğinde önceden eğitilmiş mimarilerin ve OzNet'in performansının ne iyi ne de kötü olduğu görülmüştür. Bu veri setinde, OzNet' in performans ölçütleri: AUC, doğruluk, duyarlılık, özgüllük, kesinlik ve F1 skoru sırasıyla; 0.859, %77.74, %75.93, %79.34, %76.37 and %77.62'dir. Aslında, insan gözüyle ayırt etmeyi kolaylaştıran bu dönüşümün makineye de olumlu yansması bekleniyordu. Fakat bu yöntemle işlenen veriler ile ham veriler arasında sınıflandırma performansı bakımından önemli bir fark görülmemiştir. Griden renkli RGB yönteminin de sınıflandırma başarısını artırmadığı söylenebilir.

Tüm bu sonuçlara dayanarak, Griden renkli RGB'ye dönüştürme yönteminin ve yoğunluk ayarlama yönteminin CNN mimarilerin performansını yükseltmediği ifade edilebilir. Birçok araştırmacı CNN mimarileri için ön işlemenin gerekli olup olmadığını tartışmaktadır. Ancak DWT ile işlenmiş COVID-19 veri setinin kullanılması sonucu tüm mimarilerde yüksek sınıflandırma başarısı elde edilmiştir. Dolayısıyla bu çalışma, DWT ile verileri işlemenin çok etkili bir yöntem olduğunu göstermektedir. Ayrıca bu çalışmada, sınıflandırma başarısı çok yüksek olan ve diğer önceden eğitilmiş güçlü mimariler arasında yerini alan OzNet derin öğrenme mimarisinin performans sonuçları gösterilmiştir. OzNet'in sınıflandırma başarısı sadece performans ölçüm tablolarında gösterilmemiştir. Aynı zamanda Çizelge 3.11'de karışıklık matrisi de gösterilmiştir. Ayrıca, Şekil 3.5'te OzNet performans ölçütlerinin bir histogram grafiği, Şekil 3.6'da ise ROC eğrileri ve AUC değerleri gösterilmiştir.

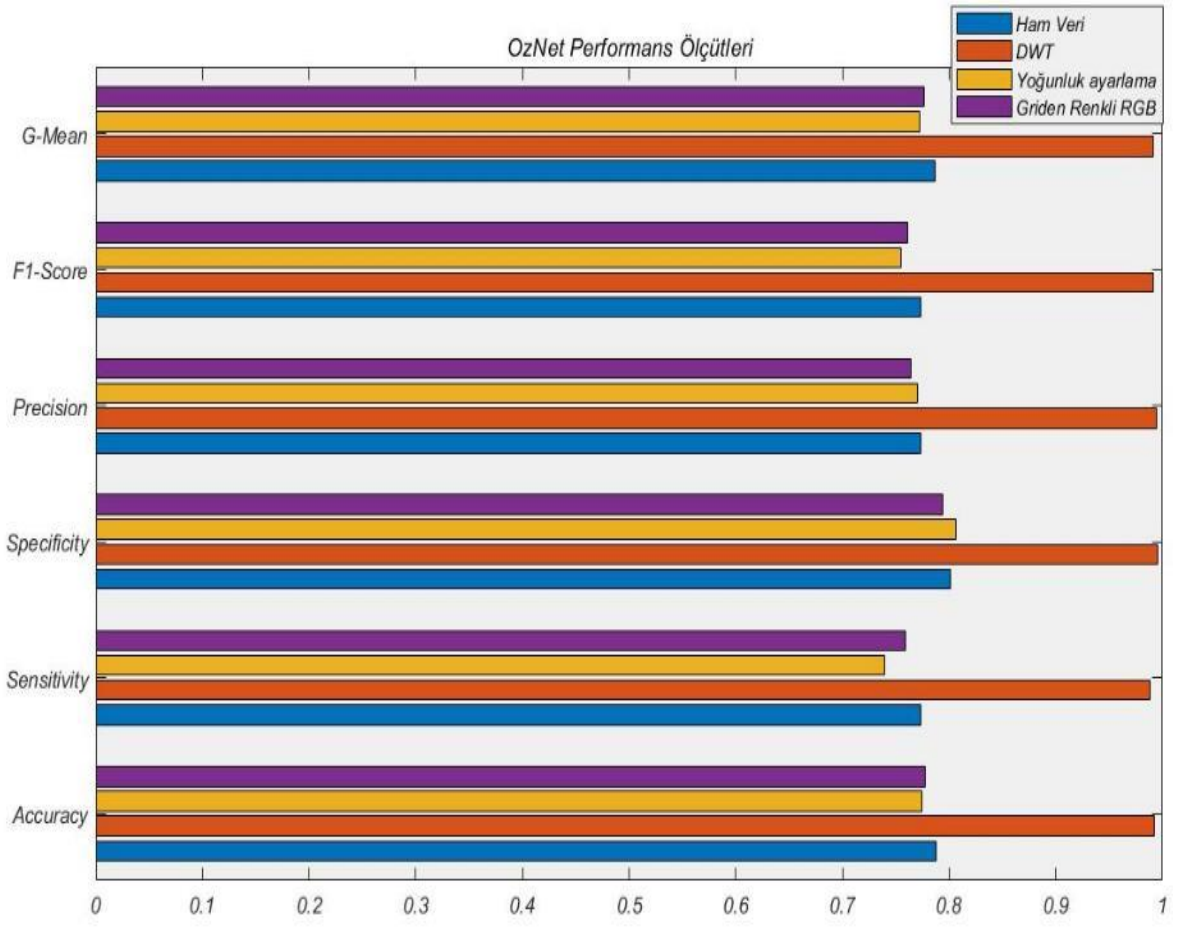
Çizelge 3.11. Ham ve ön işlenmiş COVID-19 CT tarama verilerinde OzNet'in karışıklık matrisi.

Ham veri-OzNet		TAHMİN	
GERÇEK	Sınıf	COVID	COVID Olmayan
	COVID	270	79
	COVID Olmayan	79	318

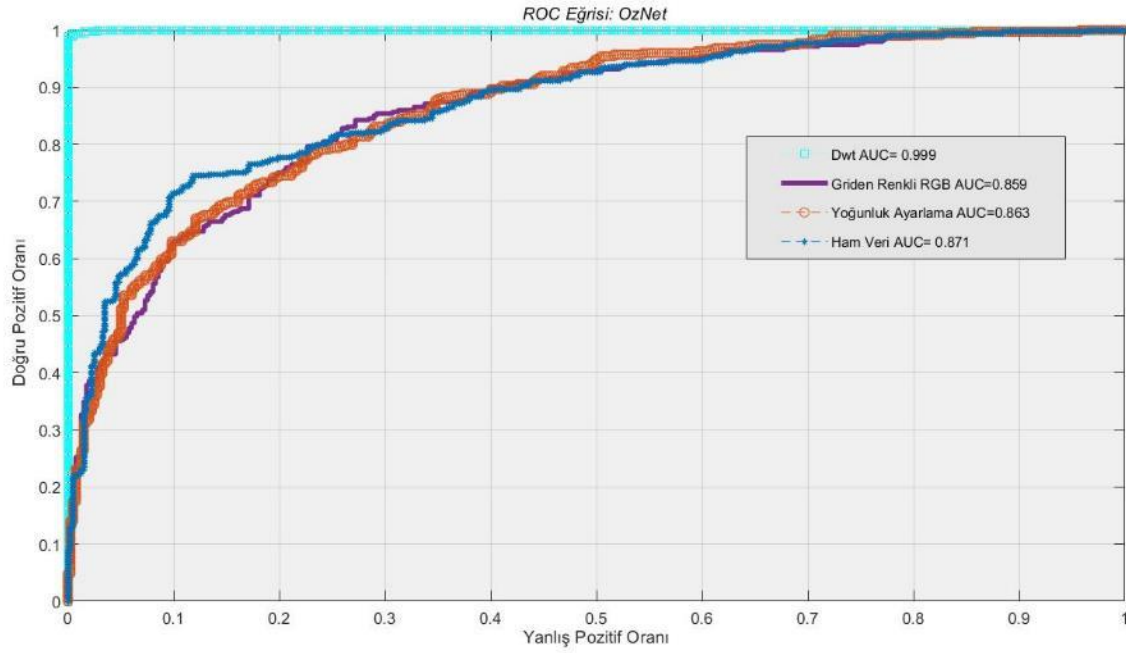
DWT-OzNet		TAHMİN	
GERÇEK	Sınıf	COVID	COVID Olmayan
	COVID	345	0
	COVID Olmayan	4	397

Yoğunluk Ayarlama -OzNet		TAHMİN	
GERÇEK	Sınıf	COVID	COVID Olmayan
	COVID	258	77
	COVID Olmayan	91	320

Griden Renkli RGB-OzNet		TAHMİN	
GERÇEK	Sınıf	COVID	COVID Olmayan
	COVID	265	82
	COVID Olmayan	84	315



Şekil 3.5. Ham ve ön işlenmiş COVID-19 CT tarama verilerinde OzNet'in performans ölçütleri histogram grafiği.



Şekil 3.6. Ham ve ön işlenmiş COVID-19 CT tarama verilerinde OzNet'in ROC eğrisi grafiği.

Görüntü işleme için DWT, görüntü sıkıştırma, görüntü küçültme, görüntü optimizasyonu ve görüntü filigranı için çok popüler bir yöntemdir [170]. Birçok araştırmacı, görüntü sıkıştırmanın görüntülerin kalitesini düşürdüğünü ve bu yöntemin görüntülerle ilgili bazı bilgileri kaybedebileceğini düşünmektedir. Ancak, DWT görüntülerin boyutunu küçültürken görüntülerin kalitesini kaybetmemektedir [171]. Bu nedenle sağlık verileri söz konusu olduğunda bu dönüşümü kullanmak oldukça etkili olmuştur. Bu çalışma, DWT'nin COVID-19 CT tarama veri setini sınıflandırmak için güçlü bir ön işleme yöntemi olduğunu göstermiştir. Çizelge 3.8'de, bu ön işleme yönteminin performans ölçütleri bakımından başarısı sunulmuştur. Ayrıca, yaygın olarak kullanılan ve güçlü sınıflandırma performansına sahip önceden eğitilmiş mimarilerle karşılaştırılan OzNet, bu mimariler arasında yer almayı başarmıştır. Açıkça DWT-OzNet algoritmasının performans ölçütleri bakımından çok iyi sonuçlar verdiği söylenebilir. Ayrıca önerilen DWT-OzNet algoritmasının daha önceki çalışmalarla karşılaştırılması Çizelge 3.12'de verilmiştir.


Çizelge 3.12. COVID-19 CT Tarama görüntülerinin önceki sınıflandırılma çalışmaları ile DWT-OzNet algoritmasının karşılaştırılması.

Çalışma	Sınıflandırma Yöntemi	Doğruluk
Goel ve diğerleri [172]	Derin Öğrenme Algoritması	0.9678
Irfan ve diğerleri [173]	Hibrit Derin Öğrenme Algoritması	0.9900
Acar ve diğerleri [174]	CNN mimarisi	0.9951
Polsinelli ve diğerleri [175]	CNN mimarisi	0.8503
Kundu ve diğerleri [176]	CNN mimarisi	0.9880
Pathak ve diğerleri [177]	CNN mimarisi	0.9302
Hasan ve diğerleri [178]	CNN mimarisi	0.9200
Ozyurt ve diğerleri [179]	Derin Öğrenme Algoritması	0.9584
	Yapay Sinir Ağları (ANN)	0.9410
Song ve diğerleri [180]	CNN mimarisi	0.8600
Loey ve diğerleri [181]	CNN mimarisi	0.8291
Bu çalışma	DWT-OzNet	0.9950

Çizelge 3.12 incelendiğinde, DWT-OzNet mimarisinin doğruluk oranı bakımından en yüksek performansa sahip olduğu görülmektedir. Çalışmanın bu bölümünde COVID-19 CT verilerinin sınıflandırılmasında %99.5 doğruluk elde edilmiştir. Çalışmanın devamında, beyin kanama türleri CT görüntüleri kullanarak OzNet aracılığı ile tespit edilmesine yönelik sonuçlar sunulmuştur.

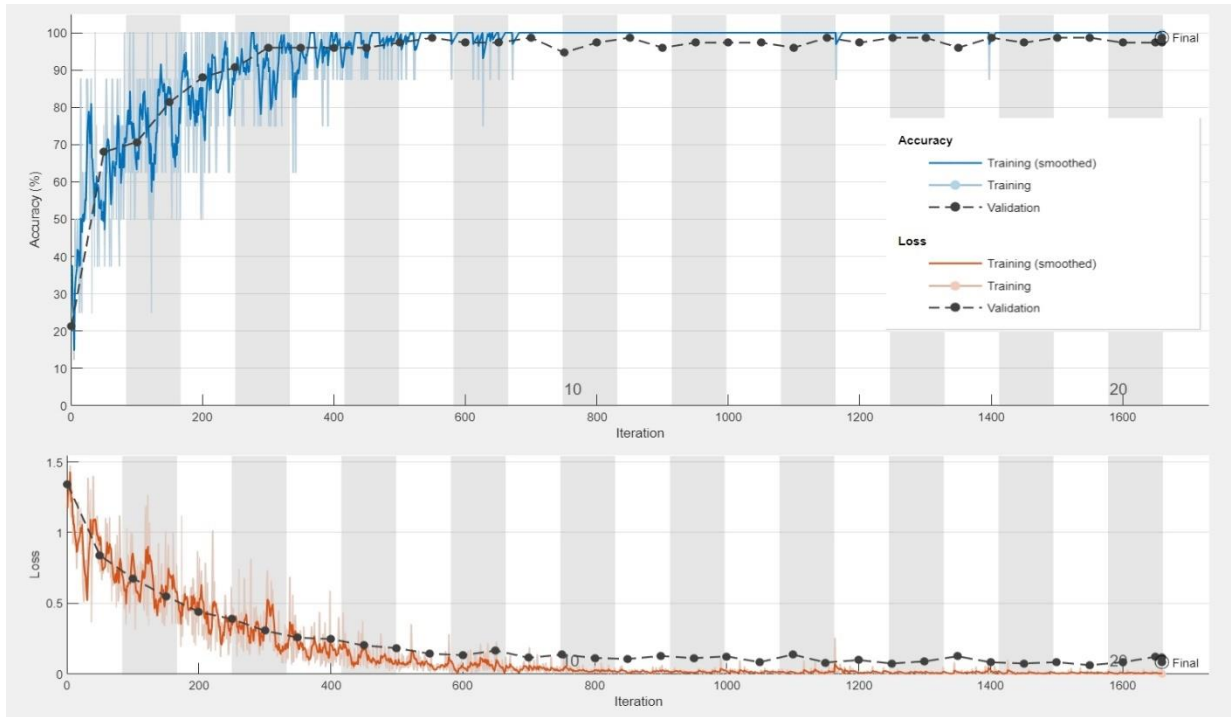
3.3. Beyin Kanaması CT Veri Setinde Sınıflandırma Sonuçları

Bu çalışmada, CT görüntülerinden farklı beyin kanaması türlerinin otomatik olarak belirlenmesi hedeflenmiştir. Kanama türlerinin belirlenmesi için Beyin CT görüntüleri sınıflandırıldığında, OzNet mimarisinden yararlanılmıştır. Oluşturulan üç farklı veri seti üzerinden sınıflandırma başarısı ölçülmüş ve önceden eğitilmiş mimariler (MobileNetv2 ve ShuffleNet) ile karşılaştırılmıştır. Elde edilen sonuçlar oldukça iyi olsa da daha iyi sınıflandırma performansı için OzNet, özellik çıkarıcı olarak kullanılmıştır. Burada OzNet'in tam bağlantılı katmanından indirgenmiş özellikler elde edilmiş ve belirlenen makine öğrenme algoritmaları ile sınıflandırma yapılmıştır. Sonuçları daha da iyileştirmek için NCA kullanılmıştır. NCA ile önemli özellikler belirlenmiş ve bu seçilen özellikleri sınıflandırmak için aynı sınıflandırma algoritmaları kullanılarak sonuçlar karşılaştırılmıştır. Sonuç olarak, beyin CT görüntülerinde kanama türlerini sınıflandırmak için çok yüksek doğrulukta mükemmel hibrit algoritmalar elde edilmiştir. Ayrıca sonuçlar, çok güvenilir bir yöntem olan 10 katlı çapraz doğrulama uygulanarak elde edilmiştir. Bu çalışmada oluşturulan veri seti 1 ve veri seti 2, 3 sınıflı, veri seti 3 ise 4 sınıflıdır. Şekil 3.7 beyin kanama türlerinin CT görüntülerini göstermektedir.



Şekil 3.7. Çalışmada kullanılan beyin kanaması türlerinin CT görüntüleri.

Bu çalışmada, materyal ve yöntemler bölümünde sunulan üç farklı oluşturulmuş beyin CT görüntülerinin kanama türleri bakımından sınıflandırılması için önerilen OzNet mimarisinden yararlanılmıştır. İlk olarak, görüntülerin boyutları 650x650'den 227x227'ye indirgenmiştir. Daha sonra, orijinal veri setinden çocuk, erişkin ve karma veri setleri elde edilmiştir. Bu çalışmada herhangi bir ön işlem yöntemi uygulanmamıştır. Buradaki amaç, OzNet performansını ham veriler üzerinden değerlendirmek olmuştur. Çizelge 3.13, her bir veri seti için OzNet'in performansını göstermektedir. Şekil 3.8, OzNet'in eğitim, doğrulama ve kayıp grafiğini göstermektedir.



Şekil 3.8. OzNet'in eğitim, doğrulama ve kayıp grafiği.

Veri seti 1, EDH, SDH+IPH ve N olmak üzere üç farklı sınıfa sahip çocuk ($18 > \text{yaş}$) beyin CT görüntülerinden oluşmaktadır. Veri seti 2, EDH, N ve IPH+SDH olmak üzere üç farklı sınıfa sahip erişkin ($18 \leq \text{yaş}$) beyin CT görüntülerinden oluşmaktadır. Veri seti 3 ise EDH, IPH, N ve SDH olmak üzere dört farklı sınıfa sahip tüm beyin CT görüntülerinden oluşmaktadır.

Çizelge 3.13. Üç farklı veri seti için OzNet' in performans ölçütleri.

	AUC	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort
Veri Seti 1	0.9935	0.9388	0.9391	0.9709	0.9382	0.9384	0.9549
Veri Seti 2	0.9923	0.9611	0.9556	0.9814	0.9608	0.9581	0.9684
Veri Seti 3	0.9838	0.9285	0.9195	0.9493	0.9317	0.9253	0.9343

Çizelge 3.13, veri seti 1 için incelendiğinde, genel doğruluk oranı %93.88 olarak elde edilmiştir. Ayrıca SDH+IPH, EDH ve N sınıfları için doğruluk oranları sırasıyla, %97.6, %92.3 ve %91.1 olarak elde edilmiştir. Burada OzNet, SDH+IPH sınıfını diğerlerinden daha iyi ayırt etmiştir.

Çizelge 3.13, veri seti 2 için incelendiğinde, genel doğruluk oranı %96.11 olarak elde edilmiştir. Ayrıca IPH +SDH, EDH ve N sınıfları için doğruluk oranları sırasıyla, %96.6, %94.4, ve %97.3 olarak elde edilmiştir. Burada OzNet, N sınıfını diğerlerinden daha iyi ayırt etmiştir. Genel olarak, veri seti 2'nin OzNet tarafından daha iyi sınıflandırıldığı, performans ölçütlerine göre söylenebilir.

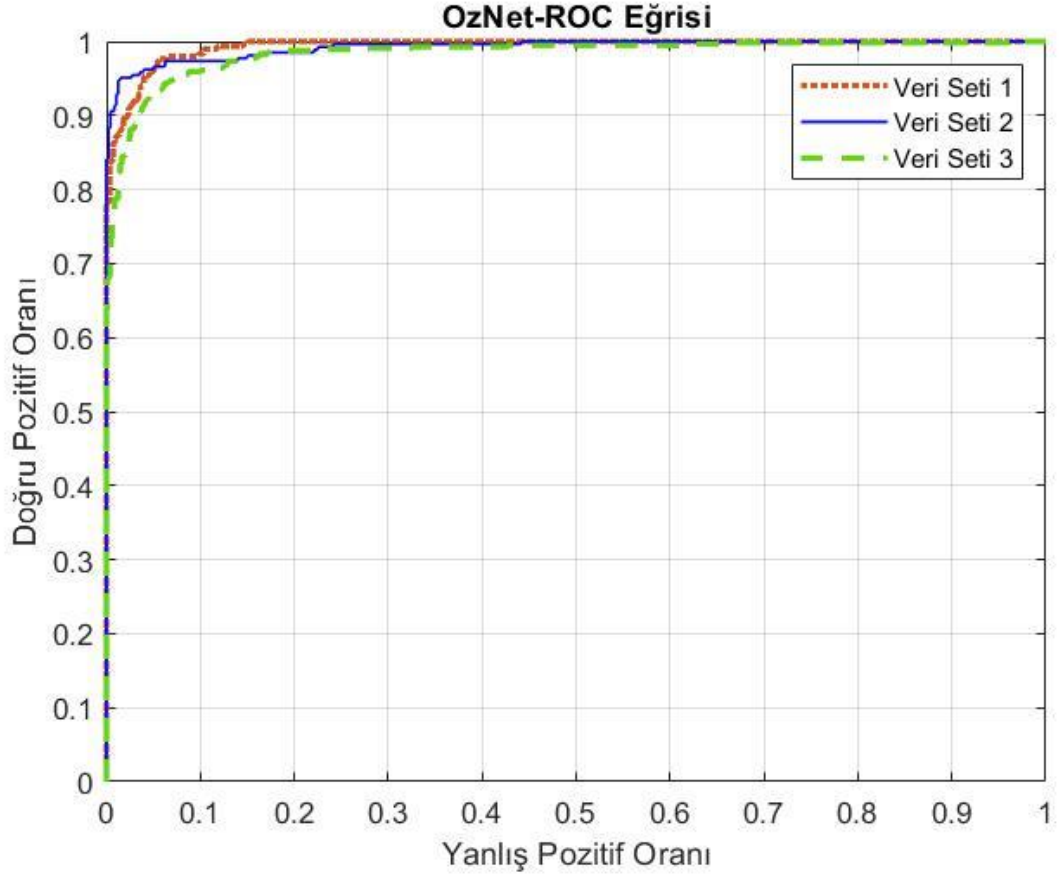
Çizelge 3.13, veri seti 3 için incelendiğinde, genel doğruluk oranı %92.85 olarak elde edilmiştir. Ayrıca SDH, IPH, EDH ve N sınıfları için doğruluk oranları sırasıyla, %93, %94.4, %91.2 ve %94 olarak elde edilmiştir. Burada OzNet, IPH sınıfını diğerlerinden daha iyi ayırt etmiştir. Burada, veri seti 3'ün dört farklı sınıfı olduğu, boyutunun diğer oluşturulan veri setlerinden daha yüksek olduğu ve sınıflar arasında dengeli bir dağılım olmadığı göz önünde bulundurulduğunda, OzNet'in performansının oldukça iyi olduğu söylenebilir. Çizelge 3.14, OzNet'in veri setleri üzerinden karışıklık matrislerini, Şekil 3.9 ise ROC eğrilerini göstermektedir.

Çizelge 3.14. OzNet'in üç farklı veri setleri için karışıklık matrisleri.

Veri Seti 1-OzNet		TAHMİN		
GERÇEK	Sınıf	EPH	N	SDH+IPH
	EPH	283	13	4
	N	11	236	3
	SDH+IPH	11	10	279

Veri Seti 2-OzNet		TAHMİN		
GERÇEK	Sınıf	EPH	IPH+SDH	N
	EPH	253	3	9
	IPH+SDH	10	140	0
	N	5	2	323

Veri Seti 3-OzNet		TAHMİN			
GERÇEK	Sınıf	EPH	IPH	N	SDH
	EPH	527	2	25	11
	IPH	8	136	2	4
	N	22	1	552	5
	SDH	21	5	8	266



Şekil 3.9. OzNet'in üç farklı veri setleri üzerinden ROC eğrileri.

Bu çalışmada OzNet, önceden eğitilmiş ResNet-18 [125], MobileNetv2 [123] ve ShuffleNet [126] mimarileri ile aynı seçenek parametreleri ile karşılaştırılmıştır. Ayrıca, OzNet mimarisinden farklı olarak daha düşük katman sayısına sahip iki farklı mimari oluşturulmuş ve performansları OzNet ile karşılaştırılmıştır. İlk olarak CNN-1 olarak adlandırılan 16 katmana (3 evrişimli katmana, 3 toplu normalleştirme katmanına, 3 ReLU, 3 maksimum havuzlama katmanına, 1 tam bağlantılı katmana ve 1 SoftMax katmana) sahip mimari oluşturulmuştur. İkinci olarak CNN-2 olarak adlandırılan 20 katmana (4 evrişimli katmana, 4 toplu normalleştirme katmanına, 4 ReLU, 4 maksimum havuzlama katmanına, 1 tam bağlantılı katmana ve 1 SoftMax katmana) sahip mimari oluşturulmuştur. Burada, CNN-1 ve CNN-2, her katman için filtre boyutu 3x3 olarak belirlenirken, filtre sayısı 64 ile başlayıp 256'ya ulaşana kadar ikişer kat artmıştır. Farklılık olarak CNN-2'de son katmandaki filtre sayısı 256 olarak

belirlenmiştir. Tüm bu parametreler deneme yanılma yoluyla belirlenmiştir. Çizelge 3.15- Çizelge 3.19 performans sonuçlarını göstermektedir.

Çizelge 3.15. Üç farklı veri seti için ResNet-18'in performans ölçütleri.

	AUC	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort
Veri Seti 1	0.9370	0.8400	0.8467	0.8364	0.7384	0.8467	0.8415
Veri Seti 2	0.9663	0.9034	0.8566	0.9292	0.8697	0.8631	0.8922
Veri Seti 3	0.9231	0.8088	0.7257	0.8544	0.7322	0.7289	0.7874

Çizelge 3.16. Üç farklı veri seti için MobileNetv2'nin performans ölçütleri.

	AUC	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort
Veri Seti 1	0.9148	0.8176	0.7700	0.8436	0.7287	0.7700	0.7488
Veri Seti 2	0.9460	0.8550	0.7925	0.8896	0.7985	0.7925	0.7955
Veri Seti 3	0.8936	0.7693	0.7027	0.8058	0.6650	0.7027	0.6833

Çizelge 3.17. Üç farklı veri seti için ShuffleNet'in performans ölçütleri.

	AUC	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort
Veri Seti 1	0.8255	0.7000	0.6700	0.7164	0.5630	0.6700	0.6119
Veri Seti 2	0.8816	0.7450	0.7434	0.7458	0.6176	0.7434	0.6747
Veri Seti 3	0.8166	0.6596	0.6885	0.6437	0.5146	0.6885	0.5889

Çizelge 3.18. Üç farklı veri seti için CNN-1'in performans ölçütleri.

	AUC	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort
Veri Seti 1	0.9314	0.7353	0.7444	0.8722	0.7796	0.7369	0.8058
Veri Seti 2	0.9515	0.8792	0.8423	0.9332	0.9050	0.8615	0.8866
Veri Seti 3	0.9805	0.8621	0.8397	0.9503	0.8565	0.8445	0.8933

Çizelge 3.19. Üç farklı veri seti için CNN-2'nin performans ölçütleri.

	AUC	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort
Veri Seti 1	0.9662	0.8176	0.8256	0.9116	0.8341	0.8122	0.8675
Veri Seti 2	0.9737	0.8725	0.8625	0.9295	0.8826	0.8676	0.8954
Veri Seti 3	0.9258	0.7147	0.6852	0.8968	0.7394	0.6855	0.7839

Çizelge 3.15'e göre, veri seti 1 için genel doğruluk oranı %84 olarak elde edilmiştir. Ayrıca, duyarlılık, özgüllük, kesinlik, F1 skoru ve Geometrik ortalama sonuçları sırasıyla, %84.67, %83.64, %73.84, %84.67 ve %84.15 olarak elde edilmiştir. Veri seti 1 için OzNet'in tüm performans sonuçları %93'ün üzerindeyken, ResNet-18 daha düşük performans göstermiştir. Çizelge 3.16'ya göre, veri seti 1 için genel doğruluk oranı %81.76 olarak elde edilmiştir. Benzer şekilde OzNet'in performansı MobileNet'ten üstün olarak elde edilmiştir. Çizelge 3.17'ye göre, veri seti 1 için genel doğruluk oranı %70 olarak elde edilmiştir. Burada da OzNet'in performansı ShuffleNet'ten üstün olarak elde edilmiştir. Çizelge 3.18 ve Çizelge 3.19'a göre, veri seti 1 için CNN-1 ve CNN-2'nin genel doğruluk oranları sırasıyla, %73.53 ve %81.76 olarak elde edilmiştir. Sonuç olarak, OzNet mimarisinin veri seti 1 için en iyi performansa sahip olduğu söylenebilir.

Çizelge 3.15'e göre, veri seti 2 için genel doğruluk oranı %90.34 olarak elde edilmiştir. Ayrıca, duyarlılık, özgüllük, kesinlik, F1 skoru ve Geometrik ortalama sonuçları sırasıyla, %85.66, %92.92, %86.97, %86.31 ve %89.22 olarak elde edilmiştir. Veri seti 2 için OzNet'in tüm performans sonuçlarının, ResNet-18'den daha iyi olduğu söylenebilir. Çizelge 3.16'ya göre, veri seti 2 için genel doğruluk oranı %85.5 olarak elde edilmiştir. Ayrıca, duyarlılık, özgüllük, kesinlik, F1 skoru ve Geometrik ortalama sonuçları sırasıyla, %79.25, %88.96, %79.85, %79.25 ve %79.55 olarak elde edilmiştir. Görüldüğü üzere OzNet'in performansının veri seti 2 için MobileNet2' den üstün olduğu söylenebilir. Çizelge 3.17'e göre, veri seti 2 için genel doğruluk oranı %74.5 olarak elde edilmiştir. Burada da OzNet'in performansı ShuffleNet'ten üstün olarak elde edilmiştir. Çizelge 3.18 ve Çizelge 3.19'a göre, veri seti 2 için CNN-1 ve CNN-2'nin genel doğruluk oranları sırasıyla, %87.92 ve %87.25 olarak elde edilmiştir. Sonuç olarak, OzNet mimarisinin veri seti 2 için de en iyi performansa sahip olduğu söylenebilir.

Çizelge 3.15'e göre, veri seti 3 için genel doğruluk oranı %80.88 olarak elde edilmiştir. Ayrıca, duyarlılık, özgüllük, kesinlik, F1 skoru ve Geometrik ortalama sonuçları sırasıyla, %72.57, %85.44, %73.22, %72.89 ve %78.74 olarak elde edilmiştir. Veri seti 3 için OzNet, %92.85 doğruluk oranı elde ederken ResNet-18, %80.88 doğruluk oranı elde etmiştir. Çizelge 3.16'ya göre aynı veri seti için MobileNetv2 %76.93 doğruluk oranı elde ederken, ShuffleNet %65.96 doğruluk oranı elde etmiştir. Çizelge 3.18 ve Çizelge 3.19'a göre, veri seti 3 için CNN-1 ve CNN-2'nin genel doğruluk oranları sırasıyla, %86.21 ve %71.47 olarak elde edilmiştir. Genel olarak, OzNet'in ilgili veri setlerini sınıflandırmada diğer CNN mimarilerinden çok daha başarılı olduğu söylenebilir.

Ham veriler üzerinden OzNet'in performansının oldukça iyi olduğu görülmüştür. Fakat söz konusu beyin kanaması olduğundan sınıflandırma sonuçlarının çok daha iyi olması gerekmektedir. Bu amaçla, OzNet materyal ve yöntem bölümünde bahsedilen bazı önemli makine öğrenme algoritmaları ile birleştirilerek hibrit algoritmalar elde edilmiştir. Bu birleşimde OzNet, görüntülerden özellik çıkarıcı olarak görevlendirilmiştir ve tam bağlantılı (FC-8) katmandan her bir görüntü için 4096 görüntü elde edilmiştir. Veri setlerinden elde edilen özelliklerin (4096x görüntü sayısı) %70'i eğitim %30'u test için bölünmüştür. Bu çalışmada, I. veri setinde bu oran tam tersi olarak verilmişti. Çünkü I. veri seti dengeli ve OzNet'in ilk derin özellik çıkarıcı olarak kullanıldığı veri seti olmuştur. Elde edilen sonucun (yüksek test oranına rağmen) başarılı (%99'un üzerinde doğruluk oranı) bulunmasıyla, OzNet'te aşırı öğrenmenin olmadığı düşünülerek ve III. veri setinin dengeli olmaması sebebiyle bu oran, %70 eğitim %30 test olarak belirlenmiştir. Daha sonra Adaboost, ANN, Torbalama, DT, KNN, LDA, Naive Bayes ve SVM algoritmaları ile sırasıyla sınıflandırma yapılmıştır.

Çizelge 3.20, performans ölçütleri bakımından incelendiğinde, oluşturulan tüm hibrit algoritmaların sonuçlarının oldukça iyi olduğu görülmüştür. OzNet-SVM algoritması veri seti 1 ve veri seti 3 için sırasıyla %98.83 ve %98.95 doğruluk oranı, %98.74 ve %98.32 duyarlılık oranı elde ederek en yüksek başarıya ulaşmıştır. Veri seti 2 için ise OzNet-Adaboost ve OzNet-ANN algoritmaları %98.66 ile aynı doğruluk oranını elde etmişlerdir. Sonuç olarak, veri seti 1 ve 3 için en iyi sınıflandırma algoritmasının OzNet-SVM olduğu, veri seti 2 için ise en iyi sınıflandırma algoritmasının OzNet-Adaboost ve OzNet-ANN olduğu söylenebilir. Burada veri seti 1 ve 3 performanslar yükselse de veri seti 2 için sonuç çok fazla değişmemiştir.

Çizelge 3.20. Üç farklı veri seti için hibrit algoritmaların performans ölçütleri.

Hibrit Algoritma	Veri Seti	AUC	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skor	G-Ort
Oznet-AdaBoost	Veri Seti 1	1	0.9686	0.9689	0.9842	0.9689	0.9689	0.9765
Oznet -ANN	Veri Seti 1	0.9996	0.9843	0.9852	0.9919	0.9853	0.9852	0.9886
Oznet -Torbalama	Veri Seti 1	0.9999	0.9843	0.9837	0.9921	0.9845	0.9841	0.9879
Oznet -DT	Veri Seti 1	0.9993	0.9686	0.9681	0.9843	0.9691	0.9681	0.9762
Oznet -KNN	Veri Seti 1	0.9591	0.9529	0.9533	0.9761	0.9552	0.9538	0.9646
Oznet -LDA	Veri Seti 1	1	0.9843	0.9829	0.9921	0.9845	0.9836	0.9875
Oznet -NBayer	Veri Seti 1	0.9944	0.9843	0.9837	0.9921	0.9845	0.9841	0.9879
Oznet-SVM	Veri Seti 1	0.9999	0.9883	0.9874	0.9941	0.9881	0.9877	0.9908
Oznet-AdaBoost	Veri Seti 2	0.9988	0.9866	0.9882	0.9936	0.9825	0.9851	0.9909
Oznet -ANN	Veri Seti 2	0.9996	0.9866	0.9850	0.9927	0.9883	0.9870	0.9888
Oznet - Torbalama	Veri Seti 2	0.9918	0.9641	0.9520	0.9807	0.9695	0.9593	0.9663
Oznet -DT	Veri Seti 2	0.9799	0.9552	0.9404	0.9761	0.9619	0.9491	0.9581
Oznet -KNN	Veri Seti 2	0.9712	0.9776	0.9797	0.9886	0.9748	0.9769	0.9842
Oznet -LDA	Veri Seti 2	0.9967	0.9641	0.9575	0.9812	0.9621	0.9598	0.9693
Oznet -NBayer	Veri Seti 2	0.9936	0.9866	0.9850	0.9927	0.9883	0.9867	0.9888
Oznet-SVM	Veri Seti 2	0.9993	0.9821	0.9767	0.9899	0.9850	0.9807	0.9834
Oznet-AdaBoost	Veri Seti 3	1	0.9875	0.9831	0.9954	0.9887	0.9857	0.9892
Oznet -ANN	Veri Seti 3	0.9998	0.9875	0.9804	0.9955	0.9886	0.9844	0.9879
Oznet - Torbalama	Veri Seti 3	0.9993	0.9833	0.9802	0.9938	0.9856	0.9829	0.9870


Oznet -DT	Veri Seti 3	0.9883	0.9603	0.9426	0.9848	0.9691	0.9546	0.9635
Oznet -KNN	Veri Seti 3	0.9631	0.9498	0.9311	0.9815	0.9491	0.9396	0.9559
Oznet -LDA	Veri Seti 3	0.9949	0.9623	0.9383	0.9868	0.9570	0.9463	0.9623
Oznet -NBayes	Veri Seti 3	0.9985	0.9749	0.9624	0.9907	0.9748	0.9678	0.9765
Oznet-SVM	Veri Seti 3	0.9999	0.9895	0.9832	0.9966	0.9832	0.9832	0.9899

Hibrit algoritmaların sınıflandırma performansını yükselttiği görülse de daha iyi sınıflandırma sonuçları için NCA kullanılarak yeni hibrit algoritmalar elde edilmiştir. Burada da benzer şekilde OzNet'ten 4096 özellik çıkarılmıştır. Daha sonra minimum bilgi kaybı olacak şekilde belirlenen tolerans değeri ve λ parametresi ile özellikler ağırlıklandırılır. NCA, eğitim verileri üzerindeki LOO ile amaç fonksiyonunu minimum yapan özelliklerin ağırlıklarını öğrenir. Son olarak, önemli özellikler minimum kayıp ile seçilir. Seçilen özellikler makine öğrenme algoritmaları ile sınıflandırılır. Çizelge 3.21 ve Şekil 3.10 her bir veri seti için belirlenen tolerans değerlerini göstermektedir. Bu çalışmada minimum kayıpla özelliklerin seçilmesi için $\lambda = 0.005$ alınmıştır. Ayrıca optimizasyon yöntemi olarak sgd (stochastic gradient descent, stokastik gradyan inişi) kullanılmış ve iterasyon sayısı 30 ile sınırlandırılmıştır.


Çizelge 3.21. Her bir deney için tolerans ve hata değerleri.

	Veri Seti 1	Veri Seti 2	Veri Seti 3
<i>Tolerans</i>	0.05	0.12	0.2
<i>Hata (MSE*)</i>	0.0039	0.0045	0.0042
λ	0.005	0.005	0.005
Çözüm yöntemi	Sgd	Sgd	Sgd
İterasyon sayısı	30	30	30
Gradyan toleransı	0.0001	0.0001	0.0001


MSE*: Hata Kareler Ortalaması (Mean Square Error)



(a)Veri Seti 1



(b)Veri Seti 2



(c) Veri Seti 3

Şekil 3.10. Tolerans değerine göre seçilen özellikler.

Bu kořullarda, 229 zellik veri seti 1'den, 112 zellik veri seti 2'den ve 45 zellik veri seti 3'ten seilmiřtir. Grldė zere 4096 zellik NCA ile indirgenmiřtir. Bu ařamadan sonra seilen bu zellikler tekrar makine ėrenme algoritmaları ile sınıflandırılmıřtır. izelge 3.22, NCA kullanılarak elde edilen OzNet hibrit algoritmalarının performans ltleri sonularını gstermektedir. Ayrıca, izelge 3.23, en iyi sınıflandırma sonularını veren yapıların karıřıklık matrisini gstermektedir.

izelge 3.22, veri seti 1 iin incelendiėinde, NCA kullanılarak %98.83 maksimum genel doėruluk oranını OzNet-ANN, OzNet-KNN ve OzNet-SVM algoritmaları tarafından elde edilmiřtir. Bu algoritmaların sınıfları ayırma bařarısı neredeyse %100'dr. rneėin OzNet-SVM algoritması, SDH+IPH, EDH ve N sınıfları iin sırasıyla %98.9, %100 ve %100 doėruluk oranları elde etmiřtir.

izelge 3.22, veri seti 2 iin incelendiėinde, NCA kullanılarak %100 maksimum genel doėruluk oranını OzNet-ANN algoritması tarafından elde edilmiřtir. Bu algoritmaların sınıfları ayırma bařarısı %100'dr.

izelge 3.22, veri seti 3 iin incelendiėinde, NCA kullanılarak %99.58 maksimum genel doėruluk oranını OzNet-ANN ve OzNet-Torbalama algoritmaları tarafından elde edilmiřtir. Bu veri seti iin NCA kullanılmadan elde edilen maksimum doėruluk oranı %98.95'dir.

Bu alıřmada NCA kullanılarak en iyi sınıflandırma bařarısı neredeyse tm veri setlerinde OzNet-ANN algoritması ile elde edilmiřtir. Bu kapsamda NCA'nın performansı, yaygın olarak kullanılan Ki-kare ve mRMR yntemleriyle karıřılařtırılmıřtır. Bu yntemler de parametrik olmayan yntemlerdir ve znitelikler her iki znitelik seim ynteminde de sıralanır [142, 182, 183]. izelge 3.24 ve izelge 3.25 sırasıyla Ki-kare ve mRMR yntemlerini kullanan OzNet-ANN algoritmasının performansını gstermektedir.

Çizelge 3.22. Üç farklı veri seti için NCA kullanılarak elde edilen hibrit algoritmaların performans ölçütleri.

Hibrit Algoritma	Veri Seti	AUC	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skoru	G-Ort
Oznet-AdaBoost	Veri Seti 1	1.000	0.9922	0.9926	0.9963	0.9913	0.9919	0.9944
Oznet -ANN	Veri Seti 1	0.9999	0.9961	0.9956	0.9979	0.9963	0.9959	0.9968
Oznet -Torbalama	Veri Seti 1	0.9999	0.9922	0.9911	0.9959	0.9927	0.9918	0.9935
Oznet -DT	Veri Seti 1	0.9996	0.9765	0.9755	0.9881	0.9774	0.9763	0.9817
Oznet -KNN	Veri Seti 1	0.9944	0.9961	0.9963	0.9981	0.9956	0.9959	0.9972
Oznet -LDA	Veri Seti 1	0.9999	0.9922	0.9918	0.9961	0.9919	0.9919	0.9940
Oznet -NBayes	Veri Seti 1	1.000	0.9882	0.9874	0.9939	0.9892	0.9882	0.9907
Oznet-SVM	Veri Seti 1	1.000	0.9961	1.000	0.9939	0.9890	0.9945	0.9972
Oznet-AdaBoost	Veri Seti 2	1.000	0.9955	0.9966	0.9977	0.9958	0.9962	0.9972
Oznet -ANN	Veri Seti 2	1.000	1.000	1.000	1.000	1.000	1.000	1.000
Oznet - Torbalama	Veri Seti 2	0.9998	0.9866	0.9890	0.9927	0.9883	0.9886	0.9909
Oznet -DT	Veri Seti 2	0.9829	0.9686	0.9635	0.9842	0.9684	0.9654	0.9738
Oznet -KNN	Veri Seti 2	0.9873	0.9910	0.9916	0.9954	0.9894	0.9904	0.9935
Oznet -LDA	Veri Seti 2	0.9996	0.9866	0.9882	0.9923	0.9890	0.9886	0.9903
Oznet -NBayes	Veri Seti 2	0.9999	0.9910	0.9924	0.9950	0.9924	0.9924	0.9937
Oznet-SVM	Veri Seti 2	1.000	0.9955	1.000	0.9931	0.9875	0.9937	0.9965
Oznet-AdaBoost	Veri Seti 3	0.9999	0.9937	0.9915	0.9979	0.9931	0.9922	0.9947
Oznet -ANN	Veri Seti 3	0.9999	0.9958	0.9944	0.9986	0.9931	0.9937	0.9965
Oznet - Torbalama	Veri Seti 3	0.9996	0.9958	0.9929	0.9987	0.9946	0.9937	0.9958

Oznet -DT	Veri Seti 3	0.9988	0.9644	0.9591	0.9875	0.9573	0.9575	0.9732
Oznet -KNN	Veri Seti 3	0.9892	0.9874	0.9832	0.9957	0.9844	0.9837	0.9894
Oznet -LDA	Veri Seti 3	0.9999	0.9895	0.9875	0.9964	0.9850	0.9859	0.9919
Oznet -NBayes	Veri Seti 3	0.9968	0.9875	0.9819	0.9952	0.9914	0.9864	0.9885
Oznet-SVM	Veri Seti 3	0.9999	0.9937	0.9943	0.9953	0.9879	0.9910	0.9949

*Koyu renkle ifade edilen ölçütler en yüksek performansı göstermektedir.

Çizelge 3.23. OzNet hibrit algoritmalarının NCA kullanılarak farklı veri setleri için karışıklık matrisleri.

Veri Seti 1 OzNet-NCA-SVM		TAHMİN		
GERÇEK	Sımf	EPH	N	SDH+IPH
	EPH	90	0	0
	N	0	74	1
	SDH+IPH	0	0	90

Veri Seti 2 OzNet-NCA-ANN		TAHMİN		
GERÇEK	Sımf	EPH	IPH+SDH	N
	EPH	79	0	0
	IPH+SDH	0	45	0
	N	0	0	99

Veri Seti 3 OzNet-NCA-ANN		TAHMİN			
GERÇEK	Sımf	EPH	IPH	N	SDH
	EPH	169	0	0	0
	IPH	0	45	0	0
	N	0	0	174	0
	SDH	1	1	0	88

Çizelge 3.24. Üç farklı veri seti için OzNet-Ki-kare-ANN algoritmasının performans ölçütleri.

	AUC	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skoru	G-Ort
Veri Seti 1	0.9998	0.9765	0.9748	0.9882	0.9762	0.9754	0.9815
Veri Seti 2	0.9996	0.9821	0.9816	0.9916	0.9772	0.9793	0.9866
Veri Seti 3	0.9997	0.9916	0.9902	0.9974	0.9850	0.9875	0.9938

Çizelge 3.25. Üç farklı veri seti için OzNet-mRMR-ANN algoritmasının performans ölçütleri.

	AUC	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skoru	G-Ort
Veri Seti 1	1	0.9921	0.9918	0.9961	0.9919	0.9918	0.9939
Veri Seti 2	0.9965	0.9910	0.9892	0.9954	0.9917	0.9922	0.9922
Veri Seti 3	0.9997	0.9916	0.9928	0.9971	0.9916	0.9922	0.9949

Çizelge 3.24'e göre, Ki-kare yöntemi kullanılarak OzNet-ANN algoritmasının veri seti 1, veri seti 2 ve veri seti 3 için genel doğruluk oranları sırasıyla %97.65, %98.21 ve %99.16'dır. NCA kullanılarak ise OzNet-ANN algoritmasının veri seti 1, veri seti 2 ve veri seti 3 için genel doğruluk oranları sırasıyla %99.61, %100 ve %99.58 olarak elde edilmişti. Burada Ki-kare yönteminin de başarılı sonuçlar verdiği görülse de NCA'nın daha üstün olduğu söylenebilir.

Çizelge 3.25'e göre, mRMR yöntemi kullanılarak OzNet-ANN algoritmasının veri seti 1, veri seti 2 ve veri seti 3 için genel doğruluk oranları sırasıyla %99.21, %99.10 ve %99.16'dır. Burada da mRMR yönteminin başarılı sonuçlar verdiği görülse de NCA'nın daha üstün olduğu söylenebilir.

Sonuç olarak, bu hibrit algoritmaların başarısı NCA kullanıldığında oldukça artmaktadır. Veri setlerinin yapısından daha önce de bahsedilmiştir. Burada veri setleri dengeli dağılıma sahip değildir ve her sınıf için görüntü sayısı çok fazla değildir. Tüm bu olumsuz koşullara rağmen oluşturulan OzNet-NCA-ANN algoritması beyin kanama türlerinin sınıflandırılması için mükemmel yakın performans göstermiştir. Çizelge 3.26 önceki çalışmalar ile karşılaştırma sonucunu göstermektedir.

Çizelge 3.26. Önceki çalışmalar ile performans karşılaştırması.

Çalışma	Özellik Çıkarıcı	Sınıflandırıcı	Doğruluk
Dawud ve diğerleri [184]	AlexNet	SVM	0.9348
Grewal ve diğerleri [185]	DenseNet	LSTM	0.8182
Phong ve diğerleri [186]	-	LeNet	0.9970
Singh ve diğerleri [87]	Sığ 3DCNN	3D CNN	0.9700
Bu çalışma [72]	OzNet-NCA	ANN	1.000

Çizelge 3.26 incelendiğinde, beyin kanama türlerinin tespiti için CT verilerinin sınıflandırılmasında %100 doğruluk elde eden önerilen algoritmanın diğerlerinden üstün olduğu görülmektedir.

3.4. Tartışma

Bu çalışmada, 34 katmanlı OzNet isimli yeni bir CNN mimarisi sunulmuştur. OzNet mimarisi oluşturulurken özellikle biyomedikal görüntülerinin en iyi şekilde sınıflandırılması hedeflenmiştir. Bilindiği üzere her veri yapısı aynı özelliklere sahip değildir. Bu durumun üstesinden gelmek için farklı işlemlerin yapılması gerekebilmektedir. Bu çalışmada sunulan sınıflandırma analizlerinde de olduğu gibi ön işlem yöntemleri oldukça başarılı sonuçlar verebilmektedir. Ön işlem yöntemlerinin yanı sıra derin öğrenme algoritmalarının özellik çıkarma özelliğinden yararlanmak da sınıflandırma performansını artırabilmektedir.

OzNet, literatürde iyi bilinen güçlü mimariler ile farklı veri setleri üzerinden aynı seçenek parametreleri kullanılarak karşılaştırılmıştır. Sonuç olarak, OzNet'in güçlü mimariler arasında yerini aldığı görülmüştür. Bu çalışmada kullanılan veri setleri dışında "2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)" isimli kongrede sunulan farklı bir ECG veri setinin sınıflandırılmasında da kullanılmıştır. OzNet sunulan bu çalışmada %95.6 [187] doğruluk oranı elde etmiştir. Ayrıca yaygın olarak kullanılan MNIST veri seti, CIFAR-10 veri seti üzerinden de OzNet değerlendirilmiştir [188]. Çizelge 3.27'de çeşitli verilerinin sınıflandırmasında kullanılan OzNet'in performans sonuçları verilmiştir.

Çizelge 3.27. Çeşitli biyomedikal verilerinin sınıflandırmasında OzNet mimarisinin performans sonuçları.

Mimari	Ön İşleme Yöntemi	Veri Türü	Sınıf Sayısı	Doğruluk
OzNet [3]	CWT	MIT-BIH Aritmi ECG Verisi	3	0.9653
OzNet-SVM [3]	CWT	MIT-BIH Aritmi ECG Verisi	3	0.9921
OzNet [187]	CWT	PTB ECG Verisi	2	0.9560
OzNet- SVM [187]	CWT	PTB ECG Verisi	2	0.9952

OzNet	DWT	COVID-19 CT Tarama Verisi	2	0.9950
OzNet [72]	-	Beyin Kanaması CT Veri Seti	3	0.9388
			3	0.9611
			4	0.9285
OzNet-NCA-ANN [72]	-	Beyin Kanaması CT Veri Seti	3	0.9961
			3	1.000
			4	0.9958
OzNet [189]	-	Inme (stroke) CT Veri Seti	2	0.8747
OzNet-mRMR-NB [189]	-	Inme (stroke) CT Veri Seti	2	0.9842
OzNet [188]	-	CIFAR-10	10	0.8540
OzNet [188]	-	MNIST	10	1.000

Çizelge 3.27 incelendiğinde önerilen OzNet mimarisinin iki ve çok sınıflı verilerde oldukça iyi performansa sahip olduğu görülmektedir. Sunulan çalışmaların en önemli özelliği hesaplama karmaşıklığının bulunmaması ve güvenilirlik düzeyinin çeşitli algoritmalarla artırılmış olmasıdır. Kullanılan her veri setinin yapısı, boyutu, özelliği farklıdır. Veri setine bağlı olarak sunulan çalışmalarda çeşitlilik olmuştur. Ayrıca, derin öğrenme algoritmalarından en iyi şekilde yararlanabilme durumları da sunulmuştur. Derin öğrenme algoritmalarının dezavantajlarından bahsedilse de (black box, kara kutu olması gibi) çağın en önemli yapay zekâ buluşlarından biridir. Güvenilirlik düzeyinin artırılması ile korkulan ihtimallerin giderilmesi sağlanabilir.

4. SONUÇ

Derin öğrenme teknolojisi son dönemde yapay zekanın en önemli parçası haline gelmiştir. Birçok alanda olduğu gibi sağlık sektöründe de kullanımı yaygınlaşmıştır. Yüksek ayırt etme gücü sayesinde otomatik sınıflandırma, özellik çıkarma ve tahmin işlemlerini kolaylıkla yapabilmektedir. Biyomedikal veriler genellikle karmaşık yapıya sahiptir. Son dönemde birçok araştırmacı derin öğrenme algoritmalarını özellikle biyomedikal verilerde test etmektedir. Bu çalışmada, biyomedikal verileri otomatik sınıflandırabilen yeni bir derin öğrenme mimarisi önerilmiştir. Önerilen bu mimari, esasen derin öğrenmenin özelleştirilmiş hali olan evrişimli sinir ağlarıdır ve OzNet olarak adlandırılmıştır.

OzNet; yedi evrişimli katman, yedi toplu normalleştirme katmanı, yedi aktivasyon katmanı (ReLU), yedi maksimum havuzlama katmanı, bir bırakma katmanı (drop out: 0.5) ile iki tam bağlantılı katman, bir SoftMax katmanı ve bir sınıflandırma katmanı kullanılarak tasarlanmıştır. Bu mimarinin parametre detayları Çizelge 2.1’de verilmiştir.

OzNet, çeşitli biyomedikal veriler üzerinde defalarca denenmiştir. Elde edilen sonuçlar oldukça ümit verici olmuştur. Bu çalışmada ilk olarak MIT-BIH ECG Aritmi veri setinden yararlanılmıştır. ECG verileri, OzNet, AlexNet ve SqueezeNet kullanılarak sınıflandırılmıştır. Bu çalışmada, sadece geleneksel bir sınıflandırma işlemi yapılmamıştır. Tek boyutlu ECG sinyalleri, CWT yardımıyla iki boyutlu skalogramlara dönüştürülmüştür. CWT’ de yer alan farklı ana dalgacık fonksiyonlarının sınıflandırma performansına etkisi araştırılmıştır. Aynı zamanda, farklı sinyal uzunluklarının da sınıflandırma performansına etkisi araştırılmıştır. Tüm sonuçlar, özellikle iki boyutlu skalogramlar için en iyi sinyal uzunluğunun 500Hz ve en iyi ana dalgacık fonksiyonunun “Amor” olduğunu göstermiştir. OzNet, AlexNet ve SqueezeNet’in doğruluk oranları açısından başarı durumları sırasıyla, %98, %94.67, ve %94.67’dir. OzNet için tüm performans ölçütleri %96’nın üzerindedir. Tüm sonuçlarla karşılaştırıldığında, OzNet mimarisi %98’lik doğruluk oranı ile çok yüksek performans göstermiştir. Genel olarak, OzNet mimarisinin önceden eğitilmiş AlexNet ve SqueezeNet mimarilerinden daha üstün performans gösterdiği görülmüştür. Ayrıca OzNet, bir döngüde 5 kez eğitilmiş ve performans detayları Çizelge 3.2’de verilmiştir. Tüm ortalama performans ölçütleri,

%96.53'ün üzerinde olarak görülmüş ve ayrıca maksimum standart sapması da 0.0173'tür. OzNet'in performansını iyileştirmek için maksimum havuzlama (MaxPool-7) ve tam bağlantılı (FC-8) katmanlarından özellikler elde edilmiş ve sırasıyla SVM ile sınıflandırılmıştır. Sonuç olarak, MaxPool-7 katmanından elde edilen özelliklerin sınıflandırılmasında OzNet-SVM algoritması sayesinde %99.2'lik doğruluk oranı ile en yüksek başarı elde edilmiştir.

Bu çalışmada ikinci olarak COVID-19 CT tarama veri setinden yararlanılmıştır. COVID-19 CT tarama veri setinden, ham ve üç farklı yöntemle (DWT, Yoğunluk ayarlama yöntemi, Griden Renkli RGB'ye Dönüştürme yöntemi) işlenmiş olmak üzere dört veri seti ele alınmıştır. Dört veri setinin sınıflandırılması için OzNet ile önceden eğitilmiş çok güçlü mimariler: AlexNet, DenseNet201, GoogleNet, NASNetMobile, ResNet-50, SqueezeNet ve VGG-16 karşılaştırılmıştır. Bu ham ve işlenmiş verilere 10 katlı çapraz doğrulama uygulanarak sağlam ve güvenilir sonuçlar elde edilmiştir. Birçok çalışmanın sonuçları incelendiğinde ölçütler arasında ciddi farklılıkların olduğu görülmektedir. Bunun nedeni veri setindeki dengesizlik ve yeterli özelliklerin bulunmamasıdır. Bu durumun önüne geçebilmek, aşırı öğrenmeyi önlemek için veri artırma yöntemi uygulanmıştır. Böylece, kullanılan her mimari için Çizelge 3.7-3.10'da ayrıntılı olarak verilen performans ölçütleri gösterilmiştir.

Bu çalışmada kullanılan ön işlem yöntemlerinden olan DWT ile işlenen COVID-19 CT taramalarının sınıflandırılmasında bu mimarilerin performansının önemli oranda arttığı görülmüştür. DWT ile işlenen veri setinin sınıflandırılmasında OzNet mimarisi ortalama %99.5 doğruluk oranı elde etmiştir. Diğer performans ölçütleri AUC, duyarlılık, özgüllük, kesinlik ve F1 skoru sırasıyla 0.999, %98.86, %99.5, %99.4 ve %99.1'dir.

Bu çalışmada kullanılan ön işlem yöntemlerinden bir diğeri ise Yoğunluk ayarlama yöntemidir. Bu yöntemde gama değeri 2 yani karanlık olarak alınmıştır. Gama değerinin 2 olarak almasının nedeni karşılaştırmanın daha spesifik olmasını sağlamaktır. Sonuç olarak, yoğunluk ayarı ile işlenen COVID-19 CT taramalarında bu mimarilerin performanslarının, ham veri seti sınıflandırma sonuçları ile karşılaştırıldığında, neredeyse değişmediği görülmüştür.

Bu çalışmada kullanılan ön işlem yöntemlerinden sonuncusu ise Griden Renkli RGB'ye dönüştürme yöntemidir. CT taramalarını gürültüden arındırmak için maks-min normalleştirme yöntemi kullanılmıştır. COVID-19 CT taramaları, mor renk kullanılarak griden renkli RGB verisine dönüştürülmüştür. Neden bu dönüşümün kullanıldığı ifade edilirse, teorik olarak renkli görüntüler gözle kolayca ayırt edilebilir ve makineler için de ayırt edilebilir olacağı varsayılmıştır. Ama sonuçlar beklendiği gibi olmamıştır. Renkli COVID-19 CT taramalarında bu mimarilerin performanslarının, ham veri seti sınıflandırma sonuçları ile karşılaştırıldığında, neredeyse değişmediği görülmüştür. Sonuç olarak, DWT en güçlü ön işlem yöntemlerinden biridir. DWT'nin gücü kullanıldığında sonuçların önemli ölçüde arttığı ifade edebilir. Ön işlem yöntemlerinden kaçınılmasına rağmen, özellikle CNN mimarileri için DWT'in uygulanmasının yararlı olduğu bu çalışma ile gösterilmiştir. Özetle, COVID-19 CT tarama görüntülerini sınıflandırmak için DWT-OzNet mimarisi önerilmektedir.

Deneysel sonuçlar, DWT-OzNet ile CT taramalarından, derin öğrenme teknikleri kullanılarak, COVID-19 hastalığının tespit edilebileceğini ortaya koymuştur. Önerilen algoritma DWT-OzNet, COVID-19 hastalığını hızlı ve doğru teşhis için etkin bir şekilde kullanılabilir ve uzmanların iş yükünü azaltabilir.

Bu çalışmada son olarak beyin kanaması CT veri setinden yararlanılmıştır. OzNet ile NCA, Adaboost, ANN, Torbalama, DT, KNN, LDA, NB, SVM gibi sınıflandırma algoritmaları birleştirilerek yeni hibrit algoritmalar geliştirilmiştir. Önerilen yeni hibrit algoritmalar, gerçek beyin kanaması veri setleri üzerinden mükemmel performanslar elde etmiştir. Öncelikle çocuk ve yetişkin beyin CT görüntülerinden veri seti 1 ve veri seti 2 isimli iki farklı veri seti oluşturulmuştur. Bu veri setleri 3 sınıfa sahiptir. Daha sonra veri seti 3 adlı bu iki veri kümesinden karma veri seti oluşturulmuştur. Bu üçüncü veri setinin ise 4 sınıfı vardır. OzNet mimarisi ile veri seti 1, veri seti 2 ve veri seti 3 sınıflandırılmış ve sırasıyla %93.88, %96.11 ve %92.85 doğruluk oranları elde edilmiştir. Sonuçlar çok iyi olsa da beyin gibi hayati öneme sahip bir organın kanama türlerinin en doğru bir şekilde sınıflandırılması bu çalışmanın temel amacıdır. Bu nedenle, NCA özellik seçim yöntemi kullanılmıştır. Burada OzNet, otomatik özellik çıkarıcı olarak kullanılmış ve özellikler tam bağlantılı katmandan (FC-8) elde edilmiştir. Ardından, NCA ile minimum kayıpla önemli özellikleri seçmek için tolerans değeri belirlenmiştir. Her veri seti için üç farklı tolerans değeri belirlenmiştir. Dolayısıyla bir sonraki aşama için özelliklerin boyutu

indirgenmiştir. Son olarak, güçlü makine öğrenme algoritmalarından yararlanılarak bu özellikler sınıflandırılmıştır. Ayrıca, Çizelge 3.20 ve Çizelge 3.22’de ayrıntıları verilen NCA’sız ve NCA’lı tüm sonuçlar karşılaştırılmıştır. Sonuç olarak, OzNet-NCA-SVM, veri seti 1 için %99.61, OzNet-NCA-ANN, veri seti 2 ve veri seti 3 için %100 ve %99.58 maksimum doğruluk elde eden algoritmalar olmuştur. Böylece, OzNet ile oluşturulan hibrit algoritmaların NCA kullanılarak daha iyi performans elde ettiği görülmüştür. Sonuç olarak, geliştirilen algoritmaların mükemmel bir performans gösterdiği söylenebilir.

Genel sonuçlara göre OzNet mimarisi biyomedikal görüntülerin sınıflandırılmasında oldukça iyi performans göstermiştir. Çizelge 3.27’de sunulan sonuçlar bu ifadeyi desteklemektedir. Gelecek çalışmalarda da farklı türdeki görüntülerin sınıflandırılmasında, tahmininde OzNet mimarisinin performansı ölçülmeye devam edilecektir. OzNet mimarisi geliştirilerek performansının daha da iyileştirilmesi sağlanacaktır.

5. KAYNAKLAR

- [1] M. Koklu, M. F. Unlarsen, I. A. Ozkan, M. F. Aslan, and K. Sabanci, "A CNN-SVM study based on selected deep features for grapevine leaves classification," *Measurement*, vol. 188, p. 110425, 2022.
- [2] M. Kaya and M. Eris, "D3SENet: A hybrid deep feature extraction network for Covid-19 classification using chest X-ray images," *Biomedical Signal Processing and Control*, p. 104559, 2023.
- [3] O. Ozaltin and O. Yeniay, "A novel proposed CNN-SVM architecture for ECG scalograms classification," *Soft Computing*, pp. 1-20, 2022. doi: <https://doi.org/10.1007/s00500-022-07729-x>.
- [4] H. Khorrami and M. Moavenian, "A comparative study of DWT, CWT and DCT transformations in ECG arrhythmias classification," *Expert systems with Applications*, vol. 37, no. 8, pp. 5751-5757, 2010.
- [5] M. Golgowski and S. Osowski, "Anomaly detection in ECG using wavelet transformation," in *2020 IEEE 21st International Conference on Computational Problems of Electrical Engineering (CPEE)*, 2020: IEEE, pp. 1-4.
- [6] M. M. Al Rahhal, Y. Bazi, M. Al Zuair, E. Othman, and B. BenJdira, "Convolutional neural networks for electrocardiogram classification," *Journal of Medical and Biological Engineering*, vol. 38, no. 6, pp. 1014-1025, 2018.
- [7] U. R. Acharya, H. Fujita, S. L. Oh, Y. Hagiwara, J. H. Tan, and M. Adam, "Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals," *Information Sciences*, vol. 415, pp. 190-198, 2017.
- [8] J. Huang, B. Chen, B. Yao, and W. He, "ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network," *IEEE Access*, vol. 7, pp. 92871-92880, 2019.
- [9] I. Krak, O. Stelia, A. Pashko, M. Efremov, and O. Khorozov, "Electrocardiogram Classification Using Wavelet Transformations," in *2020 IEEE 15th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*, 2020: IEEE, pp. 930-933.
- [10] U. B. Baloglu, M. Talo, O. Yildirim, R. San Tan, and U. R. Acharya, "Classification of myocardial infarction with multi-lead ECG signals and deep CNN," *Pattern Recognition Letters*, vol. 122, pp. 23-30, 2019.

- [11] T. Mahmud, S. A. Fattah, and M. Saquib, "Deeparnnet: An efficient deep cnn architecture for automatic arrhythmia detection and classification from denoised ecg beats," *IEEE Access*, vol. 8, pp. 104788-104800, 2020.
- [12] M. Salem, S. Taheri, and J. S. Yuan, "ECG arrhythmia classification using transfer learning from 2-dimensional deep CNN features," in *2018 IEEE Biomedical Circuits and Systems Conference (BioCAS)*, 2018: IEEE, pp. 1-4.
- [13] Y. Zhao, J. Cheng, P. Zhang, and X. Peng, "ECG classification using deep CNN improved by wavelet transform," *Computers, Materials and Continua*, 2020.
- [14] X. Xu and H. Liu, "ECG heartbeat classification using convolutional neural networks," *IEEE Access*, vol. 8, pp. 8614-8619, 2020.
- [15] A. Rajkumar, M. Ganesan, and R. Lavanya, "Arrhythmia classification on ECG using Deep Learning," in *2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS)*, 2019: IEEE, pp. 365-369.
- [16] S. Kiranyaz, T. Ince, and M. Gabbouj, "Real-time patient-specific ECG classification by 1-D convolutional neural networks," *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 3, pp. 664-675, 2015.
- [17] C. Chen, Z. Hua, R. Zhang, G. Liu, and W. Wen, "Automated arrhythmia classification based on a combination network of CNN and LSTM," *Biomedical Signal Processing and Control*, vol. 57, p. 101819, 2020.
- [18] K. Sandeep, P. Kora, K. Swaraja, K. Meenakshi, and L. Pampana, "ECG classification using machine learning," *Int J Recent Technol Eng (IJRTE)*, vol. 8, no. 4, pp. 2492-2494, 2019.
- [19] Y. Xing *et al.*, "Accurate ECG Classification Based on Spiking Neural Network and Attentional Mechanism for Real-Time Implementation on Personal Portable Devices," *Electronics*, vol. 11, no. 12, p. 1889, 2022.
- [20] C.-Y. Chen *et al.*, "Automated ECG classification based on 1D deep learning network," *Methods*, vol. 202, pp. 127-135, 2022.
- [21] K. Pałczyński, S. Śmigielski, D. Ledziński, and S. Bujnowski, "Study of the Few-Shot Learning for ECG Classification Based on the PTB-XL Dataset," *Sensors*, vol. 22, no. 3, p. 904, 2022.
- [22] X. Cheng *et al.*, "Efficient hardware design of a deep U-net model for pixel-level ECG classification in healthcare device," *Microelectronics Journal*, vol. 126, p. 105492, 2022.
- [23] Y. Jiao, H. Qi, and J. Wu, "Capsule network assisted electrocardiogram classification model for smart healthcare," *Biocybernetics and Biomedical Engineering*, vol. 42, no. 2, pp. 543-555, 2022.

- [24] M. Sepahvand and F. Abdali-Mohammadi, "A novel method for reducing arrhythmia classification from 12-lead ECG signals to single-lead ECG with minimal loss of accuracy through teacher-student knowledge distillation," *Information Sciences*, vol. 593, pp. 64-77, 2022.
- [25] A. S. Eltrass, M. B. Tayel, and A. I. Ammar, "Automated ECG multi-class classification system based on combining deep learning features with HRV and ECG measures," *Neural Computing and Applications*, vol. 34, no. 11, pp. 8755-8775, 2022.
- [26] A. Kumar, S. Kumar, V. Dutt, A. K. Dubey, and V. García-Díaz, "IoT-based ECG monitoring for arrhythmia classification using Coyote Grey Wolf optimization-based deep learning CNN classifier," *Biomedical Signal Processing and Control*, vol. 76, p. 103638, 2022.
- [27] L. Meng, W. Tan, J. Ma, R. Wang, X. Yin, and Y. Zhang, "Enhancing dynamic ECG heartbeat classification with lightweight transformer model," *Artificial Intelligence in Medicine*, vol. 124, p. 102236, 2022.
- [28] W. H. Organization. <https://covid19.who.int/> (accessed 30.04.2021 15:19).
- [29] S.-H. Wang, V. V. Govindaraj, J. M. Górriz, X. Zhang, and Y.-D. Zhang, "Covid-19 classification by FGCNet with deep feature fusion from graph convolutional network and convolutional neural network," *Information Fusion*, vol. 67, pp. 208-229, 2021.
- [30] M. F. Aslan, M. F. Unlarsen, K. Sabanci, and A. Durdu, "CNN-based transfer learning–BiLSTM network: A novel approach for COVID-19 infection detection," *Applied Soft Computing*, vol. 98, p. 106912, 2021.
- [31] S. R. Nayak, D. R. Nayak, U. Sinha, V. Arora, and R. B. Pachori, "Application of deep learning techniques for detection of COVID-19 cases using chest X-ray images: A comprehensive study," *Biomedical Signal Processing and Control*, vol. 64, p. 102365, 2021.
- [32] X. Yang, X. He, J. Zhao, Y. Zhang, S. Zhang, and P. Xie, "COVID-CT-dataset: a CT scan dataset about COVID-19," *arXiv preprint arXiv:2003.13865*, 2020.
- [33] R. Babukarthik, V. A. K. Adiga, G. Sambasivam, D. Chandramohan, and J. Amudhavel, "Prediction of covid-19 using genetic deep learning convolutional neural network (GDCNN)," *IEEE Access*, vol. 8, pp. 177647-177666, 2020.
- [34] D.-P. Fan *et al.*, "Inf-net: Automatic covid-19 lung infection segmentation from ct images," *IEEE Transactions on Medical Imaging*, vol. 39, no. 8, pp. 2626-2637, 2020.
- [35] D. Sharifrazi *et al.*, "Fusion of convolution neural network, support vector machine and Sobel filter for accurate detection of COVID-19 patients using X-ray images," *Biomedical Signal Processing and Control*, vol. 68, p. 102622, 2021.

- [36] A. Subasi, A. Mitra, F. Ozyurt, and T. Tuncer, "Automated COVID-19 detection from CT images using deep learning," in *Computer-Aided Design and Diagnosis Methods For Biomedical Applications*: CRC Press, 2021, pp. 153-176.
- [37] M. Barstugan, U. Ozkaya, and S. Ozturk, "Coronavirus (covid-19) classification using ct images by machine learning methods," *arXiv preprint arXiv:2003.09424*, 2020.
- [38] S. H. Khan, A. Sohail, A. Khan, and Y. S. Lee, "Classification and region analysis of COVID-19 infection using lung CT images and deep convolutional neural networks," *arXiv preprint arXiv:2009.08864*, 2020.
- [39] C. de Vente *et al.*, "Improving automated covid-19 grading with convolutional neural networks in computed tomography scans: An ablation study," *arXiv preprint arXiv:2009.09725*, 2020.
- [40] T. D. Pham, "A comprehensive study on classification of COVID-19 on computed tomography with pretrained convolutional neural networks," *Scientific reports*, vol. 10, no. 1, pp. 1-8, 2020.
- [41] O. A. Adebisi, J. A. Ojo, and O. M. Oni, "Comparative Analysis of Deep Learning Models for Detection of COVID-19 from chest X-Ray Images," *Int. J. Sci. Res. in Computer Science and Engineering Vol*, vol. 8, no. 5, 2020.
- [42] M. A. Gungor, "A comparative study on wavelet denoising for high noisy CT images of COVID-19 disease," *Optik*, vol. 235, p. 166652, 2021.
- [43] Y. S. Taspinar, I. Cinar, and M. Koklu, "Classification by a stacking model using CNN features for COVID-19 infection diagnosis," *Journal of X-Ray Science and Technology*, no. Preprint, pp. 1-16.
- [44] A. Subasi, S. A. Qureshi, T. Brahimi, and A. Serireti, "COVID-19 detection from X-ray images using artificial intelligence," in *Artificial Intelligence and Big Data Analytics for Smart Healthcare*: Elsevier, 2021, pp. 209-224.
- [45] G. Jia, H.-K. Lam, and Y. Xu, "Classification of COVID-19 chest X-Ray and CT images using a type of dynamic CNN modification method," *Computers in biology and medicine*, vol. 134, p. 104425, 2021.
- [46] S. Thakur and A. Kumar, "X-ray and CT-scan-based automated detection and classification of covid-19 using convolutional neural networks (CNN)," *Biomedical Signal Processing and Control*, vol. 69, p. 102920, 2021.
- [47] A. Narin, C. Kaya, and Z. Pamuk, "Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks," *Pattern Analysis and Applications*, pp. 1-14, 2021.
- [48] S. Ahuja, B. K. Panigrahi, N. Dey, V. Rajinikanth, and T. K. Gandhi, "Deep transfer learning-based automated detection of COVID-19 from lung CT scan slices," *Applied Intelligence*, vol. 51, no. 1, pp. 571-585, 2021.

- [49] T. Akram *et al.*, “A novel framework for rapid diagnosis of COVID-19 on computed tomography scans,” *Pattern analysis and applications*, pp. 1-14, 2021.
- [50] Y. Li, X. Pei, and Y. Guo, “A 3D CNN Classification Model for Accurate Diagnosis of Coronavirus Disease 2019 using Computed Tomography Images,” *medRxiv*, 2021.
- [51] T. Tuncer, F. Ozyurt, S. Dogan, and A. Subasi, “A novel Covid-19 and pneumonia classification method based on F-transform,” *Chemometrics and Intelligent Laboratory Systems*, vol. 210, p. 104256, 2021.
- [52] I. Ozsahin, B. Sekeroglu, M. S. Musa, M. T. Mustapha, and D. Uzun Ozsahin, “Review on diagnosis of COVID-19 from chest CT images using artificial intelligence,” *Computational and Mathematical Methods in Medicine*, vol. 2020, 2020.
- [53] M. Gour and S. Jain, “Uncertainty-aware convolutional neural network for COVID-19 X-ray images classification,” *Computers in biology and medicine*, vol. 140, p. 105047, 2022.
- [54] A. K. Dash and P. Mohapatra, “A Fine-tuned deep convolutional neural network for chest radiography image classification on COVID-19 cases,” *Multimedia Tools and Applications*, vol. 81, no. 1, pp. 1055-1075, 2022.
- [55] S. Chakraborty, S. Paul, and K. Hasan, “A transfer learning-based approach with deep cnn for covid-19-and pneumonia-affected chest x-ray image classification,” *SN Computer Science*, vol. 3, no. 1, pp. 1-10, 2022.
- [56] M. F. Aslan, K. Sabanci, A. Durdu, and M. F. Unlarsen, “COVID-19 diagnosis using state-of-the-art CNN architecture features and Bayesian Optimization,” *Computers in Biology and Medicine*, p. 105244, 2022.
- [57] W. Saad, W. A. Shalaby, M. Shokair, F. A. El-Samie, M. Dessouky, and E. Abdellatef, “COVID-19 classification using deep feature concatenation technique,” *Journal of Ambient Intelligence and Humanized Computing*, vol. 13, no. 4, pp. 2025-2043, 2022.
- [58] J. Amin, M. A. Anjum, M. Sharif, A. Rehman, T. Saba, and R. Zahra, “Microscopic segmentation and classification of COVID-19 infection with ensemble convolutional neural network,” *Microscopy research and technique*, vol. 85, no. 1, pp. 385-397, 2022.
- [59] J. Broderick *et al.*, “Guidelines for the Management of Spontaneous Intracerebral Hemorrhage in Adults: 2007 Update: A Guideline from the American Heart Association/American Stroke Association Stroke Council, High Blood Pressure Research Council, and the Quality of Care and Outcomes in Research Interdisciplinary Working Group: The American Academy of Neurology affirms the value of this guideline as an educational tool for neurologists,” *Stroke*, vol. 38, no. 6, pp. 2001-2023, 2007.

- [60] J. Elliott and M. Smith, "The acute management of intracerebral hemorrhage: a clinical review," *Anesthesia & Analgesia*, vol. 110, no. 5, pp. 1419-1427, 2010.
- [61] R. F. McCormack and A. Hutson, "Can computed tomography angiography of the brain replace lumbar puncture in the evaluation of acute-onset headache after a negative noncontrast cranial computed tomography scan?," *Academic Emergency Medicine*, vol. 17, no. 4, pp. 444-451, 2010.
- [62] P. Parizel, S. Makkat, E. Van Miert, J. Van Goethem, L. Van den Hauwe, and A. De Schepper, "Intracranial hemorrhage: principles of CT and MRI interpretation," *European radiology*, vol. 11, no. 9, pp. 1770-1783, 2001.
- [63] A. Gautam and B. Raman, "Towards effective classification of brain hemorrhagic and ischemic stroke using CNN," *Biomedical Signal Processing and Control*, vol. 63, p. 102178, 2021, doi: <https://doi.org/10.1016/j.bspc.2020.102178>.
- [64] W. Kuo, C. Häne, P. Mukherjee, J. Malik, and E. L. Yuh, "Expert-level detection of acute intracranial hemorrhage on head computed tomography using deep learning," *Proceedings of the National Academy of Sciences*, vol. 116, no. 45, pp. 22737-22745, 2019, doi: <https://doi.org/10.1073/pnas.1908021116>.
- [65] X. W. Gao, R. Hui, and Z. Tian, "Classification of CT brain images based on deep learning networks," *Computer methods and programs in biomedicine*, vol. 138, pp. 49-56, 2017, doi: <https://doi.org/10.1016/j.cmpb.2016.10.007>.
- [66] L. Li *et al.*, "Deep learning for hemorrhagic lesion detection and segmentation on brain ct images," *IEEE Journal of Biomedical and Health Informatics*, vol. 25, no. 5, pp. 1646-1659, 2020, doi: 10.1109/JBHI.2020.3028243.
- [67] M. Srikrishna *et al.*, "Deep learning from MRI-derived labels enables automatic brain tissue classification on human brain CT," *Neuroimage*, vol. 244, p. 118606, 2021, doi: <https://doi.org/10.1016/j.neuroimage.2021.118606>.
- [68] A. Shoeibi *et al.*, "Applications of epileptic seizures detection in neuroimaging modalities using deep learning techniques: methods, challenges, and future works," *arXiv preprint arXiv:2105.14278*, 2021.
- [69] A. Shoeibi *et al.*, "Detection of epileptic seizures on EEG signals using ANFIS classifier, autoencoders and fuzzy entropies," *Biomedical Signal Processing and Control*, vol. 73, p. 103417, 2022.
- [70] A. Shoeibi *et al.*, "Automatic Diagnosis of Schizophrenia in EEG Signals Using CNN-LSTM Models," *Frontiers in Neuroinformatics*, vol. 15, 2021.
- [71] D. Sharifrazi *et al.*, "CNN-KCL: Automatic myocarditis diagnosis using convolutional neural network combined with k-means clustering," 2020.(preprint)
- [72] O. Ozaltin, O. Coskun, O. Yeniay, and A. Subasi, "Classification of brain hemorrhage computed tomography images using OzNet hybrid algorithm," *International Journal of Imaging Systems and Technology*, 33(1), 69-91, 2023.

- [73] B. Shahangian and H. Pourghassem, "Automatic brain hemorrhage segmentation and classification algorithm based on weighted grayscale histogram feature in a hierarchical classification structure," *Biocybernetics and Biomedical Engineering*, vol. 36, no. 1, pp. 217-232, 2016, doi: <https://doi.org/10.1016/j.bbe.2015.12.001>.
- [74] A. Gautam, B. Raman, and S. Raghuvanshi, "A hybrid approach for the delineation of brain lesion from CT images," *Biocybernetics and Biomedical Engineering*, vol. 38, no. 3, pp. 504-518, 2018, doi: <https://doi.org/10.1016/j.bbe.2018.04.003>.
- [75] H. Bhadauria and M. Dewal, "Intracranial hemorrhage detection using spatial fuzzy c-mean and region-based active contour on brain CT imaging," *Signal, Image and Video Processing*, vol. 8, no. 2, pp. 357-364, 2014, doi: <https://doi.org/10.1007/s11760-012-0298-0>.
- [76] A. I. Maas, C. W. Hukkelhoven, L. F. Marshall, and E. W. Steyerberg, "Prediction of outcome in traumatic brain injury with computed tomographic characteristics: a comparison between the computed tomographic classification and combinations of computed tomographic predictors," *Neurosurgery*, vol. 57, no. 6, pp. 1173-1182, 2005, doi: <https://doi.org/10.1227/01.NEU.0000186013.63046.6B>.
- [77] B. Shahangian and H. Pourghassem, "Automatic brain hemorrhage segmentation and classification in CT scan images," in *2013 8th Iranian Conference on Machine Vision and Image Processing (MVIP)*, 2013: IEEE, pp. 467-471, doi: doi: 10.1109/IranianMVIP.2013.6780031.
- [78] J.-L. Solorio-Ramírez, M. Saldana-Perez, M. D. Lytras, M.-A. Moreno-Ibarra, and C. Yáñez-Márquez, "Brain Hemorrhage Classification in CT Scan Images Using Minimalist Machine Learning," *Diagnostics*, vol. 11, no. 8, p. 1449, 2021, doi: <https://doi.org/10.3390/diagnostics11081449>.
- [79] U. Balasooriya and M. S. Perera, "Intelligent brain hemorrhage diagnosis using artificial neural networks," in *2012 IEEE Business, Engineering & Industrial Applications Colloquium (BEIAC)*, 2012: IEEE, pp. 128-133, doi: doi: 10.1109/BEIAC.2012.6226036.
- [80] D. M. Alawad, A. Mishra, and M. T. Hoque, "AIBH: accurate identification of brain hemorrhage using genetic algorithm based feature selection and stacking," *Machine Learning and Knowledge Extraction*, vol. 2, no. 2, pp. 56-77, 2020, doi: <https://doi.org/10.3390/make2020005>.
- [81] R. F. Mansour and N. O. Aljehane, "An optimal segmentation with deep learning based inception network model for intracranial hemorrhage diagnosis," *Neural Computing and Applications*, vol. 33, no. 20, pp. 13831-13843, 2021, doi: <https://doi.org/10.1007/s00521-021-06020-8>.
- [82] M. Toğaçar, Z. Cömert, B. Ergen, and Ü. Budak, "Brain Hemorrhage Detection based on Heat Maps, Autoencoder and CNN Architecture," in *2019 1st*

International Informatics and Software Engineering Conference (UBMYK), 2019: IEEE, pp. 1-5, doi: 10.1109/UBMYK48245.2019.8965576.

- [83] C. Anupama, M. Sivaram, E. L. Lydia, D. Gupta, and K. Shankar, “Synergic deep learning model–based automated detection and classification of brain intracranial hemorrhage images in wearable networks,” *Personal and Ubiquitous Computing*, pp. 1-10, 2020, doi: <https://doi.org/10.1007/s00779-020-01492-2>.
- [84] M. Chawla, S. Sharma, J. Sivaswamy, and L. Kishore, “A method for automatic detection and classification of stroke from brain CT images,” in *2009 Annual international conference of the IEEE engineering in medicine and biology society*, 2009: IEEE, pp. 3581-3584, doi: 10.1109/IEMBS.2009.5335289.
- [85] A. Majumdar, L. Brattain, B. Telfer, C. Farris, and J. Scalera, “Detecting intracranial hemorrhage with deep learning,” in *2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC)*, 2018: IEEE, pp. 583-587, doi: doi: 10.1109/EMBC.2018.8512336.
- [86] A. Muhammad and W. Guojun, “Segmentation of calcification and brain hemorrhage with midline detection,” in *2017 IEEE International Symposium on Parallel and Distributed Processing with Applications and 2017 IEEE International Conference on Ubiquitous Computing and Communications (ISPA/IUCC)*, 2017: IEEE, pp. 1082-1090, doi: doi: 10.1109/ISPA/IUCC.2017.00164.
- [87] S. P. Singh, L. Wang, S. Gupta, B. Gulyas, and P. Padmanabhan, “Shallow 3D CNN for detecting acute brain hemorrhage from medical imaging sensors,” *IEEE Sensors Journal*, vol. 21, no. 13, pp. 14290-14299, 2020, doi: doi: 10.1109/JSEN.2020.3023471.
- [88] A. Rovlias, S. Theodoropoulos, and D. Papoutsakis, “Chronic subdural hematoma: surgical management and outcome in 986 cases: a classification and regression tree approach,” *Surgical neurology international*, vol. 6, 2015, doi: doi: 10.4103/2152-7806.161788.
- [89] S.-J. Yeh, S.-C. Tang, L.-K. Tsai, and J.-S. Jeng, “Pathogenetical subtypes of recurrent intracerebral hemorrhage: designations by SMASH-U classification system,” *Stroke*, vol. 45, no. 9, pp. 2636-2642, 2014, doi: <https://doi.org/10.1161/STROKEAHA.114.005598>.
- [90] K. Uyar, Ş. Taşdemir, E. Ülker, M. Öztürk, and H. Kasap, “Multi-Class brain normality and abnormality diagnosis using modified Faster R-CNN,” *International journal of medical informatics*, vol. 155, p. 104576, 2021.
- [91] Ö. F. Ertuğrul and M. F. Akıl, “Detecting hemorrhage types and bounding box of hemorrhage by deep learning,” *Biomedical Signal Processing and Control*, vol. 71, p. 103085, 2022.

- [92] V. Abramova *et al.*, “Hemorrhagic stroke lesion segmentation using a 3D U-Net with squeeze-and-excitation blocks,” *Computerized Medical Imaging and Graphics*, vol. 90, p. 101908, 2021.
- [93] S. Santhoshkumar, V. Varadarajan, S. Gavaskar, J. J. Amalraj, and A. Sumathi, “Machine learning model for intracranial hemorrhage diagnosis and classification,” *Electronics*, vol. 10, no. 21, p. 2574, 2021.
- [94] S. Barin, M. Saribaş, B. G. Çiltaş, G. E. Güraksin, and K. Utku, “Hybrid Convolutional Neural Network-Based Diagnosis System for Intracranial Hemorrhage,” *BRAIN. Broad Research in Artificial Intelligence and Neuroscience*, vol. 12, no. 4, pp. 01-27, 2021.
- [95] M. Burduja, R. T. Ionescu, and N. Verga, “Accurate and efficient intracranial hemorrhage detection and subtype classification in 3D CT scans with convolutional and long short-term memory neural networks,” *Sensors*, vol. 20, no. 19, p. 5611, 2020.
- [96] H. Salehinejad *et al.*, “A real-world demonstration of machine learning generalizability in the detection of intracranial hemorrhage on head computerized tomography,” *Scientific reports*, vol. 11, no. 1, pp. 1-11, 2021.
- [97] S. Jkooy. <https://github.com/UCSD-AI4H/COVID-CT> (accessed 03.03.2021 15:57).
- [98] M. Hssayeni. Computed Tomography Images for Intracranial Hemorrhage Detection and Segmentation (version 1.3.0). [Online] Available: <https://physionet.org/content/ct-ich/1.2.0/>
- [99] A. Goldberger, L. Amaral, L. Glass, J. Hausdorff, P. C. Ivanov, R. Mark, J. E. Mietus, G. B. Moody, C. K. Peng, and H. E. Stanley. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation* [Online].
- [100] M. D. Hssayeni, Croock, M. S., Al-Ani, A., Al-khafaji, H. F., Yahya, Z. A., & Ghoraani, B. , “Intracranial Hemorrhage Segmentation Using Deep Convolutional Model. ,” *arXiv preprint* vol. arXiv:1910.08643., 2019. [Online]. Available: <https://arxiv.org/abs/1910.08643>.
- [101] M. Hssayeni. <https://www.kaggle.com/vbookshelf/computed-tomography-ct-images> (accessed 19.11.2021, 18:55).
- [102] https://github.com/mathworks/physionet_ECG_data/ (accessed 22.12.2020 07:56).
- [103] “Physionet.” <https://www.physionet.org/> (accessed 01.06.2020 14:00).
- [104] G. B. Moody and R. G. Mark, “The impact of the MIT-BIH arrhythmia database,” *IEEE Engineering in Medicine and Biology Magazine*, vol. 20, no. 3, pp. 45-50, 2001.

- [105] A. L. Goldberger *et al.*, “PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals,” *circulation*, vol. 101, no. 23, pp. e215-e220, 2000.
- [106] D. S. Baim *et al.*, “Survival of patients with severe congestive heart failure treated with oral milrinone,” *Journal of the American College of Cardiology*, vol. 7, no. 3, pp. 661-670, 1986.
- [107] M. D. Hssayeni, M. S. Croock, A. D. Salman, H. F. Al-khafaji, Z. A. Yahya, and B. Ghoraani, “Intracranial hemorrhage segmentation using a deep convolutional model,” *Data*, vol. 5, no. 1, p. 14, 2020, doi: <https://doi.org/10.3390/data5010014>.
- [108] İ. V. Öner, M. K. Yeşilyurt, and E. Ç. Yılmaz, “Wavelet analiz tekniği ve uygulama alanları,” *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, vol. 7, no. 1, pp. 42-56, 2017.
- [109] D. L. Fugal, *Conceptual wavelets in digital signal processing: an in-depth, practical approach for the non-mathematician*. Space & Signals Technical Pub., 2009.
- [110] H. K. Lee and Y.-S. Choi, “Application of continuous wavelet transform and convolutional neural network in decoding motor imagery brain-computer interface,” *Entropy*, vol. 21, no. 12, p. 1199, 2019.
- [111] Z. Yılmaz and M. R. Bozkurt, “Ayrık Dalgacık Dönüşümü Kullanarak Aritmilere Ait Özniteliklerin Çıkarılması,” *XIV. Akademik Bilişim Konferansı*, pp. 23-25, 2013.
- [112] J. Amin, M. Sharif, N. Gul, M. Yasmin, and S. A. Shad, “Brain tumor classification based on DWT fusion of MRI sequences using convolutional neural network,” *Pattern Recognition Letters*, vol. 129, pp. 115-122, 2020.
- [113] R. D. Pai, S. Halvi, and B. Hiremath, “Medical color image enhancement using wavelet transform and contrast stretching technique,” *International Journal of Scientific and Research Publications*, vol. 5, no. 7, pp. 1-7, 2015.
- [114] P. Rajan and C. Sundar, “Brain tumor detection and segmentation by intensity adjustment,” *Journal of medical systems*, vol. 43, no. 8, pp. 1-13, 2019.
- [115] H. Lin, J. Gao, Q. Mei, G. Zhang, Y. He, and X. Chen, “Three-dimensional shape measurement technique for shiny surfaces by adaptive pixel-wise projection intensity adjustment,” *Optics and Lasers in Engineering*, vol. 91, pp. 206-215, 2017.
- [116] A.-W. S. Ibrahim and H. J. Sartep, “Grayscale image coloring by using YCbCr and HSV color spaces,” *compare*, vol. 4, no. 4, 2017.
- [117] H. Kekre, S. D. Thepade, A. Athawale, and A. Parkar, “Using assorted color spaces and pixel window sizes for colorization of grayscale images,” in

Proceedings of the International Conference and Workshop on Emerging Trends in Technology, 2010, pp. 481-486.

- [118] A. Narin, "Detection of Focal and Non-focal Epileptic Seizure Using Continuous Wavelet Transform-Based Scalogram Images and Pre-trained Deep Neural Networks," *IRBM*, 2020.
- [119] M. C. Bingol and O. Aydogmus, "İnsan-robot etkileşiminde insan güvenliği için çok kanallı iletişim kullanarak evrişimli sinir ağı tabanlı bir yazılımının geliştirilmesi ve uygulaması," *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 31, no. 2, pp. 489-495, 2019.
- [120] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, pp. 1097-1105, 2012.
- [121] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 4700-4708.
- [122] C. Szegedy *et al.*, "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9.
- [123] A. G. Howard *et al.*, "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2017.
- [124] B. Zoph, V. Vasudevan, J. Shlens, and Q. V. Le, "Learning transferable architectures for scalable image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 8697-8710.
- [125] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [126] X. Zhang, X. Zhou, M. Lin, and J. Sun, "Shufflenet: An extremely efficient convolutional neural network for mobile devices," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 6848-6856.
- [127] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size," *arXiv preprint arXiv:1602.07360*, 2016.
- [128] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [129] S. K. Addagarla, G. K. Chakravarthi, and P. Anitha, "Real time multi-scale facial mask detection and classification using deep transfer learning techniques," *International Journal*, vol. 9, no. 4, pp. 4402-4408, 2020.

- [130] Y. Chandola, J. Virmani, H. Bhadauria, and P. Kumar, J. V. Yashvi Chandola, H.S. Bhadauria, Papendra Kumar., Ed. *Chapter 4 -Deep Learning for Chest Radiographs: Computer-Aided Classification*. Elsevier, 2021.
- [131] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998.
- [132] Y. Ioannou, D. Robertson, J. Shotton, R. Cipolla, and A. Criminisi, "Training cnns with low-rank filters for efficient image classification," *arXiv preprint arXiv:1511.06744*, 2015.
- [133] Q. Shang, D. Tan, S. Gao, and L. Feng, "A hybrid method for traffic incident duration prediction using BOA-optimized random forest combined with neighborhood components analysis," *Journal of Advanced Transportation*, vol. 2019, 2019, doi: <https://doi.org/10.1155/2019/4202735>.
- [134] M. Jin and W. Deng, "Predication of different stages of Alzheimer's disease using neighborhood component analysis and ensemble decision tree," *Journal of neuroscience methods*, vol. 302, pp. 35-41, 2018, doi: <https://doi.org/10.1016/j.jneumeth.2018.02.014>.
- [135] S. Raghu and N. Sriraam, "Classification of focal and non-focal EEG signals using neighborhood component analysis and machine learning algorithms," *Expert Systems with Applications*, vol. 113, pp. 18-32, 2018, doi: <https://doi.org/10.1016/j.eswa.2018.06.031>.
- [136] J. Goldberger, G. E. Hinton, S. Roweis, and R. R. Salakhutdinov, "Neighbourhood components analysis," *Advances in neural information processing systems*, vol. 17, 2004.
- [137] W. Yang, K. Wang, and W. Zuo, "Neighborhood component feature selection for high-dimensional data," *J. Comput.*, vol. 7, no. 1, pp. 161-168, 2012, doi: 10.4304/jcp.7.1.161-168.
- [138] M. L. McHugh, "The chi-square test of independence," *Biochemia medica*, vol. 23, no. 2, pp. 143-149, 2013, doi: <https://doi.org/10.11613/BM.2013.018>.
- [139] D. Sharpe, "Chi-square test is statistically significant: Now what?," *Practical Assessment, Research, and Evaluation*, vol. 20, no. 1, p. 8, 2015, doi: <https://doi.org/10.7275/tbfa-x148>.
- [140] M. Sankaran, "Approximations to the non-central chi-square distribution," *Biometrika*, vol. 50, no. 1/2, pp. 199-204, 1963.
- [141] H. Peng, F. Long, and C. Ding, "Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 27, no. 8, pp. 1226-1238, 2005.

- [142] C. Ding and H. Peng, "Minimum redundancy feature selection from microarray gene expression data," *Journal of bioinformatics and computational biology*, vol. 3, no. 02, pp. 185-205, 2005.
- [143] H. Jiang, *Machine Learning Fundamentals: A Concise Introduction*. Cambridge University Press, 2021.
- [144] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The bulletin of mathematical biophysics*, vol. 5, no. 4, pp. 115-133, 1943.
- [145] D. Rumelhart, G. Hinton, and R. Williams, "Learning Internal Representations by Error Propagation. Parallel Distributed Processing, Vol. I, Rumelhart, D. E. and McClelland, JL," ed: MIT Press, Cambridge, MA, 1986.
- [146] J. R. Quinlan, *C4. 5: programs for machine learning*. Elsevier, 2014.
- [147] A. Subasi, M. Balfaqih, Z. Balfagih, and K. Alfawwaz, "A Comparative Evaluation of Ensemble Classifiers for Malicious Webpage Detection," *Procedia Computer Science*, vol. 194, pp. 272-279, 2021, doi: <https://doi.org/10.1016/j.procs.2021.10.082>.
- [148] P. Cichosz, *Data mining algorithms: explained using R*. John Wiley & Sons, 2014.
- [149] J. M. Keller, M. R. Gray, and J. A. Givens, "A fuzzy k-nearest neighbor algorithm," *IEEE transactions on systems, man, and cybernetics*, no. 4, pp. 580-585, 1985.
- [150] T. Cover and P. Hart, "Nearest neighbor pattern classification," *IEEE transactions on information theory*, vol. 13, no. 1, pp. 21-27, 1967.
- [151] J. Han, J. Pei, and M. Kamber, *Data mining: concepts and techniques*. Elsevier, 2011.
- [152] P. Xanthopoulos, P. M. Pardalos, and T. B. Trafalis, "Linear discriminant analysis," in *Robust data mining*: Springer, 2013, pp. 27-33.
- [153] M. Koklu and I. A. Ozkan, "Multiclass classification of dry beans using computer vision and machine learning techniques," *Computers and Electronics in Agriculture*, vol. 174, p. 105507, 2020.
- [154] C. Cortes and V. Vapnik, "Support-vector networks," *Machine learning*, vol. 20, no. 3, pp. 273-297, 1995, doi: <https://doi.org/10.1007/BF00994018>.
- [155] I. H. Witten, E. Frank, M. A. Hall, and C. J. Pal, *DATA MINING: Practical machine learning tools and techniques*, Fourth ed. (DATA MINING). Morgan Kaufmann, 2017, p. 601.
- [156] C. C. Aggarwal, *Data mining: the textbook*. Springer, 2015.

- [157] Ö. İlyas, “Uzun Kısa Dönem Bellek Ağlarını Kullanarak Erken Aşama Diyabet Tahmini,” *Mühendislik Bilimleri ve Araştırmaları Dergisi*, vol. 2, no. 2, pp. 50-57, 2020.
- [158] S. Arlot and A. Celisse, “A survey of cross-validation procedures for model selection,” *Statistics surveys*, vol. 4, pp. 40-79, 2010.
- [159] A. Abdullah and M. KARABATAK, “Veri Seti-Sınıflandırma İlişkisinde Performansa Etki Eden Faktörlerin Değerlendirilmesi,” *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 32, no. 2, pp. 531-540, 2020.
- [160] A. P. Bradley, “The use of the area under the ROC curve in the evaluation of machine learning algorithms,” *Pattern recognition*, vol. 30, no. 7, pp. 1145-1159, 1997.
- [161] A. D. Ertorsun, B. Bağ, G. Uzar, and M. A. Turanoğlu, “Roc (Receiver operating charactersitic) eğrisi yöntemi ile tanı testlerinin performanslarının değerlendirilmesi,”
<http://tip.baskent.edu.tr/kw/upload/464/dosyalar/cg/sempozyum/ogrsmpzsnm12/10.2.pdf> [Online].
- [162] A. Çınar and S. A. Tuncer, “Classification of normal sinus rhythm, abnormal arrhythmia and congestive heart failure ECG signals using LSTM and hybrid CNN-SVM deep neural networks,” *Computer Methods in Biomechanics and Biomedical Engineering*, vol. 24, no. 2, pp. 203-214, 2021.
- [163] A. S. Eltrass, M. B. Tayel, and A. I. Ammar, “A new automated CNN deep learning approach for identification of ECG congestive heart failure and arrhythmia using constant-Q non-stationary Gabor transform,” *Biomedical Signal Processing and Control*, vol. 65, p. 102326, 2021.
- [164] P. G. Gaddam and R. Sreehari, “Automatic Classification of Cardiac Arrhythmias based on ECG Signals Using Transferred Deep Learning Convolution Neural Network,” in *Journal of Physics: Conference Series*, 2021, vol. 2089, no. 1: IOP Publishing, p. 012058.
- [165] S. Krishnakumar, M. Yasodha, J. V. Priyadharshini, J. B. Janney, S. Divakaran, and V. L. Christy, “Detection of Arrhythmia and Congestive Heart Failure Through Classification of ECG Signals Using Deep Learning Neural Network,” in *2021 International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation (ICAECA)*, 2021: IEEE, pp. 1-7.
- [166] C. U. Kumari *et al.*, “Heart Rhythm Abnormality Detection and Classification using Machine Learning Technique,” in *2020 4th International Conference on Trends in Electronics and Informatics (ICOEI)(48184)*, 2020: IEEE, pp. 580-584.
- [167] S. Nahak and G. Saha, “A fusion based classification of normal, arrhythmia and congestive heart failure in ECG,” in *2020 National Conference on Communications (NCC)*, 2020: IEEE, pp. 1-6.

- [168] R. F. Olanrewaju, S. N. Ibrahim, A. L. Asnawi, and H. Altaf, "Classification of ECG signals for detection of arrhythmia and congestive heart failure based on continuous wavelet transform and deep neural networks," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 22, no. 3, pp. 1520-1528, 2021.
- [169] N. Rahuja and S. K. Valluru, "A Deep Neural Network Approach to Automatic Multi-Class Classification of Electrocardiogram Signals," in *2021 International Conference on Intelligent Technologies (CONIT)*, 2021: IEEE, pp. 1-4.
- [170] G. Othman and D. Q. Zeebaree, "The applications of discrete wavelet transform in image processing: A review," *Journal of Soft Computing and Data Mining*, vol. 1, no. 2, pp. 31-43, 2020.
- [171] A. Katharotiya, S. Patel, and M. Goyani, "Comparative analysis between DCT & DWT techniques of image compression," *Journal of information engineering and applications*, vol. 1, no. 2, pp. 9-17, 2011.
- [172] C. Goel, A. Kumar, S. K. Dubey, and V. Srivastava, "Efficient deep network architecture for covid-19 detection using computed tomography images," *medRxiv*, 2020.
- [173] M. Irfan *et al.*, "Role of Hybrid Deep Neural Networks (HDNNs), Computed Tomography, and Chest X-rays for the Detection of COVID-19," *International Journal of Environmental Research and Public Health*, vol. 18, no. 6, p. 3056, 2021.
- [174] E. Acar, E. Şahin, and İ. Yilmaz, "Improving effectiveness of different deep learning-based models for detecting COVID-19 from computed tomography (CT) images," *medRxiv*, 2020.
- [175] M. Polsinelli, L. Cinque, and G. Placidi, "A light CNN for detecting COVID-19 from CT scans of the chest," *Pattern recognition letters*, vol. 140, pp. 95-100, 2020.
- [176] R. Kundu, H. Basak, P. K. Singh, A. Ahmadian, M. Ferrara, and R. Sarkar, "Fuzzy rank-based fusion of CNN models using Gompertz function for screening COVID-19 CT-scans," *Scientific reports*, vol. 11, no. 1, pp. 1-12, 2021.
- [177] Y. Pathak, P. K. Shukla, A. Tiwari, S. Stalin, and S. Singh, "Deep transfer learning based classification model for COVID-19 disease," *Irbm*, 2020.
- [178] N. Hasan, Y. Bao, and A. Shawon, "DenseNet convolutional neural networks application for predicting COVID-19 using CT image," 2020.
- [179] F. Ozyurt, T. Tuncer, and A. Subasi, "An automated COVID-19 detection based on fused dynamic exemplar pyramid feature extraction and hybrid feature selection using deep learning," *Computers in Biology and Medicine*, vol. 132, p. 104356, 2021.

- [180] Y. Song *et al.*, “Deep learning enables accurate diagnosis of novel coronavirus (COVID-19) with CT images,” *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 2021.
- [181] M. Loey, G. Manogaran, and N. E. M. Khalifa, “A deep transfer learning model with classical data augmentation and cgan to detect covid-19 from chest ct radiography digital images,” *Neural Computing and Applications*, pp. 1-13, 2020.
- [182] G. A. Darbellay and I. Vajda, “Estimation of the information by an adaptive partitioning of the observation space,” *IEEE Transactions on Information Theory*, vol. 45, no. 4, pp. 1315-1321, 1999.
- [183] I. S. Thaseen and C. A. Kumar, “Intrusion detection model using fusion of chi-square feature selection and multi class SVM,” *Journal of King Saud University-Computer and Information Sciences*, vol. 29, no. 4, pp. 462-472, 2017.
- [184] A. M. Dawud, K. Yurtkan, and H. Oztoprak, “Application of deep learning in neuroradiology: brain haemorrhage classification using transfer learning,” *Computational Intelligence and Neuroscience*, vol. 2019, 2019.
- [185] M. Grewal, M. M. Srivastava, P. Kumar, and S. Varadarajan, “Radnet: Radiologist level accuracy using deep learning for hemorrhage detection in ct scans,” in *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, 2018: IEEE, pp. 281-284.
- [186] T. D. Phong *et al.*, “Brain hemorrhage diagnosis by using deep learning,” in *Proceedings of the 2017 International Conference on Machine Learning and Soft Computing*, 2017, pp. 34-39.
- [187] Ö. Özaltın and Ö. Yeniay, “Ecg classification performing feature extraction automatically using a hybrid cnn-svm algorithm,” in *2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*, 2021: IEEE, pp. 1-5, doi: 10.1109/HORA52670.2021.9461295.
- [188] Öznur Özaltın, Murat Köklü, Aynur Yonar, and Ö. Yeniay, “Automatically Image Classification Based on a New CNN Architecture,” presented at the III. International Applied Statistics Conference (UYIK - 2022), Skopje, N. Macedonia, 22-24 June 2022 . 2022. [Online]. Available: <https://www.uyik.org/kongre-kitaplari>.
- [189] O. Ozaltın, O. Coskun, O. Yeniay, and A. Subasi, “A Deep Learning Approach for Detecting Stroke from Brain CT Images Using OzNet,” *Bioengineering*, vol. 9, no. 12, p. 783, 2022, <https://doi.org/10.3390/bioengineering9120783>.

EKLER

EK 1 - Tezden Türetilmiş Yayınlar

1. Ö. Özaltın and Ö. Yeniay, “ECG Classification Performing Feature Extraction Automatically Using a Hybrid CNN-SVM Algorithm,” in *2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*, IEEE, pp. 1-5, 2021. (full text)
doi: 10.1109/HORA52670.2021.9461295.
2. O.Ozaltın and O. Yeniay, “A Novel Proposed CNN-SVM Architecture for ECG Scalograms Classification”, *Soft Computing*, 2022.
<https://doi.org/10.1007/s00500-022-07729-x>.
3. O.Ozaltın, O. Yeniay and A.Subasi, “OzNet: A New Deep Learning Approach for Automated Classification of Covid-19 Computed Tomography Scans” ,*BIG DATA*, Manuscript ID: BIG-2022-0042.R1, Submitted 26.01.2022 (Accepted 24.01.2023).
4. O. Ozaltın, O. Coskun, O. Yeniay, and A. Subasi, “Classification of brain hemorrhage computed tomography images using OzNet hybrid algorithm,” *International Journal of Imaging Systems and Technology*, 33(1), 69-91, 2023,
<https://doi.org/10.1002/ima.22806>.
5. O. Ozaltın, M. Köklü, A. Yonar, and Ö. Yeniay, “Automatically Image Classification Based on a New CNN Architecture,” presented at the III. International Applied Statistics Conference (UYIK - 2022),Skopje,N. Macedonia, 22-24 June, 2022 [Online]. Available: <https://www.uyik.org/kongre-kitaplari>.
(full text)
6. O. Ozaltın, O. Coskun, O. Yeniay, and A. Subasi, “A Deep Learning Approach for Detecting Stroke from Brain CT Images Using OzNet “. *Bioengineering*, 9,783, 2022, <https://doi.org/10.3390/bioengineering9120783>.

EK 2- Tezden Türetilmiş Bildiriler

1. Ö. Özaltın, A.Yonar, O.Coskun and Ö. Yeniay, “ A Hybrid Structure for Classification of Brain Cysts Images,” presented at the III. International Applied Statistics Conference (UYIK - 2022),Skopje,N. Macedonia, 22-24 June 2022, p.242 [Online]. Available: <https://www.uyik.org/kongre-kitaplari>. (Abstract)