



**DERİN ÖĞRENME TABANLI HİBRİT MODEL
TASARIMI İLE EKG SİNYAL
SINIFLANDIRMASINDA ARİTMİ TESPİTİ**

**2022
YÜKSEK LİSANS TEZİ
BİYOMEDİKAL MÜHENDİSLİĞİ**

Tuğba TAŞBAŞI

**Tez Danışmanı
Dr. Öğr. Üyesi Eftâl ŞEHİRLİ**

**DERİN ÖĞRENME TABANLI HİBRİT MODEL TASARIMI İLE EKG
SİNYAL SINIFLANDIRMASINDA ARİTMİ TESPİTİ**

Tuğba TAŞBAŞI

Tez Danışmanı

Dr. Öğr. Üyesi Eftâl ŞEHİRLİ

T.C.

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalında

Yüksek Lisans Tezi

Olarak Hazırlanmıştır

KARABÜK

Aralık 2022

Tuğba TAŞBAŞI tarafından hazırlanan “DERİN ÖĞRENME TABANLI HİBRİT MODEL TASARIMI İLE EKG SİNYAL SINIFLANDIRMASINDA ARİTMİ TESPİTİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Eftâl ŞEHİRLİ

.....

Tez Danışmanı, Biyomedikal Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Biyomedikal Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 27/12/2022

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Doç. Dr. Muhammet Kamil TURAN (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Abdullah ELEN (BANÜ)

Çevrimiçi

Üye : Dr. Öğr. Üyesi Eftâl ŞEHİRLİ (KBÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Doç. Dr. Müslüm KUZU

.....

Lisansüstü Eğitim Enstitüsü Müdürü

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

Tuğba TAŞBAŞI

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME TABANLI HİBRİT MODEL TASARIMI İLE EKG SİNYAL SINIFLANDIRMASINDA ARİTMİ TESPİTİ

Tuğba TAŞBAŞI

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Eftâl ŞEHİRLİ

Aralık 2022, 75 sayfa

Elektrokardiyografi (EKG), cilt üzerine yerleştirilen elektrotlar sayesinde kalbin elektriksel aktivitesini algılayarak elde edilen kalp grafiğinin okunup tanı konulması işlemidir. Elde edilen verilerle birlikte, hastanın fizik muayenesi, hastanın öyküsü ve diğer etmenler de göz önüne alınarak kalp ve damar hastalıkları teşhisi konulabilmektedir. Kalp hastalıkları hayati risk taşıyan ve insanların hayat kalitesini düşüren hastalıklardandır. Bu sebeplerle erken tanı önemli bir rol oynamaktadır. Makine öğrenmesi ve derin öğrenme yöntemleri sayesinde medikal alanda önemli gelişmeler elde edilmiştir. Günümüzde derin öğrenme yöntemi ile EKG cihazından elde edilen verilerdeki anormallikleri yorumlayıp sınıflandırarak ani ölümlerin önüne geçmek hedeflenmektedir. Bu çalışmada amaç, derin öğrenme mimarilerinden olan Konvolüsyonel Sinir Ağları (Convolutional Neural Network, CNN) ve Uzun Kısa Vadeli Bellek (Long Short-Term Memory, LSTM) modelleri kullanılarak hibrit bir sistem oluşturulup EKG sinyalleri üzerinde aritmileri tahmin etmek için bir çözüm

üretmektir. Çalışmada Massachusetts Institute of Technology – Boston’s Beth Israel Hospital (MIT-BIH) aritmi veri setinde paylaşılmış olan 109.446 adet kalp sinyalleri 187 sütunda sayılaşdırılmış olup N: Non-ecotic beats (normal beat), S: Supraventricular ectopic beats, V: Ventricular ectopic beats, F: Fusion beats, Q: Unknown beats olmak üzere beş sınıfa ayrılmıştır. Veri setinde bulunan beş sınıftan veri sayısı en az olan F ve S sınıfı tek bir sınıf olarak birleştirilip Others isminde yeni sınıf olarak değerlendirilmiştir. Tüm sınıflar için CNN modelinde bulunan accuracy, specitivity, sensitivity, F1-score, Matthews correlation coefficient (MCC), Eğri Altındaki Alan (Area Under Curve, AUC) score ortalama değerleri sırasıyla %98.15, %98.58, %98.20, %98.09, 0.96, 0.997’dir. Tüm sınıflar için LSTM modelinde bulunan accuracy, specitivity, sensitivity, F1-score, MCC, AUC score ortalama değerleri sırasıyla %98.42, %98.67, %98.46, %98.34, 0.97, 0.997’dir. Tüm sınıflar için geliştirilen hibrit model ile bulunan accuracy, specitivity, sensitivity, F1-score, MCC, AUC score ortalama değerleri sırasıyla %98.48, %98.78, %98.58, %98.54, 0.97, 0.997’dir.

Anahtar Sözcükler : Aritmi, EKG sinyali, CNN, LSTM, derin öğrenme

Bilim Kodu : 92517

ABSTRACT

M. Sc. Thesis

ARRHYTHMIA DETECTION ON ECG SIGNALS VIA HYBRID MODEL DESIGN BASED ON DEEP LEARNING

Tuğba TAŞBAŞI

**Karabük University
Institute of Graduate Programs
Department of Biomedical Engineering**

Thesis Advisor:

Assist. Prof. Dr. Eftâl ŞEHİRLİ

December 2022, 75 pages

Electrocardiography (ECG) is the process of reading and diagnosing the heart graph obtained by sensing the electrical activity of the heart by means of electrodes placed on the skin. Together with the data obtained, the diagnosis of cardiovascular diseases can be made by considering the patient's physical examination, the patient's history and other factors. Heart diseases are life-threatening diseases that reduce the quality of people's lives. For these reasons, early diagnosis plays an important role. Thanks to machine learning and deep learning methods, important developments have been achieved in the medical field. Recently, it is aimed to prevent sudden deaths by interpreting and classifying the abnormalities in the data obtained from the ECG device with the deep learning method. The aim of this study is to create a hybrid system using Convolutional Neural Networks (CNN) and Long Short-Term Memory (LSTM) models, which are deep learning architectures, and to produce a solution to predict arrhythmias on ECG signals. In this study, 109,446 heart signals shared in the

MIT-BIH arrhythmia dataset was quantified in 187 columns and N: Non-ecotic beats (normal beat), S: Supraventricular ectopic beats, V: Ventricular ectopic beats, F: Fusion beats, Q: Unknown beats. divided into five classes. F and S classes, which have the least amount of data from the five classes in the data set, were combined as a single class and evaluated as a new class named Others. The average values of accuracy, specificity, sensitivity, F1-score, MCC, AUC score found in the CNN model for all classes are 98.15%, 98.58%, 98.20%, 98.09%, 0.96, and 0.997, respectively. The average values of accuracy, specificity, sensitivity, F1-score, MCC, AUC score found in the LSTM model for all classes are 98.42%, 98.67%, 98.46%, 98.34%, 0.97, and 0.997, respectively. The average values of accuracy, specificity, sensitivity, F1-score, MCC and AUC score found by the hybrid model developed for all classes are 98.48%, 98.78%, 98.58%, 98.54%, 0.97, 0.997, respectively.

Key Word : Arrhythmia, ECG signal, CNN, LSTM, deep learning

Science Code : 92517

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Dr. Öğr. Üyesi Eftâl ŐEHİRLİ'ye sonsuz teşekkürlerimi sunarım.

Sevgili aileme manevi hiçbir yardımını esirgemedен yanımda oldukları için tüm kalbimle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	5
KALP	5
2.1. KALP ELEKTRİKSEL İLETİM SİSTEMİ.....	5
2.2. ELEKTROKARDİYOĞRAFİ (EKG)	6
2.3. KARDİOVASKÜLER HASTALIK	8
2.3.1. Kardiyak Aritmi.....	9
2.3.1.1. Atriyal Fibrilasyon (AF)	9
2.3.1.2. Sağ Demet Dal Bloğu (RBBB) ve Sol Demet Dal Bloğu (LBBB). 10	
2.3.1.3. Erken Atrial Kasılma ve Erken Ventriküler Kasılma	10
2.3.1.4. Ektopik Atımlar	11
2.3.1.5. Miyokard Enfarktüsü (MI).....	11
2.3.1.6. Füzyon Atımı	12
2.3.1.7. Sinüs Bradikardisi	12
2.3.1.8. Taşikardi	12
2.3.1.9. Atriyal Flutter (AFL)	13
2.3.1.10. Ventriküler Flutter (VF).....	13

2.3.1.11. Ventriküler Fibrilasyon (VFİB)	14
BÖLÜM 3	15
YAPAY ZEKA	15
3.1. YAPAY SİNİR AĞLARI (YSA)	18
3.1.1. Tek Katmanlı Algılayıcılar	19
3.1.2. Çok Katmanlı Algılayıcılar	20
3.1.3. Denetimli ve Denetimsiz Öğrenme	21
3.1.4. Aktivasyon Fonksiyonu	23
3.2. DERİN SİNİR AĞLARI	27
BÖLÜM 4	29
EKG SİNYAL SINIFLANDIRMASINDA YAPILAN ÇALIŞMALAR	29
BÖLÜM 5	32
MATERYAL VE YÖNTEM	32
5.1. VERİ SETİ	32
5.2. VERİ ÖN İŞLEME	33
5.3. EVRİŞİMLİ SİNİR AĞLARI (CNN)	34
5.4. UZUN KISA VADELİ BELLEK (LSTM)	38
5.5. HİPER PARAMETRE OPTİMİZASYONU	43
5.6. MODEL PERFORMANSI DEĞERLENDİRME	44
BÖLÜM 6	48
ÇALIŞMA BULGULARI VE TARTIŞMA	48
6.1. GELİŞTİRİLEN MODELLERDE ELDE EDİLEN BULGULAR	48
6.2. TARTIŞMA	56
BÖLÜM 7	63
SONUÇLAR	63
KAYNAKLAR	65
ÖZGEÇMİŞ	75

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Normal bir EKG kaydında bulunan dalga ve aralıkların gösterimi	6
Şekil 2.2. Atriyal Taşikardi (fibrilasyon ve çarpıntı) EKG görüntüsü	9
Şekil 2.4. PVC'nin EKG örnek görüntüleri	11
Şekil 2.5. Ektopik atımlar EKG görüntüleri.....	11
Şekil 2.6. Sinüs bradikardisi EKG örneği	12
Şekil 2.7. Atriyal taşikardi örneği	13
Şekil 2.8. AFL'nin EKG örneği	13
Şekil 2.9. Ventriküler fibrilasyon EKG örneği	14
Şekil 3.1. Tıpta yapay zekanın gelişiminin zaman çizelgesi.....	17
Şekil 3.2. Sinir hücresine ait sinyal ve bilgi iletim işleminin modellenmesi	18
Şekil 3.3 Tek katmanlı algılayıcıların çalışma prensibi	19
Şekil 3.4. Çok katmanlı algılayıcı örneği.....	21
Şekil 3.5. Denetimli makine öğrenmesi örneği	22
Şekil 3.6. Denetimsiz makine öğrenmesi örneği.....	22
Şekil 3.7. YSA'da öğrenmenin gerçekleşmesi.....	23
Şekil 3.8. Sigmoid aktivasyon fonksiyonu grafiği.....	24
Şekil 3.9. Hiperbolik tanjant aktivasyon fonksiyonu grafiği	24
Şekil 3.10. ReLU aktivasyon fonksiyonu grafiği.....	25
Şekil 3.11. Leaky ReLU aktivasyon fonksiyonu grafiği.....	26
Şekil 5.1. CNN genel gösterim	34
Şekil 5.2. CNN modeli blok diyagramı.....	37
Şekil 5.3. LSTM model diyagramı.....	40
Şekil 5.4. LSTM modeli blok diyagramı	42
Şekil 5.5. Karışıklık matrisi	45
Şekil 6.1. Çalışmada geliştirilen hibrit model.....	51
Şekil 6.2. Epoch sayısı 30 olan sınıflandırmalarda ROC eğrileri	60
Şekil 6.3. Epoch sayısı 50 olan sınıflandırmalarda ROC eğrileri	61
Şekil 6.4. Epoch sayısı 100 olan sınıflandırmalarda ROC eğrileri	62

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 5.1. Veri seti sınıf bilgileri	32
Çizelge 5.2. Veri seti sınıf dağılım bilgileri.....	33
Çizelge 5.3. Veri ön işleme sonrası veri seti sınıf dağılım bilgileri.....	33
Çizelge 5.4. CNN modelinin yapısı	38
Çizelge 5.5. LSTM modelinin yapısı	42
Çizelge 6.1. N, V, Q ve Others sınıfları için karışıklık matrisi değerleri	51
Çizelge 6.2. CNN ve LSTM modellerinden elde edilen genel sonuçlar.....	52
Çizelge 6.3. N, V, Q ve Others sınıflarından elde edilen accuracy değerleri	53
Çizelge 6.4. N, V ve Q sınıflarından elde edilen accuracy değerleri.....	54
Çizelge 6.5. N ve V sınıflarından elde edilen accuracy değerleri.....	55
Çizelge 6.6. F ve S sınıflarından elde edilen accuracy değerleri	55
Çizelge 6.7. Önerilen yöntem ve yapılan diğer çalışmaların karşılaştırılması.....	58

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

φ : Fi

α : Alfa

σ : Sigma

KISALTMALAR

AAMI : Association for the Advancement of Medical Instrumentation (Tıbbi Aletleri Geliştirme Derneği)

AF : Atriyal Fibrilasyon

AFB : Atrial Fusion Beats (Atriyal Füzyon Atımları)

AFL : Atriyal Flutter

AUC : Area Under Curve (Eğri Altındaki Alan)

BIH : Boston's Beth Israel Hospital (Boston Beth İsrail Hastanesi)

BN : Batch Normalization (Toplu Normalizasyon)

CAD : Computer Aided Diagnosis (Bilgisayar Destekli Tanı)

CNN : Convolutional Neural Network (Evrişimli Sinir Ağları)

EKG : Elektrokardiyografi

ELP : ECG Language Processing (EKG Dil İşleme)

FC : Fully Connected (Tam Bağlantılı)

FN : False Negative (Yanlış Negatif)

FP : False Positive (Yanlış Pozitif)

FPR : False Positive Rate (Yanlış Pozitif Oranı)

Hz : Hertz

KVH : Kardiyovasküler Hastalıklar

LBBB : Left Bundle Branch Block (Sol Demet Dal Bloğu)

LSTM : Long Short-Term Memory (Uzun-Kısa Süreli Bellek)

MCC : Matthews Correlation Coefficient (Matthews Korelasyon Katsayısı)
MI : Myocardial Infarction (Miyokard Enfarktüs)
MIT : Massachusetts Institute of Technology (Massachusetts Teknoloji Enstitüsü)
PAC : Premature Atrial Contraction (Erken Atriyal Kasılma)
PVC : Premature Ventricular Contraction (Erken Ventriküler Kasılma)
RBBB : Right Bundle Branch Block (Sağ Demet Dal Bloğu)
RELU : Rectified Linear Unit (Doğrultulmuş Lineer Birim)
RGB : Red Green Blue (Kırmızı Yeşil Mavi)
RNN : Recurrent Neural Network (Yinelemeli Sinir Ağı)
ROC : Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
SVEB : Supraventricular Ectopic Beats (Supraventriküler Atımlar)
SVT : Supraventricular Tachycardia (Supraventriküler Taşikardi)
TANH : Hiperbolik Tanjant
TN : True Negative (Gerçek Negatif)
TP : True Positive (Gerçek Pozitif)
TPR : True Positive Rate (Gerçek Pozitif Oranı)
VEB : Ventricular Ectopic Beats (Ventriküler Ektopik Atımlar)
VF : Ventricular Flutter (Ventriküler Flutter)
VFB : Ventricular Fusion Beats (Ventriküler Füzyon Atımları)
VFİB : Ventricular Fibrillation (Ventriküler Fibrilasyon)
WHO : World Health Organization (Dünya Sağlık Örgütü)
YSA : Yapay Sinir Ağları

BÖLÜM 1

GİRİŞ

Kardiyovasküler hastalıklar (KVH) dünya genelinde en çok ölüme sonuçlanan hastalık sınıflarının başında gelmektedir. Dünya Sağlık Örgütü (World Health Organization, WHO) tarafından yapılan çalışma verilerine göre 2019 yılında tahminen 17,9 milyon insanın ölüm sebebi KVH olmuştur. Bu değer dünya nüfusunun %32'sini oluşturmuştur. KVH içinde %85 ile en çok ölüme neden olan, kalp krizi ve felç durumlarıdır [1]. Tüm bu veriler KVH teşhis ve tedavisinin ne kadar önemli olduğunu anlatmaktadır.

Sağlıklı bir insana ait normal sayılan kalp hızı 60-100 atım/dk olarak belirlenmiştir. Kalbin 100 atım/dakikadan çok atması ya da 60 atım/dakikadan az atması durumunda kalpte aritmi meydana gelmektedir. Kalp atımının hızlı ve yavaş olması dışında düzensiz oluşu kalp aritmisi olarak değerlendirilmektedir. Kalplerinde ritim bozukluğu meydana gelen hastalardaki kan basıncı, kalp ileti yollarında sürdürülemezlik bilinç kaybı ve ani ölümlere sebebiyet verebilmektedir [2]. Kardiyak aritmiler kalp hastalıklarının önemli belirtilerinden biridir ve tüm yaş aralıklarındaki insanlarda yaygın görülmektedir [3].

Elektrokardiyografi (EKG), kalp kasının ve kalbin elektriksel faaliyetlerinin kaydedilmesi işlemidir. Yapılan kayıt sonucunda elde edilen grafik elektrokardiyogram olarak adlandırılmaktadır. EKG non-invaziv ve uygulanması kolay olduğu için KVH teşhisinde akla gelen yaygın bir yöntemdir [4]. Elektrokardiyografi işlemi için hastanın kol ve bacaklarına elektrotlar bağlanması gerekmektedir. İnsan vücudunun çeşitli yerlerine göre farklı derivasyonlar bulunmaktadır. Bu derivasyonlar, buldukları yerlere göre hekime hastalık hakkında bilgi vermede kolaylık sağlamaktadırlar. EKG, kardiyoloji alanında hastaların durumları hakkında bilgi veren ve kardiyak aritmi gibi hastalıkların

teşhisinin yapılmasına yardımcı olan bir teknik olarak kullanılmaktadır [5]. KVH otomatik teşhisi için çeşitli çalışmalar yapılmıştır. EKG sinyallerinden özellik çıkarılarak sonrasında çıkarılan özellikler sınıflandırılarak KVH'lerin otomatik tespiti yapılmaktadır. EKG sinyallerini sınıflandırmak için genellikle iki çeşit yapay sinir ağı yaklaşımı kullanılmaktadır. Bu yaklaşımlar makine öğrenmesi ve derin öğrenme olarak karşımıza çıkmaktadır [6].

Makine öğrenimi insanların öğrenme şeklini taklit etmede, veriyi ve kendine ait algoritmalarını kullanan bir yapay zeka türüdür [7]. Makine öğrenmesinde istatistiksel yöntemler kullanılmaktadır. Kullanılan yöntemler aracılığıyla algoritmalar, sınıflandırmalar ya da tahminler yapılarak model eğitilmektedir. Makine öğrenmesi yaklaşımında, veri türü kullanıcı tarafından seçilmekte ve tanımlanmaktadır. Başka bir ifade ile kullanıcı kullanmak istediği veri özelliklerini kendisi seçmesi gerekmektedir [8].

Derin öğrenme bir veya daha çok gizli katman içeren makine öğrenmesine benzeyen algoritmalar içeren bir tür yapay zeka alanıdır [9]. Derin öğrenme ve makine öğrenmesi arasındaki en önemli fark modelde kullanılan algoritmaların öğrenme şeklidir. Derin öğrenmede özellik çıkarma otomatik olarak yapılmaktadır. Bu özelliği sayesinde insan müdahalesi olmadan daha büyük verilerde çalışabilme imkanı sağlanmaktadır. Makine öğrenmesinde, verilerde belirlenen özellikler seçildiği için veri içinde önemli sayılabilecek özelliklerin kaybolması muhtemel bir olaydır. Derin öğrenmede verilerden önemli bilgiler otomatik öğrenilirken, kendi kendine yeni özellikleri çıkarma imkanına sahiptir [10]. Makine öğrenmesinde insan faktörü daha etkili olmasına karşılık derin öğrenmede daha azdır. Son yıllarda büyük verilerde çalışmak için, özellik çıkarma gibi bölümlerde insan faktörünün az olduğu derin öğrenme yaklaşımı daha çok tercih edilmektedir [11]. Derin öğrenmenin çeşitli mimarileri bulunmaktadır. Bu tez çalışmasında derin öğrenme mimarilerinden CNN ve Yinelemeli Sinir Ağının (Recurrent Neural Network, RNN) bir türü olan LSTM modelleri kullanılmıştır. Seçilecek model probleme göre değişiklik göstermektedir. Çalışmada çözülmek istenilen probleme göre en uygun model seçilerek istenilen performans değerlendirme metrik oranlarına ulaşmak hedeflenmektedir.

CNN, algoritmalar içinde çok popüler olan ve herhangi bir insan denetimine gerek kalmadan otomatik özellik çıkaran derin öğrenme mimarilerinin başında gelmektedir [12]. Standart bir CNN yapısında üç çeşit katman bulunmaktadır; Evrişim (Convolution) Katmanı, Havuzlama (Pooling) Katmanı ve Tam Bağlantılı Katman (Fully Connected Layer, FC). Evrişim ve havuzlama katmanlarında özellik çıkarılırken tam bağlantılı katmanda çıkarılan özellikler sınıflandırılmaktadır. Bir girdi görüntüsü alınır, farklılaşmayı sağlamak için görüntünün çeşitli yönlerine önemli ağırlıklar ve biaslar atanılarak minimum ön işleme filtreler uygulanmaktadır [13]. İlk evrişim katmanı düşük seviyeli özellikleri yakalarken, sonraki katmanlar daha yüksek seviyeli özellikleri çıkararak veri setindeki görüntülerin analizi ile bir ağ oluşturulmaktadır [14].

RNN, bir veri kümesinin sıralı özneliğini tanımak ve bir sonraki olası senaryoyu tahmin etmek için kalıpları kullanmak üzere tasarlanmış bir derin öğrenme mimarisidir. Ses, zaman serisi verileri ve yazılı doğal dil gibi sıralı verileri işlemeye yönelik güçlü bir yaklaşımdır. Giriş ve çıkışların birbirinden bağımsız olduğu geleneksel ağların aksine, bir RNN’de gizli katman önceki adımlardan sıralı bilgileri korumaktadır. RNN’de yapılan işlem, bir önceki adımın çıktısının tahmin amacıyla, aynı ağırlık ve bias kullanılarak mevcut bir adıma girdi olarak beslendiğini göstermektedir. Katmanlar tek bir tekrarlayan katman oluşturmak için birleştirilmektedir. Yapılan işlem geri bildirim döngülerini ve sıralı verileri işlemektedir, bilgilerin bellekte olduğu gibi kalmasına izin vererek son çıktıyı bilgilendirmektedir [15].

Bu tez çalışmasının amacı, EKG sinyallerini kullanarak KVH’lerden biri olan kardiyak aritminin otomatik teşhisini sağlamaktır. Bu amaç doğrultusunda derin öğrenme mimarilerinden hibrit bir model oluşturulup her bir sınıf için yüksek accuracy değerlerine ulaşmak hedeflenmiştir. Bu tez çalışmasında halka açık olarak bulunan Massachusetts Institute of Technology – Boston’s Beth Israel Hospital (MIT-BIH) aritmi veri seti kullanılarak derin öğrenmenin iki farklı modeli olan CNN ve LSTM modelleri ile hibrit bir model oluşturup otomatik kardiyak aritmi tespiti yapılması hedeflenmiştir.

Son yıllarda tıp alanında hastalıkları tespit etmek için derin öğrenme yöntemleri sıklıkla kullanılmaktadır. Gelişen teknoloji ile beraber hastalıkları daha iyi anlamak için mevcut yöntemleri geliştirmek ve yeni yöntemler bulmak devam eden araştırmalar arasında bulunmaktadır. Kalp insan vücudunda bulunan en önemli organların başında gelmektedir. Kalp rahatsızlığı yaşam kalitesini doğrudan etkilemekle birlikte ölüm gibi ciddi sonuçlar doğurabilmektedir. Bu sebeple KVH erken tespit edilmesi tedaviye zemin hazırlamak için çok önemlidir. KVH tespiti için geliştiren modellere bakıldığında, hibrit model üzerinden yapılan değerlendirmeler az olmakla birlikte kullanılan performans değerlendirme metrikleri genellikle birbirine çok benzemektedir. Bu tez çalışmasında kullanılan hibrit model bu noktada diğer çalışmalardan ayrılmakta ve literatüre bir özgünlük katmaktadır.

Bu tez çalışmasının birinci bölümünde “Giriş” başlığı altında tez çalışması hakkında özet bilgi verilerek tez çalışmasının amacı, tez çalışmasının kapsamı ve tez çalışmasının önemi anlatılmıştır. İkinci bölümde kalp, kalp elektriksel ileti sistemi, elektrokardiyografi, KVH ve kardiyak aritmi hakkında genel bilgilere yer verilmiştir. Üçüncü bölümde yapay zeka ile birlikte yapay sinir ağları, tek katmanlı ve çok katmanlı algılayıcılar, denetimli ve denetimsiz öğrenme, yapay sinir ağlarında öğrenmenin gerçekleşmesi, aktivasyon fonksiyonu, derin sinir ağları, derin öğrenme mimarileri ilgili teorik bilgiler verilmiştir. Dördüncü bölümde EKG sinyal sınıflandırmasında yapılan çalışmalar hakkında literatür bilgileri verilmiştir. Beşinci bölümde veri seti bilgileri, veri ön işleme, CNN yapısının detaylı anlatımı, geliştirilen CNN modeli, RNN hakkında kısa bilgiler ve LSTM yapısı, geliştirilen LSTM modeli, hiper parametre optimizasyonu, model performans değerlendirme metrikleri hakkında “Materyal ve Yöntem” başlığı altında teorik bilgilere yer verilmiştir. Altıncı bölümde ise geliştirilen model ile elde edilen bulgular ve konu ile alakalı yapılan diğer çalışmaların sonuçlarının kıyaslandığı tartışma bölümüne yer verilmiştir.

BÖLÜM 2

KALP

İnsan kalbinin en önemli işlevi, karbondioksit ve diğer atıkları vücuttan uzaklaştırarak vücut içinde bulunan bütün organlara devamlı oksijen ve besin sağlayabilmek için kardiyovasküler sistem aracılığıyla kan pompalamaktır [16]. Kalpte bulunan kulakçıkların koordineli bir şekilde kasılması ile kan ventriküllere iletilmektedir. Kalpteki işin büyük bir kısmını yapan ventriküller, kanı vücudun geri kalan kısmına iletebilmek için eş zamanlı olarak kasılmaktadır [17]. Kalbin göğüsteki yeri, göğüs kafesinin özellikle orta mediasten bölgesinde ve diyaframın hemen üzerinde bulunmaktadır. Kalbi, perikard adında çift zarlı bir kese çevreleyerek büyük damarlara yapıştırmaktadır [18]. İnsan kalbi, dört kapak ile birbirine bağlanmış şekilde bulunan sağ ve sol atriyumlar (kulakçık) ile sağ ve sol ventriküllerden (karıncık) oluşan dört odacıktan meydana gelmektedir. Bu kapakların koordineli bir şekilde çalışması, kan haznelerinin doldurulması işini düzenlerken, elektrik ve mekanik kalp sistemini de kontrol etmektedir [19].


2.1. KALP ELEKTRİKSEL İLETİM SİSTEMİ

Kalp elektriksel iletim sistemi, kalp atışını kontrol edebilmek amacıyla düğümlerden, hücrelerden ve sinyallerden oluşan ağ şeklinde bir yapıdır [20]. Kalp, kanın vücuda yayılabilmesi için koordineli kasılmaları başlatmak adına gerekli elektriksel uyarıyı üreterek ilgili bölümlerine iletmektedir [21]. Sinoatriyal düğüm, kalbin doğal kalp pili olarak adlandırılmaktadır ve üst sağ kulakçıkta yer alarak her kalp atışını normal kalp ritminde başlatmak için gerekli elektriksel aktiviteyi otomatik olarak üretmektedir [22]. Oluşan elektrik sinyali kalp kulakçıklarının kasılmasını tetiklemektedir. Bu sırada atriyoventriküler düğüm, atriyumdan kan boşalana kadar gelecek olan elektrik sinyalini bekletmektedir. Sinyal daha sonra sol ve sağ his demet dalları boyunca kalbin karıncıklarına doğru ilerlemektedir.

His demeti, elektrik sinyalini purkinje liflerine taşımaktadır. Ventriküllerde sinyal, purkinje lifleri adı verilen ve daha sonra elektrik yükünü kalp kasına ileten özel doku tarafından taşınmaktadır. Böylece kalp kasının tam bir kasılması oluşmaktadır [23, 24].

2.2. ELEKTROKARDİYOĞRAFI (EKG)

EKG, cilt üzerine yerleştirilen elektrotlar sayesinde kalbin elektriksel aktivitesini algılayarak elde edilen kalp grafiğinin okunup tanı konulması işlemidir. Kalpte sürekli devam eden bir elektriksel sistem bulunmaktadır. Elektriksel aktivitenin belli bir sürede değişim grafiği elektrokardiogram bilgisinin vermektedir. Geleneksel EKG hastaya yatar pozisyonda 12 derivasyonlu bir şekilde uygulanmaktadır. Vücuttaki elektrotlar, kalp kasının etkisiyle kulakçıkların depolarizasyon ve ventriküllerin repolarizasyon oluşumlarından meydana gelen küçük elektriksel aktiviteleri tespit etmektedir [25]. Sinoatriyal düğümde meydana gelen uyarı ile kalp atışının başlamasından itibaren EKG kaydında bulunan altı çeşit dalga ve aralıkları Şekil 2.1'de gösterilmektedir [26, 27].



Şekil 2.1. Normal bir EKG kaydında bulunan dalga ve aralıkların gösterimi [27].

Kalp, her atımına sinoatriyal düğümünden oluşan P dalga ile başlamaktadır. P dalgası, kalp döngüsü esnasında ya da bir kalp atışında atriyumların depolarizasyonu ile ortaya çıkan ilk elektriksel olay olan dalgadır. P dalgası pozitif ve yavaş bir dalga olarak değerlendirilmektedir [28]. P dalgasının ilk yarısı sağ atriyumun depolarizasyonunu ifade ederken diğer yarısı sol atriyumun depolarizasyonunu ifade etmektedir [29]. Bir kalp döngüsünde PR, QRS, QT, ST ve RR mesafesi bir ya da daha çok dalga içeren tek segmentli sürelerdir. Şekil 2.1’de görüldüğü gibi, PR mesafesi P dalgasının başlangıcından QRS kompleksinin başına kadar geçen sürenin aralığıdır. Ventriküllerin depolarizasyonu ve repolarizasyonu arasında geçen süre QT mesafesi olarak adlandırılmaktadır. RR mesafesi QRS kompleksinin pik yaptığı zirve noktasından itibaren bir sonraki QRS kompleksinin pik yaptığı noktaya kadar geçen süre olarak tanımlanmaktadır. Hastalık sınıflandırma için RR mesafesinin önceki kısmı, sonraki kısmı ve ortalaması gibi değerleri kullanılmaktadır [30]. İki dalga birbirine düz bir çizgi ile bağlanmaktadır. Bu düz çizgiler arasında bulunduğu dalgaları birbirine dahil etmeyen segmentlerdir ve izoelektrik çizgi olarak adlandırılmaktadır [31]. Normal bir EKG’de iki tane segment bulunmaktadır. PR segmenti, atriyumlarda meydana gelen depolarizasyondan sonra ventriküllerde oluşacak depolarizasyona kadarki zamanda elektriksel aktivitenin oluşmadığı bir süreyi anlatmaktadır. ST segmenti, QRS kompleksinden T dalgasının başına kadar olan kısımdaki süreyi anlatmaktadır [32]. QRS kompleksi Q, R ve S dalgalarının oluşturduğu bir komplekstir ve ventriküllerde oluşan depolarizasyon olayını anlatmaktadır. Q dalgası, ventriküllerde septal depolarizasyon esnasında oluşan hızlı, negatif ve boyut olarak küçük dalgalardır. QRS kompleksi içinde ilk pozitif olan dalga R dalgasıdır. R dalgası Q dalgasından sonra gelen güçlü ve hızlı bir dalgadır. R dalgasının oluşum sebebi kalp döngüsü esnasında büyük bir ventriküler depolarizasyon oluşmasıdır [33]. QRS kompleksinin son dalgası R dalgasını takip eden hızlı ve güçlü S dalgasıdır. Bu dalga kalp atışında en son oluşmaktadır. QRS kompleksinden sonra ilk oluşan dalga T dalgasıdır ve ventriküllerin repolarizasyonunu temsil etmektedir. T dalgasının devamında U dalgası gelebilmektedir. U dalgası, normal yetişkin bir insanda fizyolojik olarak EKG kaydı içerisinde görülmeyen bir dalgadır [34].

EKG sinyalini otomatik sınıflandırmada çeşitli sorunlar gözlemlenmiştir. Bu sorunların temel nedeni EKG sinyal morfolojisinin karmaşık yapısından

kaynaklanmaktadır. Kalp ritminde hastaya bağı olarak heyecan, stres, egzersiz ve diğ er fizyolojik etmenlerden kaynaklı deęişimler gözlenebilmektedir. Bahsedilen etmenler kişinin kalp hızını deęiştirmesi sebebiyle PR, RR ve QT mesafelerini deęiştirerek farklı EKG modellerinin oluşmasına sebep olabilmektedir [35]. EKG sinyalinin otomatik sınıflandırılmasında sorun oluşturan etmenlerden biri de dalga biçiminin bazen farklı hastalardan alınan EKG modellerinin zamansal veya morfolojik özelliklerinde farklılık göstermesidir. EKG dalga biçimleri, farklı kalp atışlarına sahip farklı hastalar için benzer olabilir ve aynı hasta için farklı zamanlarda farklı olabilmektedir [36]. Kalp hastalıklarının doğru şekilde teşhis edilebilmesi için EKG'yi oluşturan dalgaların başlangıcı ve kayması, dalgalar arasındaki süre, vuruşun hızı ile birlikte düzensiz ya da düzenli oluşu, dalga genliğinin büyüklüğü gibi özellikler dikkate alınmaktadır [37]. Bu sebeplerle KVH'lerin otomatik sınıflandırılması ve EKG'nin doğru anlaşılması günümüzde büyük bir öneme sahiptir.

2.3. KARDİYOVASKÜLER HASTALIK

KVH, kalp yapılarında, beyin de dahil olmak üzere diğ er önemli organları beslemekle görevli kaslarda ve damar sistemlerinde meydana gelen bozuklukları kapsamaktadır. Kalpte doğuştan rahatsızlıklar oluşabildiği gibi kişinin yaşam şartlarına, beslenme şekline, geçirdiği hastalık ve sakatlıklara göre sonradan oluşum gösterebilmektedir. KVH oluşum ve ilerlemesine göre kişinin hayat kalitesini düşürebilmekte ya da yaşamını durdurabilecek seviyelere getirebilmektedir [38].

EKG verileri ile tespit edilen ve en çok rastlanan KVH'ler aşağıdaki gibi listelenmiştir [39]. Bunlar:


1. Kalp ritminde anormal deęişimler (kardiyak aritmi)
2. Kalp bloęu ve iletim sorunları
3. Kalbin yetersiz kanlanması, kalp lezyonları, nekroz
4. Elektrolit bozuklukları (Mg, K, Ca) ve zehirlenme
5. Kalp yapısından kaynaklı hastalıklar
6. Senkop veya ani ölüme yatkınlık gösteren durumlar

2.3.1. Kardiyak Aritmi

Sağlıklı bir insana ait normal sayılan kalp hızı 60-100 atım/dk olarak belirlenmiştir. Kalp hızında meydana gelen anormallikler veya düzensizlikler kardiyak aritmi olarak adlandırılmaktadır. Kalp aritmisine sahip bir hastada çarpıntı, güçsüzlük, bilinç bozukluğu, göğüs ağrısı, nefes darlığı ve nöbet görülebilmektedir. Kalp aritmisini, kalp krizinin bir belirtisi olarak karşımıza çıkmaktadır. İlerlemiş kalp yetmezliği ile kardiyak arrestin nedenleri incelendiğinde kalp aritmilerin de etkili olduğu, çeşitli kalp hastalıklarının sonucunda gelişen ritim bozukluklarının hastalarda meydana geldiği gözlemlenmiştir [40]. Ölümcül aritmilerin nedenleri arasında en önemlisi yapısal koroner arter anormallikleri ve sonuçları, ikincisi ise dilate ve hipertrofik kardiyomiyopatiler, üçüncü sırada kapakçık veya doğuştan gelen kalp hastalıkları ve bilinen iyon kanalı anormallikleri gibi hastalıklar oluşturmaktadır [41]. Bunların yanında mevcut hastalıkların tedavisi için kullanılan ilaçlar da yan etki olarak kalp aritmisini oluşturabilmektedir. Kalp aritmisinde en yaygın sınıflandırma türleri aşağıda verilmiştir.

2.3.1.1. Atriyal Fibrilasyon (AF)


Atriyal Fibrilasyon (AF), atriyum içindeki aksiyon potansiyelinin çok hızlı bir şekilde ateşlenmesi sonucunda meydana gelmektedir. Hızlı sayılabilecek bir atriyal hız genel olarak 400-600 atım/dakikadan fazla olan durumlarda meydana gelmektedir [42]. Normal bir EKG de P dalgaları düşük genliğe sahip olmasından kaynaklı atriyal hızın yüksek olduğu AF durumunda görülmeyecektir. Şekil 2.2’de atriyal taşikardiye ait fibrilasyon ve çarpıntı örneklerinin EKG kaydı gösterilmektedir [43].



Şekil 2.2. Atriyal Taşikardi (fibrilasyon ve çarpıntı) EKG görüntüsü [43].

2.3.1.2. Sağ Demet Dal Bloğu (RBBB) ve Sol Demet Dal Bloğu (LBBB)

Sağ Demet Dal Bloğu (Right Bundle Branch Block, RBBB) ve Sol Demet Dal Bloğu (Left Bundle Branch Block, LBBB), iletim sisteminde anormal QRS yapısına yol açan bir kesinti olayından kaynaklanmaktadır. RBBB’de depolarizasyon olayı, septumdan geçerek sol ventrikülden sağ kısma yayıldığı için sağ ventrikülün aktivasyonu gecikmektedir. Bu sürede sol ventrikül aktive olmaktadır. EKG’de QRS kompleksinin ilk kısmı aynı kalmaktadır. Geciken sağ ventrikül aktivasyonu sonucunda EKG’de genliği artan ve uzamış bir S dalgası meydana gelmektedir. Sol demet, sol ventrikülü depolarize etmektedir. Bir LBBB’de sol demet etkinleştirilememektedir. Bu işlem yerine, sağ demetten gelen dürtü sağ ventrikül boyunca yayıldıktan sonra devamında sol ventriküle yayılmasıyla sol ventrikül depolarize edilir [44]. Bu elektriksel yayılma modeli, anormal bir QRS morfolojisi yaratır. Şekil 2.3’te LBBB ve RBBB’nin EKG örnekleri aşamalarıyla birlikte gösterilmektedir [45].



Şekil 2.3. Aşağıdan yukarıya normal, LBBB ve RBBB’nin EKG örnekleri [45].

2.3.1.3. Erken Atrial Kasılma ve Erken Ventriküler Kasılma

Erken Atriyal Kasılma (Premature Atrial Complex, PAC) ve Erken Ventriküler Kasılma (Premature Ventricular Complex, PVC), kalbin normal sinüs ritminin premature ya da erken bir vuruş nedeniyle kesintiye uğraması sonucu oluşmaktadır. Aritmi türleri içinde atriyumdan gelen erken atımlar PAC, ventrikülden gelen erken


atımlar PVC olarak sınıflandırılmaktadır. Şekil 2.4’de PVC’nin örnek EKG görüntüsü gösterilmektedir [46].



Şekil 2.4. PVC’nin EKG örnek görüntüleri [46].

2.3.1.4. Ektopik Atımlar

Atriyum içindeki sinüs düğümünün dışında bir alanda sinüs düğümünden daha hızlı aksiyon potansiyelleri oluştuğunda ektopik atriyal ritimler meydana gelmektedir. Ektopik atımlar, sebebi anlaşılamayan etkenlerden kaynaklı anormal atımlar olarak karşımıza çıkmaktadır. Sinoatrial düğümünden daha çok atrioventriküler kaynaklı veya sadece ventrikül kaynaklı gelişmektedir [47]. Şekil 2.5’te ektopik atımların EKG örnekleri gösterilmektedir [46].



Şekil 2.5. Ektopik atımlar EKG görüntüleri [46].

2.3.1.5. Miyokard Enfarktüsü (MI)

Miyokard Enfarktüsü (Myocardial Infarction, MI), arterlerin iç duvarlarında plakların oluşumu sonucunda kalbe giden kan akışının azalması ve oksijen yetersizliği nedeni ile kalp kaslarında yaralanma meydana gelmesine sebep olan kalp krizi için kullanılan

bir terimdir [48]. Kalp krizinde ST segmentinin çökmesi ya da yükselmesi, RBBB, LBBB ve T dalgasının yönünün değişmesi gibi durumlar EKG’de görüntülenebilmektedir [49].

2.3.1.6. Füzyon Atımı

Farklı kaynaklardan gelen elektrik impulsları aynı anda kalbin aynı bölgesine etki ettiğinde bir füzyon atımı meydana gelmektedir. İmpulslar, ventriküler odacıklar üzerinde etki ettiğinde Ventriküler Füzyon Atımları (Ventricular Fusion Beats, VFB), atriyal odacıklar üzerinde etki ettiğinde Atriyal Füzyon Atımları (Atrial Fusion Beats, AFB) meydana gelmektedir [50].

2.3.1.7. Sinüs Bradikardisi

Sinüs bradikardisi, normal hızın altında (dakikada 60 atımdan az) sinüs ritmidir. Kalp atış hızı, sempatik ve parasempatik sinir sistemleri arasında karmaşık bir etkileşimi yansıtmaktadır. Yaş ve fiziksel kondüsyon gibi birçok faktörden etkilenmektedir [51]. Şekil 2.6’ da sinüs bradikardisinin EKG örneği verilmiştir [46].




Şekil 2.6. Sinüs bradikardisi EKG örneği [46].

2.3.1.8. Taşikardi

Kalp hızı normal dinlenme hızının üzerine çıktığında meydana gelen aritmeye taşikardi denilmektedir. Yetişkin bir insanın dinlenme halindeki kalp atış hızının dakikada 100 atımın üzerine çıktığı durum taşikardi olarak kabul edilmektedir.

Üst kalp odacıklarında oluşan hızlı kalp atışına Atriyal veya Supraventriküler Taşikardi (SVT) denilmektedir [52]. Sinoatriyal düğümden kaynaklanan elektriksel uyarıların hızındaki artışa bağlı olarak sinüs ritminde artışın meydana geldiği taşikardi türüne Sinüs Taşikardisi denilmektedir [53]. 120 ms'den daha fazla bir sürede üçten daha fazla anormal QRS kompleksi ve QRS sapmasını gösteren durumlara Ventriküler Taşikardi (VT) denilmektedir [46]. Şekil 2.7'de Atriyal taşikardi örneği verilmiştir [52].



Şekil 2.7. Atriyal taşikardi örneği [52].

2.3.1.9. Atriyal Flutter (AFL)

Kalbin atriyumlarında başlayan anormal kalp ritmine Atriyal Flutter (AFL) denilmektedir. AFL ilk oluştuğunda genellikle hızlı kalp ritmi meydana gelmektedir. SVT'nin bir türü olarak sınıflandırılmaktadır [52]. Şekil 2.8'de AFL'nin EKG örneği verilmiştir [46].



Şekil 2.8. AFL'nin EKG örneği [46].

2.3.1.10. Ventriküler Flutter (VF)

Ventriküler Flutter (VF), dakikada 150-300 atım hızında ventrikülleri etkileyen kararsız bir taşikardiye sahip aritmi türüdür. Ventriküler taşikardi ile fibrilasyon arasında oluşan VF ani kardiyak ölüme neden olabilen bir geçiş aşamasıdır [54].

2.3.1.11. Ventriküler Fibrilasyon (VFİB)

Ventriküler Fibrilasyon (VFİB), ventriküllerdeki düzensiz elektriksel aktivite nedeniyle kalbin pompalamak yerine titrediği bir kardiyak aritmidir ve herhangi bir net P dalgası olmaksızın düzensiz, biçimsiz QRS kompleksleri göstermesiyle karakterize edilmektedir [55]. VFİB, hastalarda bilinç kaybı oluşturması sonucunda tedavi uygulanmadığı takdirde ani ölümler meydana gelebilmektedir [56]. Şekil 2.9'da VFİB'nin EKG örneği verilmiştir [46].



Şekil 2.9. Ventriküler fibrilasyon EKG örneği [46].

BÖLÜM 3

YAPAY ZEKA

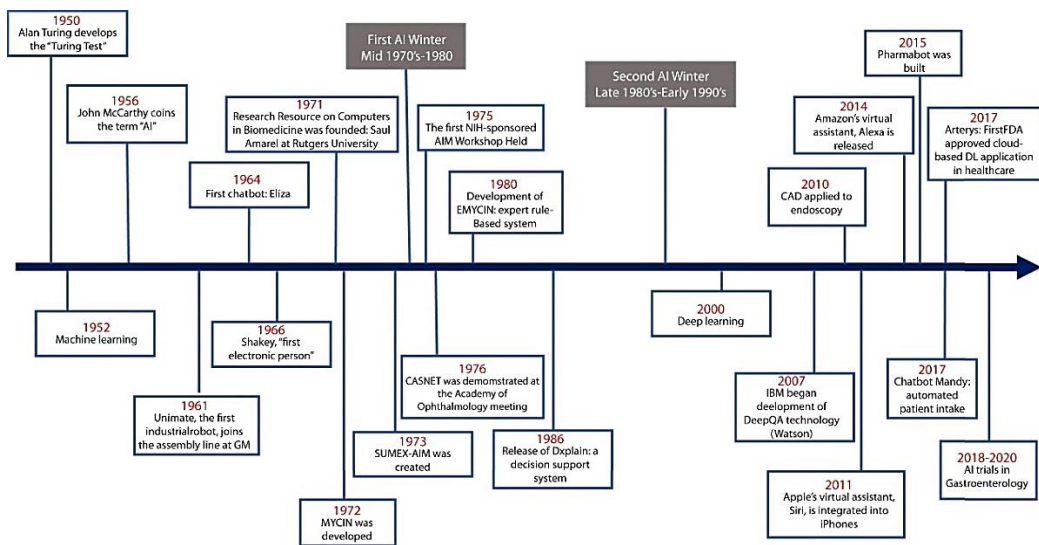
Yapay zeka, minimum insan müdahalesi ile akıllı davranışı modellemek için bir bilgisayarın kullanımını gerektiren genel bir terim olarak kullanılmaktadır [57]. Yapay zeka gerçek dünyadaki problemleri çözmek için bilişsel işlevleri taklit etmenin her yönü ile ilgilenen ve insanlar gibi öğrenerek düşünebilen sistemleri inşa eden çok geniş bir alan olarak tanımlanmaktadır [58].

Bilgisayarı, akıllı davranış ve eleştirel düşünceyi canlandırmak amaçlı kullanma kavramı 1950 yılında Alan Turing tarafından tanımlanmıştır [59]. 1956 yılında John McCarthy yapay zeka terimini “akıllı makineler yapma bilimi ve mühendisliği” olarak tanımlamıştır. John McCarthy 1956 yılında yapay zeka konulu konferans vererek yapay zekanın araştırılıp geliştirilmesi için önemli bir adım atmıştır [57]. İlk endüstriyel robot kolu (Unimate; Unimation, Danbury, Conn, ABD) 1961'de General Motors'taki montaj hattına katılmıştır ve otomatik basınçlı döküm gerçekleştirilmiştir. Unimate, adım adım komutları takip edebilmiştir [60]. 1964 yılında, Eliza, Joseph Weizenbaum tarafından tanıtılmıştır. Doğal dil işlemeyi kullanan Eliza, insan konuşmasını taklit etmek için kalıp eşleştirme ve ikame metodolojisini kullanarak iletişim kurabilmiştir (yüzeysel iletişim), gelecekteki sohbet botları için çerçeve görevi görmektedir [61]. 1966 yılında “ilk elektronik insan” olan Shakey geliştirilmiştir. Stanford Araştırma Enstitüsü'nde oluşturulan talimatları yorumlayabilen ilk mobil robot olarak karşımıza çıkmıştır. Shakey bir adımlık komutları basitçe takip etmek yerine daha karmaşık talimatları işleyebilmiş ve uygun eylemleri gerçekleştirebilmiştir [62]. 1971'de Rutgers Üniversitesi'nde Saul Amarel tarafından Biyotıpta Bilgisayarlar Üzerine Araştırma Kaynağı'nın geliştirilmesi konusunda çalışmalar yapılması için teşvik gerçekleştirilmiştir. Zaman paylaşımli bir bilgisayar sistemi Stanford Üniversitesi Tıbbi Deneysel-Tıpta Yapay Zeka 1973'te oluşturulmuş ve çeşitli kurumlardan klinik ve biyomedikal araştırmacılar arasında ağ

oluřturma yetenekleri geliřtirilmiřtir [63].1970'lerin bařında bir ‘‘geriye zincirleme’’ yapay zeka sistemi olan MYCIN geliřtirilmiřtir. Doktorlar tarafından girilen hasta bilgilerine ve yaklařık 600 kuraldan oluřan bir bilgi tabanına dayanarak MYCIN, potansiyel bakteriyel patojenlerin bir listesini saęlayabilmekte ve ardından hastanın vucut aęırlıęına gcre uygun řekilde ayarlanmıř antibiyotik tedavi seeneklerini onerebilmektedir. MYCIN, daha sonraki kural tabanlı sistem olan EMYCIN'in erevesi haline gelmiřtir [64]. Daha sonra INTERNIST-1, hekime teřhiste yardımcı olmak iin daha geniř bir tıbbi bilgi tabanı kullanılarak geliřtirilmiřtir. Zaman paylařımlı bir bilgisayar sistemi olan, Ulusal Saęlık Enstitileri sponsorluęunda Tıpta Yapay Zeka alıřtayı 1975'te Rutgers niversitesi'nde dzenlenmiřtir [65]. CASNET, yapay zekayı ilaca uygulamanın fizibilitesini gsteren ilk prototiplerden biridir. CASNET modeli, u ayrı programdan oluřan nedensel-iliřkisel bir aędır: model oluřturma, danıřma ve ortak alıřanlar tarafından oluřturulmuř ve srdrlen bir veritabanı. Bu model, belirli bir hastalık hakkındaki bilgileri hastalara bireysel olarak uygulayabilmekte ve doktorlara hasta yonetimi konusunda tavsiyeler saęlayabilmektedir. CASNET Rutgers niversitesi'nde geliřtirilmiřtir ve 1976'da Las Vegas, Nevada'daki Oftalmoloji Akademisi toplantısında resmen gsterilmiřtir [66]. 1986 yılında, bir karar destek sistemi olan DXplain, Massachusetts niversitesi tarafından piyasaya srlmüřtir [67]. Bu program, ayırıcı tanı oluřturmak iin girilen semptomları kullanmıřtır. Aynı zamanda, hastalıkların ayrıntılı tanımlarını ve ek referansları saęlayan elektronik bir tıbbi ders kitabı olarak da hizmet vermektedir. DXplain ilk ıktıęında yaklařık 500 hastalık hakkında bilgi verebilmekteydi [68].

Derin oęrenme alıřmaları ilk olarak 1950'lerde bařlamıř olmasına raęmen, tıbbi uygulanması ‘‘fazla uydurma’’ sorunuyla sınırlı kalmıřtır. Fazla uydurma, makine oęrenimi belirli bir veri kumesine ok odaklandıęında, yeni veri kmelerini doęru bir řekilde iřleyemedięinde meydana gelmektedir. Bu sınırlamalar, 2000'lerde daha byk veri setlerinin mevcudiyeti ve onemli olde geliřtirilmiř bilgi iřlem gc ile ařılmıřtır [69]. 2007'de Uluslararası İř Makineleri (International Business Machines), insan katılımcılarla rekabet eden ve televizyon yarıřma programı Jeopardy'de birincilięi kazanan Watson adında bir aık alanlı soru yanıtlama sistemi oluřturmuřtur. İleri akıl yrtme (verilerden sonulara kadar kuralları izleyen), geriye

dönük akıl yürütme (sonuçlardan verilere kuralları izleyen) veya zaman kurallarını kullanan geleneksel sistemlerin aksine, DeepQA adı verilen bu teknoloji, doğal olası cevaplar üretmek için yapılandırılmamıştır [70]. Yapay zeka destekli endoskopi, gelecek vaat eden, gelişmekte olan bir alandır. 2010 yılındaki ilk uygulamalar, neoplastik ve neoplastik olmayan kolon poliplerinin saptanması, ayırt edilmesi ve karakterizasyonu için bilgisayar destekli tanıyı (Compter Aided Diagnosis: CAD) içermektedir. Gelişmiş bilgisayar donanımı ve yazılım programlarıyla birlikte, dijitalleştirilmiş tıp daha kolay erişilebilir hale gelmiştir ve tıpta yapay zeka hızla büyümeye başlamıştır. Doğal dil işleme, sohbet robotlarını yüzeysel iletişimden meydana gelen Eliza anlamlı konuşmaya dayalı arayüzlere dönüştürülmüştür. Bu teknoloji, 2011 yılında Apple'ın sanal asistanı Siri ve 2014'te Amazon'un sanal asistanı Alex için uygulanmıştır [71]. Yapay zekanın tıbbi görüntülemeye uygulanmasının, raporlamada doğruluğa, tutarlılığa ve verimliliğin artırılmasına dayanması önerilmiştir. Arterys, 2017'de sağlık hizmetlerinde Amerika Birleşik Devletleri Gıda ve İlaç İdaresi tarafından onaylanan ilk klinik bulut tabanlı derin öğrenme uygulaması olmuştur. İlk Arterys ürünü olan CardioAI, kardiyak manyetik rezonans görüntülerini saniyeler içinde analiz edebilmiştir. Bu uygulama günümüzde karaciğer ve akciğer görüntüleme, göğüs ve kas-iskelet röntgen görüntüleri ve kafanın kontrastsız bilgisayarlı tomografi görüntülerini kapsayacak şekilde genişlemiştir [72-73]. Şekil 3.1'de tıpta yapay zekanın gelişiminin zaman çizelgesi verilmiştir [68].




Şekil 3.1. Tıpta yapay zekanın gelişiminin zaman çizelgesi [68].

3.1. YAPAY SİNİR AĞLARI (YSA)

Yapay Sinir Ağları (YSA), beyinden ilham alarak biyolojik sinir sisteminin bilgiyi işleme biçiminin modellenmesi üzerine geliştirilen teknolojidir. İnsan beyinde bilgi, nöronlar aracılığıyla transfer edilmektedir. İnsanlara ait sinir hücreleri beyinden sinyal alıp sinyal göndermekle görevlidirler. Çekirdeği içinde bulunduran bir hücre gövdesi (soma), uzun kuyruk benzeri yapıda olan akson ve somadan çıkan lifli köklere benzer yapı olan dendritler bir sinir hücresinin temel üç yapısıdır [74]. Aksonlar miyelin adında bir yapı ile çevrelenmiştir. Aksonlar elektrik sinyallerini iletme işlemini miyelin ile gerçekleştirmektedir. Dendritler anten gibi diğer hücrelerin aksonlarından sinyal almaktadırlar. Dendritlerden elde edilen bilgiler, ağırlıklandırılarak aksonlara iletilmektedir. Böylece aksonlar bilgiyi başka sinir hücrelerine transfer etmektedir [75].

YSA insan beynini modellemeyi amaçlamaktadır. Sinir hücresinde sinyal iletim işlemi matematiksel olarak Şekil 3.2’de modellenmiştir [77].



Şekil 3.2. Sinir hücresine ait sinyal ve bilgi iletim işleminin modellenmesi [77].

Şekil 3.2’ye bakıldığında, x_0 dentrite gelen giriş değeridir. Dentritte bulunan ağırlık w_0 ’dır. Bu giriş bilgileri ve ağırlıklar çarpılarak ($x_0 w_0$) sinir hücresine iletilmektedir. Tüm ağırlık ve giriş değerleri çarpılarak toplanmaktadır ($\sum_i w_i x_i + b$). Toplam sonucu tekrar bias değeri (b) ile toplanarak aktivasyon fonksiyonuyla işleme konulmaktadır. Elde edilen değer akson çıkışına aktarılmaktadır. Çıkış gerçek çıkış olabildiği gibi başka bir hücrenin giriş değeri de olabilmektedir.

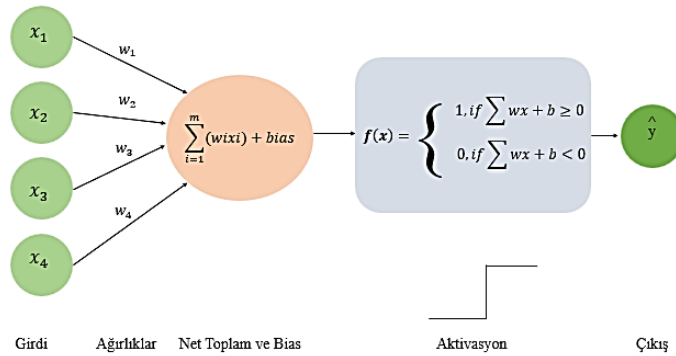
YSA katman çeşitlerine göre iki sınıfa ayrılmaktadır;

1. Giriş ve çıkış katmanlarından oluşan “tek katmanlı algılayıcılar”. Sınır ağında bulunan giriş katmanı sinyalleri alarak çıkış katmanına iletmektedir. Çıkış katmanı aldığı sinyallere göre bir çıkış sinyali üretmektedir.
2. Giriş katmanı, çıkış katmanı ve bir veya birden fazla gizli katmandan oluşan “çok katmanlı algılayıcılar”. Tek katmanlı algılayıcılardan farkı, giriş bilgileri çıkışa aktarılmadan önce gizli katmanlarda ara işlemlere tabi tutulmalarıdır [78].

3.1.1. Tek Katmanlı Algılayıcılar

Perceptron, ikili sınıflandırıcıların denetimli öğrenimi için kullanılan bir algoritmadır. Bu algoritma, nöronların eğitim setindeki öğeleri birer birer öğrenmesini ve işlemlerini sağlamaktadır. Tek katmanlı algılayıcılar doğrusal olarak ayrılabilen kalıplarda öğrenme yapabilmektedirler. Sınıflandırma işleminde sınıfları tahmin etmek için aktivasyon fonksiyonu kullanılmaktadır. Sürekli değeri tahmin edebilmek için doğrusal bir fonksiyon kullanılabilir [79].

Tek katmanlı algılayıcılar giriş katmanından ve çıkış katmanından oluşmaktadır. Giriş katmanında girdi sayısı çok fazla olabilmesine rağmen tek bir çıkıştan meydana gelmektedir. Girdi değerleri toplam fonksiyonu (\sum) ve aktivasyon fonksiyonuna tabi tutulmaktadır. Şekil 3.3’te tek katmanlı algılayıcının çalışma prensibi ve matematiksel ifadesi verilmiştir [80].



Şekil 3.3 Tek katmanlı algılayıcıların çalışma prensibi [80].

Çıktı (y) değerinin, girdi (x) değeri ile ağırlık (w) değerinin çarpılarak bias (b) değeri ile toplamından elde edildiği Eşitlik 3.1’de gösterilmiştir. Eşitlik 3.2’de tek katmanlı algılayıcıların çalışma prensibinin genel formülü verilmiştir.

$$y = w * x + b \quad (3.1)$$


$$y = \varphi(\sum_{i=1}^n w_i x_i + b) = \varphi(w^T x + b) \quad (3.2)$$

Ağırlık vektörünü w, girdi vektörünü x, bias değerini b, doğrusal olmayan aktivasyon fonksiyonunu φ temsil etmektedir. Ağırlık vektörü ve girdi vektörü çarpımından sonra bilgi iletilir, daha sonra bu etkileşim sonucundan oluşan bilgi aktivasyon fonksiyonuna iletilmekte ve bir y çıktısına dönüştürülmektedir.

3.1.2. Çok Katmanlı Algılayıcılar

Tek katmanlı algılayıcılar doğru eşik değeri verildiğinde ve (and) mantık kapısı ve veya (or) mantık kapısı problemlerini çözebilmektedir. Fakat xor mantık kapısı problemlerinde tek katmanlı algılayıcılar yetersiz kalmaktadır. Tek bir doğru ile sınıflar ayrılmadığı için birden fazla doğruya ihtiyaç duyulmaktadır. Bu sebeple çok katmanlı algılayıcı modeli geliştirilmiştir. Çok katmanlı algılayıcılarda giriş katmanı, gizli katman veya gizli katmanlar ve çıkış katmanı bulunmaktadır. Girdiler giriş katmanına verildikten sonra ileri yayılım ile etkileşim gerçekleşmektedir [78].

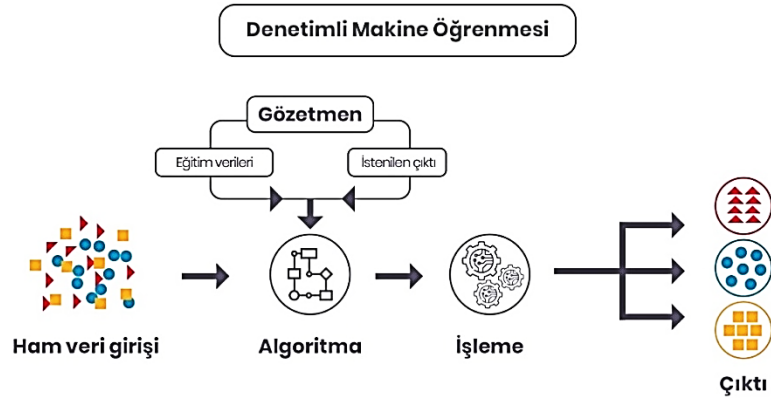
Çok katmanlı algılayıcılarda gizli katmanlarda sürekli ve türevlenebilir işlem yapılması gerekmektedir. Aktivasyon fonksiyonu seçimi yapılırken doğrusal olmayan türevlenebilir fonksiyonlar seçilmektedir. İleri yayılım aşamasında gizli katmanların çıktısı ve hata değeri hesaplanmaktadır. Geri yayılım aşamasında ise hesaplanmış olan hata değerini en aza indirmek için gizli katmanlardaki ağırlık değerleri yeniden hesaplanmaktadır [81]. Şekil 3.4’te çok katmanlı bir algılayıcı örneği verilmiştir [82].



Şekil 3.4. Çok katmanlı algılayıcı örneği [82].

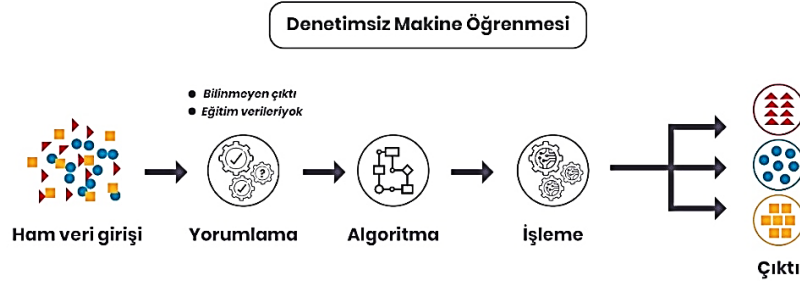
3.1.3. Denetimli ve Denetimsiz Öğrenme

Denetimli ve denetimsiz öğrenme algoritmaları büyük verilerinden bilgi edinmek için kullanılan önemli öğrenme modelleridir. Denetimli öğrenme, bir algoritmanın etiketlenmemiş durumlarını tahmin etmek için hedef veya etiketli durumlarla elde bulunan verilerden elde edilen bilgileri genelleştirebilen öğrenme şeklidir. Sınıflandırma (classification) ve regresyon yöntemleri denetimli öğrenmeyi kapsamaktadır. Sınıflandırma yöntemleri için Destek Vektör Makineleri (Support Vector Machines), Ayrıştırma Analizi (Discriminat Analysis), Naive Bayes, En Yakın Komşu (Nearest Neighbor) örnekleri verilmektedir. Regresyon yöntemleri için Lineer Regresyon, Karar Ağaçları (Decision Trees) ve YSA örnekleri verilmektedir [83]. Denetimli öğrenmede sınıflandırma işlemi yapılması için sınıf sayısı ve örnek grupta bulunan her bir örneğin hangi sınıfa ait olduğu bilinmektedir. Denetimli öğrenmede etiketli veri kümelerinin kullanıldığı bir makine öğrenimi gerçekleştirilmektedir. Veri kümelerinin tasarlanma amacı, verileri sınıflandırmak ya da sonuçları doğru bir şekilde tahmin etmek için gerekli algoritmaları eğitmek veya denetlemektir. Geliştirilen model, etiketlenmiş girdi ve çıktıları kullanarak doğruluğunu ölçerek zamanla öğrenebilmektedir [84]. Şekil 3.5'te denetimli makine öğrenmesinin örneği verilmiştir [85].



Şekil 3.5. Denetimli makine öğrenmesi örneği [85].

Denetimsiz öğrenme, etiketsiz verilerle eğitilen makine öğrenmesi şeklindedir. Denetimsiz öğrenmede veri setinin çıkış bilgileri bilinmediği için sınıflandırma problemlerinde ya da tanıma çalışmalarında kullanılmamaktadır. Denetimsiz öğrenmede sınıflandırma yaparken eldeki verilerin hangi sınıfa ait olduğu ve grup sayısı belli değildir. Eğitilen sistem, öğrenme işlemi sonucunda oluşacak yanıtı ulaşabilmek için davranış ve gerekli geri beslemeyi hesaba katmak durumundadır. Şekil 3.6’da denetimsiz makine öğrenmesi örneği verilmiştir.




Şekil 3.6. Denetimsiz makine öğrenmesi örneği [85].

Denetimsiz öğrenme, genellikle verilerin arasında benzer olanların ya da hiç benzerliği olmayanların ayrımının yapıldığı nesnelerin kümeler halinde gruplandığı kümeleme yöntemlerinde ve verilerin nitelikleri arasındaki ilişkilerin bulunduğu ilişkilendirme yöntemlerinde kullanılmaktadır [86].

Yapay sinir ağlarında öğrenmenin gerçekleşmesi için Şekil 3.7’deki gibi bir yol izlenmektedir [87]. Soldan sağa doğru işlemler ileri beslemeyi, sağdan sola doğru

yapılan işlemler ise geri yayılımı temsil etmektedir. Soldan sağa bakılacak olursa denkleme göre x giriş vektörünün w ağırlık vektörünün transpozu ile çarpımı bias değeri ile toplanarak bir z değeri elde edilmektedir. Elde edilen z değeri bir aktivasyon fonksiyonu ile işleme tabi tutulur. Örnekteki denklemden sigmoid aktivasyon fonksiyonu kullanılmıştır. Bu işlem sonucunda bir a değeri elde edilmektedir. a değeri elde edilmek istenilen y değeri ile kayıp fonksiyonuna (loss fonksiyonu) tabi tutulur ve maliyet hesabı yapılır. Amaç kayıp fonksiyonuna tabi tutularak elde edilen hata değerini minimize etmektir. Bu sebeple geri yayılım yapmak önemlidir. Geri beslemede, ileri beslemede yapılan işlemlerin tersi işlemler yapılmaktadır. İşlem sonucunda ağırlık değerleri güncellenmektedir. Yeni ağırlık değerleriyle tekrar ileri besleme yapılarak tekrar kayıp fonksiyonu değerleri hesaplanmaktadır. Bu şekilde kayıp fonksiyonunu minimize edecek şekilde ileri besleme ve geri yayılım yapılmaktadır.




Şekil 3.7. YSA'da öğrenmenin gerçekleşmesi [87].

3.1.4. Aktivasyon Fonksiyonu

Öğrenmenin gerçekleşmesinde önemli olan ileri yönde besleme yapıldıktan sonra geri yayılım yapılabilmesidir. Geri yayılımda, işlemler tersinden yapılabilmesi için kullanılan aktivasyon fonksiyonunun türevlenebilir bir fonksiyon olması gerekmektedir. Aktivasyon fonksiyonu katmanlarda kullanılmaktadır. Geri yayılımda ağırlıkların güncellenmesinde aktivasyon fonksiyonunun yapısı modelin performansını etkileyen önemli parametrelerden biridir. Türevlenemediğinde geri yayılımda besleme yapılamamaktadır [88].

Sigmoid fonksiyonu doğrusal olmayan ve sıklıkla kullanılan bir aktivasyon fonksiyonudur. 0-1 arasında değişen üstel bir fonksiyondur. Girdi ne kadar büyükse çıktı 1'e yaklaşırken, girdi ne kadar küçükse çıktı 0'a yaklaşmaktadır [88]. Şekil 3.8'de türevlenebilen lineer olmayan bir aktivasyon fonksiyonunun grafiği verilmiştir. Eşitlik

3.3'te normal sigmoid aktivasyon fonksiyonu ve Eşitlik 3.4'te sigmoid aktivasyon fonksiyonunun türevi verilmiştir. Eşitlikte verilen x parametresi sigmoid aktivasyon fonksiyonundaki giriş verilerini temsil etmektedir [89].




Şekil 3.8. Sigmoid aktivasyon fonksiyonu grafiği [89].

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

$$\frac{df(x)}{dx} = \frac{e^x}{(1+e^x)^2} \quad (3.4)$$

Hiperbolik tanjant (tanh) fonksiyonu sigmoid fonksiyonunun +1 ve -1 değerleri arasında kaydırılmış halidir. Aktivasyon fonksiyonu tanh'da ortalamanın 0 olması bazı durumlarda istenilen bir olaydır. Örneğin gelecek katman için öğrenmede kolaylık sağlamaktadır. Ara katmanda tanh fonksiyonu, çıkış katmanında sigmoid fonksiyonu öğrenme açısından kullanışlı olabilmektedir. Şekil 3.9'da tanh aktivasyon fonksiyonunun grafiği verilmiştir. Eşitlik 3.5'te tanh aktivasyon fonksiyonunun normal denklemini ve Eşitlik 3.6'da tanh aktivasyon fonksiyonunun türevi verilmiştir [89].




Şekil 3.9. Hiperbolik tanjant aktivasyon fonksiyonu grafiği [89].

$$f(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.5)$$

$$\frac{df(x)}{dx} = 1 - f(x)^2 \quad (3.6)$$

ReLU (Rectified Linear Unit) aktivasyon fonksiyonu, türemlenebilen ve doğrusal olmayan bir aktivasyon fonksiyonudur. Sigmoid ve tanh aktivasyon fonksiyonlarında, belirlenen eşik değerinden sonra türev alınmadığı için kaybolan gradyan sorunu ortaya çıkmaktadır. Bu sorunu çözmek için ReLU aktivasyon fonksiyonu geliştirilmiştir. Kaybolan gradyan sorununu çözen ReLU, negatif değer aldığı anda sıfıra karşılık geldiği için, bu noktalarda türevlenemez ve öğrenme süreci beklentinin altına düşerek yavaşlamaktadır [90]. ReLU aktivasyon fonksiyonunun en belirgin özelliği diğer aktivasyon fonksiyonlarına göre hesaplama yükünün daha düşük olmasıdır. Şekil 3.10'da ReLU aktivasyon fonksiyonunun grafiği verilmiştir. Eşitlik 3.7'de ReLU aktivasyon fonksiyonunun normal denklemi ve Eşitlik 3.8'de Relu aktivasyon fonksiyonunun türev denklemi verilmiştir [89].



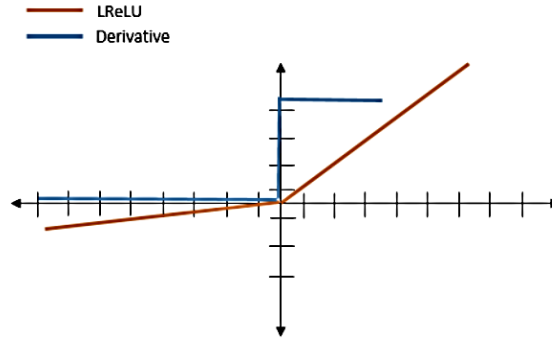
Şekil 3.10. ReLU aktivasyon fonksiyonu grafiği [89].

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.7)$$

$$\frac{df(x)}{dx} = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (3.8)$$

Öğrenmenin gerçekleşmesi için türevin sürekli sıfırdan farklı çıkması durumu Leaky ReLU aktivasyon fonksiyonunda gerçekleşmektedir. Sıfır anı hariç her durumda türevin bir sonucu bulunmaktadır. Sürekli türemlenebilmesi her aşamada öğrenmenin

gerçekleştiği anlamına gelmektedir [91]. ReLU aktivasyon fonksiyonunda meydana gelen negatif bölge sorununu çözen Leaky ReLU aktivasyon fonksiyonu, x giriş değerinin sıfırdan küçük olduğu durumlarda da Şekil 3.11’de görüldüğü gibi değer almaktadır. Eşitlik 3.9’a bakıldığında Leaky ReLU aktivasyon fonksiyonunun normal denklemi verilmiştir ve giriş değerinin sıfırdan küçük olduğu durumlarda aktivasyon fonksiyonu (α) elde edilmektedir. Eşitlik 3.10’da Leaky ReLU aktivasyon fonksiyonunun türevi verilmiştir [89].



Şekil 3.11. Leaky ReLU aktivasyon fonksiyonu grafiği [89].

$$f(x) = \begin{cases} \alpha x, & x < 0 \text{ ve } \alpha = 0.01 \\ x, & x \geq 0 \end{cases} \quad (3.9)$$

$$\frac{df(x)}{dx} = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (3.10)$$

Çok sınıflı modellerde çıkış katmanında softmax aktivasyon fonksiyonu tercih edilmektedir. İki etiketli çıkış katmanlarında sigmoid fonksiyonu kullanılırken ikiden fazla etiketli çıkış katmanında softmax fonksiyonu kullanılmaktadır [92]. Eşitlik 3.11’de softmax aktivasyon fonksiyonunun denklemi verilmiştir. Softmax fonksiyonunun girdi vektörü \vec{z} ifadesidir. Girdi vektörünün girdi değerini z_i , girdi vektörünün bütün öğelerine uygulanan eksponansiyel fonksiyonu e^{z_i} , çoklu sınıflar için sınıf sayısını j, normalizasyon işlemini $\sum_{j=1}^n e^{z_j}$ ifadesi temsil etmektedir.

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}} \quad (3.11)$$

3.2. DERİN SİNİR AĞLARI

Derin öğrenme, tıp alanında hastalık sınıflandırma, yeni hastalık fenotipleme ve biyolojik sinyallerden hastalık teşhisi gibi birçok karmaşık probleme çözüm imkanı sunan çok katmanlı bir yapay zeka yöntemidir. Derin öğrenme yöntemi, konuşma tanıma, görsel nesne tanıma, ilaç keşfi, hastalık sınıflandırma ve genomik gibi birçok alanda bilgisayar donanımı ve algoritmalarındaki yeniliklerle beraber gelişerek tıp alanındaki sorunların çözümde umut vadeden bir alan haline gelmiştir. Tek katmanlı algılayıcı modelinin doğrusal olmayan problemlerin çözümünde yetersiz kalması sebebiyle çok katmanlı algılayıcılar geliştirilmiştir ve derin öğrenme metotları uygulanmıştır. Çok katmanlı algılayıcılar, bilgi girdilerinin sağlandığı giriş katmanı, belirlenen sayıda gizli katman veya katmanlardan meydana gelen ara katman ve çıkış katmanından meydana gelmektedir [93].

Çok katmanlı algılayıcılarda derin öğrenme, önceki katmandan gelen bilgileri sonraki katmana aktarırken nasıl değiştirmesi gerektiğini hesaplayan parametreler ile birlikte ileri besleme ve geri yayılım algoritmasını uygulayarak karmaşık problemlerin çözümünde kullanılmaktadır. İleri beslemede veri setinin girdilerinin olduğu giriş katmanında girdi miktarı kadar nöron bulunmaktadır. Buradaki bilgiler gizli katmanda bulunan her bir nöronda ağırlıklandırılarak bias değeri ile toplanıp aktivasyon fonksiyonuna tabi tutulduktan sonra bir sonraki gizli katmana veya çıkış katmanına iletilmektedir [78]. Eşitlik 3.12’de verilen $z^{[l]}$ değeri, denklemde belirtildiği gibi ilgili katmandaki ağırlıklarla ($w^{[l]}$) bir önceki katmandan gelen giriş değerlerinin ($a^{[l-1]}$) çarpımının ilgili katmandaki bias değeri ($b^{[l]}$) ile toplamını ifade etmektedir [78].

$$z^{[l]} = w^{[l]} \cdot a^{[l-1]} + b^{[l]} \quad (3.12)$$

Eşitlik 3.13’te belirtilen çıkış katmanındaki çıkış bilgisi ($a^{[l]}$) ilgili katmandaki $z^{[l]}$ değeri ile $g^{[l]}$ aktivasyon fonksiyonunun çarpma işlemine tabi tutulması ile elde edilmektedir [78].

$$a^{[l]} = g^{[l]}(z^{[l]}) \quad (3.13)$$

Derin sinir ağlarında ileri besleme ve geri yayılım yapılırken sistem aynı şekilde fakat biraz daha karmaşık yapıdadır. Yapay sinir ağında elde edilen çıktı değerleriyle başlangıçta beklenen çıktı değerleri karşılaştırılacağı için çıkış katmanında belirtilen nöron sayısı ile veri setinde bulunan çıktı sayısı aynı olmak durumundadır. Eşitlik 3.14'te hata değerinin ($e_j(n)$) hesaplaması verilmiştir. Çıkış hücresinin konumu j , eğitim verisinin konumu n $d_j(n)$ ise beklenen çıktı değerini ifade etmektedir [78].

$$e_j(n) = d_j(n) - y_j(n) \quad (3.14)$$

Çıkış katmanında toplam hata $E(n)$ değerinin hesaplanması Eşitlik 3.15'te verilmiştir ve C çıkış katmanındaki toplam nöronları ifade etmektedir [78].

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (3.15)$$

Çıkış katmanına giriş katmanından gelen girdilerin toplamı ($v_j(n)$) Eşitlik 3.16'da verilmiştir ve $X = (x_1, \dots, x_n)$, j . nörona kaç tane değer (m) girildiğini, w_j ağırlığı, x_i girdi değerini, f aktivasyon fonksiyonunu ifade etmektedir [78].

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)x_i(n) \quad (3.16)$$

Çıktı hücrelerinde elde edilen sonuç $y_j(n)$ Eşitlik 3.17'de ifade edilmiştir [78].

$$y_j(n) = f(v_j(n)) \quad (3.17)$$

BÖLÜM 4

EKG SİNYAL SINIFLANDIRMASINDA YAPILAN ÇALIŞMALAR

Derin öğrenmeye dayalı çalışmalar son yıllarda daha da önem kazanmıştır. Özellikle sağlık alanında hastalık sınıflandırmak için makine öğrenmesine karşı derin öğrenme çalışmaları yapılarak avantajları ve dezavantajları değerlendirilmiştir. Makine öğrenmesinde özellik çıkarma işlemleri manuel bir şekilde yapılmaktadır. Manuel olarak özellik çıkarmak, sınıflandırma kısmına gelindiğinde bazı özelliklerin kaybolmasına sebep olmaktadır. Sınıflandırmada önemli özelliklerin kaybolması istenilmeyen bir durumdur. Verilerin yapaylık veya parazit içermesi manuel olarak özellik çıkarma aşamasını çok karışık bir hale getirmektedir. Manuel özellik çıkarmak küçük verilerde kolay olmasına karşı büyük çaptaki verilerde durumu daha da zorlaştırmaktadır. Bu tür sorunlardan dolayı hastalık sınıflandırmada derin öğrenme yaklaşımları son yıllarda daha çok tercih edilmeye başlanmıştır. Derin öğrenmeye dayalı sistemlerde özellik çıkarma işlemi otomatik olarak yapılmaktadır. Derin öğrenmede, otomatik olarak özellik çıkarılması sayesinde insan kaynaklı hatalar ortadan kaldırılarak daha iyi performanslar elde edilmiştir. Ayrıca, önemli verilerin kaybolması problemi, karmaşık verilerden özellik çıkarma problemi, çok büyük boyutlardaki verilerin sınıflandırılması zorluğu gibi birçok problem derin öğrenme yaklaşımı ile çözülmüştür. Derin öğrenme yaklaşımlarındaki amaç üst düzey özellikleri öğrenerek en iyi sınıflandırmayı yapmaktır [92].

Kumar vd. (2014), veri setinde bulunan özellikleri karıştırarak EKG vuruş sınıflandırması için Çok Katmanlı Algılayıcı Yapay Sinir Ağı (MLPNN) kullanmışlardır. S-dönüşümüne dayalı öznitelikler ile zamansal öznitelikler hesaplanarak bir veri seti oluşturulmuştur. Zamansal öznitelikler, ST ve WT temelli özniteliklerdir. Yapılan çalışmada N, S, V, F ve Q olmak üzere beş sınıf için ST + Temporal öznitelik çıkarımında accuracy değeri %96.90 hesaplanırken ST +WT + Temporal öznitelik çıkarımında bu değer %97.50 olmuştur [94].

Kiranyaz vd. (2015), öznitelik çıkarma ve sınıflandırmayı tek bir öğrencide birleştirerek, 1D CNN yaklaşımı ile hastaya özgü sınıflandırma yapıp izleyebilmek için bir sistem önermişlerdir. Sistemdeki tüm eğitim ve test kayıtları için ventriküler ektopik atımları (VEB) sınıflandırmada accuracy değeri %99.00 hesaplanırken, supraventriküler ektopik atımlarını (SVEB) sınıflandırmada accuracy değeri %97.60 olarak hesaplanmıştır [95].

Xiong vd. (2017), AF tespiti için yapay sinir ağlarını kullanmışlardır. AF sınıfının içinde bulunduğu bir veri seti ile çalışarak 16 katmanlı bir CNN mimarisi tasarlamışlardır. Yapılan çalışmada CNN ile elde edilen sonuçları karşılaştırmak için RNN ve spektrogram öğrenimi de uygulamışlardır. Dört sınıflı bir çalışma yapılmış olup, yapılan çalışma sonucunda CNN mimarisinde accuracy değerini %90.00 hesaplayarak RNN ve spektrogram öğrenimine göre daha iyi sonuç elde etmişlerdir [96].

Li vd. (2017), 1D CNN tabanlı bir sinir ağı modeli ile EKG veri setinde sinyalleri beş sınıfta sınıflandırmışlardır. CNN modelini toplamda beş katmanlı bir sistem haline getirip accuracy değerini %97.50 elde etmişlerdir [97].

Li vd. (2018), bilgi füzyon ve one-hot encoding teknikleri kullanarak bir CNN mimarisi tasarlayıp EKG veri setinde sınıflandırma yapmışlardır. Geliştirilen model kardiyak aritmi teşhisi için etkili olmuştur. Ortalama accuracy beş ve sekiz kalp atışı kategorisinde sırasıyla %99.10 ve %97.00 olarak belirlenmiştir [98].

Yıldırım (2018), EKG sinyallerini sınıflandırmada DBLSTM-WS adında çift yönlü bir LSTM yapay sinir ağını kullanarak dalgacık dizilerini oluşturmak için dalgacık tabanlı yeni katman kullanmıştır. Bu yeni katman ile frekanslar farklı ölçeklerde alt bantlarına ayrıştırılmıştır. Çalışmada kullanılan model ile %99.39 accuracy değeri hesaplanmıştır [99].

Baloğlu vd. (2019), yaptıkları çalışmada MI teşhis etmek amacıyla bir derin öğrenme modeli geliştirmişlerdir. Standart 12 derivasyonlu EKG sinyalini uçtan uca (end to

end) yapıya sahip bir CNN modeli ile sınıflandırma yapmışlardır ve accuracy değerini %99.78 olarak hesaplamışlardır [100].

Shaker vd. (2020), 15 sınıflı bir EKG veri seti ile çalışmış olup veri kümesinde dengesiz veriler için veri artırma tekniği kullanmışlardır. CNN yapılarını kullanarak %98.30 accuracy değeri elde etmişlerdir. Yaptıkları çalışmada veri artırımı ile accuracy değerinin arttığını gözlemlemişlerdir [101].

Varlı (2021), biyolojik sinyallerin sınıflandırılması için CNN ve LSTM yapılarını içeren bir derin öğrenme modeli geliştirip, ikili sınıflandırmada %99.47 accuracy değeri elde etmiştir [92].

Mousavi vd. (2021), EKG sinyallerini analiz etmek için EKG Dil İşleme (ELP) adında yeni bir teknik geliştirmişlerdir. CNN, RNN ve RNN-Attention mimarilerinin üçü için sırasıyla buldukları accuracy değerleri %97.00, %96.96, %97.00 'dır [102].

Şehirli vd. (2021), yaptıkları çalışmada QRS kompleksinin EKG sinyalleri üzerinde segmentasyonu ve KVH makine öğrenmesine dayalı sınıflandırılması için yeni hibrit bir model geliştirmişlerdir. MIT-BIH Aritmi veritabanında yedi farklı sınıf içeren EKG sinyali ile çalışarak DT, KNN, RF, NB, LDA, SVM gibi çeşitli makine öğrenmesi algoritmaları ile hibrit bir yapı oluşturup her sınıf için performans değerlendirme metrik değerleri hesaplamışlardır. Yapılan çalışmada geliştirilen hibrit model ile %92.41 accuracy değeri hesaplanmıştır [103].

BÖLÜM 5

MATERYAL VE YÖNTEM

Materyal ve yöntem bölümünde, bu tez çalışmasında kullanılan veri seti bilgileri, veri ön işleme aşamaları, modellerde kullanılan derin öğrenme yapıları, oluşturulan CNN ve LSTM modellerinin yapıları, hiper parametre optimizasyonu ve modellerin ölçüm parametreleri açıklanmıştır.

5.1. VERİ SETİ

Bu tez çalışmasında EKG sinyallerini elde etmek için Python uyumlu ve Physio.net (<http://www.physionet.org>) adresinden ulaşılan MIT-BIH aritmi veri seti kullanılmıştır [104, 105]. Çizelge 5.1’de veri seti sınıf bilgileri verilmiştir.

Çizelge 5.1. Veri seti sınıf bilgileri.

Sınıf	MIT-BIH kalp atışı türleri
N	Non-ecotic beats (normal beats)
S	Supraventricular ectopic beats
V	Ventricular ectopic beats
F	Fusion beats
Q	Unknown beats

Veri seti, 1975 ve 1979 yılları arasında BIH Aritmi Labaratuvarı tarafından incelenen 47 denekten elde edilen iki kanallı ayaktan EKG kayıtlarının 48 yarım saatlik alıntılarını içermektedir. EKG verilerinin örnekleme frekansı 125 Hz.’dir.

Veri setinde, Boston'daki Beth Israel Hastanesinde yatan hastaların kayıtlarından yaklaşık %60'ı, geri kalan kısım için karma popülasyondan toplanan ayakta tedavi gören hastalardan saatlik olarak alınan EKG kayıtlarından yaklaşık olarak %40'ı ve ek olarak rastgele bir şekilde anlamlı aritmileri içerecek şekilde aynı gruplardan 25 kayıt seçilmiştir.

Çizelge 5.2'de bu tez çalışmasında kullanılan N, S, V, F ve Q sınıflarına ait fragment dağılım bilgileri verilmiştir.

Çizelge 5.2. Veri seti sınıf dağılım bilgileri.

Veri seti	N	S	V	F	Q	Toplam
MIT-BIH aritmi	90,589	2,779	7,236	803	8,039	109,446

5.2. VERİ ÖN İŞLEME

MIT-BIH aritmi veri setinde toplamda beş sınıf ile çalışma yapılmıştır. Veri setinde veri dağılımına bakıldığında F ve S sınıfı diğer sınıflara göre oldukça düşük sayıdadır. Bu yüzden model oluşturulmadan önce veri setinde çeşitli çalışmalar yapılmıştır. F ve S sınıfı "Others" isminde, her iki sınıftan 803'er tane fragment çekilerek toplamda 1606 fragmentten oluşan yeni bir sınıf olarak değerlendirilmiştir. N, V ve Q sınıflarından da aynı şekilde 1606 fragment ile veri seti hazırlanmıştır.

Çizelge 5.3'te N, S, V, F ve Q sınıflarına ait veri ön işlemeden sonraki fragment dağılım bilgileri verilmiştir.

Çizelge 5.3. Veri ön işleme sonrası veri seti sınıf dağılım bilgileri.

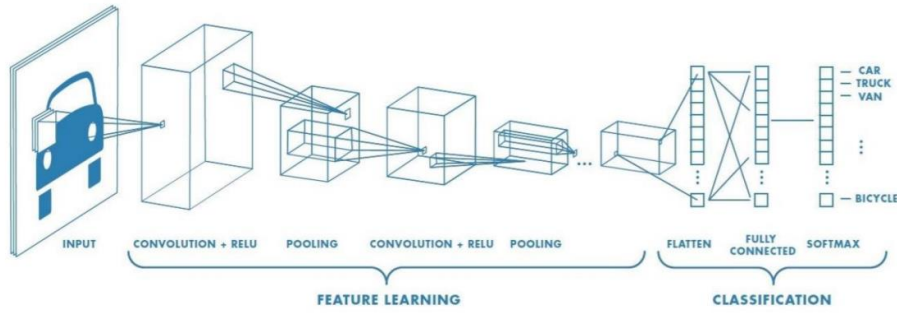
Veri seti	N	V	Q	Others	Toplam
MIT-BIH aritmi	1,606	1,606	1,606	1,606	6,424

Her bir sınıfı belirleyebilmek amacıyla model çalıştırılıp sonuçlar elde edildikten sonra performans değerlendirme metrikleri karşılaştırılarak yüksek olan sınıf veri setinden çıkarılarak CNN ve LSTM modellerinde tekrar çalıştırılmıştır. Bunlara ek olarak F ve S sınıfı için modeller ikili sınıflandırma yaparak tekrar çalıştırılmıştır.

Çalışmanın amacı tüm sınıflarda yüksek accuracy değerlerini tespit etmek olduğu için, veri seti farklı sınıflar ile tekrar tekrar oluşturulmuştur.

5.3. EVRİŞİMLİ SİNİR AĞLARI (CNN)

CNN, sinyaller ve diziler için 1D, görüntü veya ses spektrogramları için 2D, video ya da hacimsel görüntüler için 3D gibi çeşitli boyutlardaki verileri işlemek amacıyla tasarlanmış, bir veya daha fazla katmana sahip olabilen, katmanlarının en az birinde matris çarpımı ya da evrişim işlemi uygulanan derin öğrenme modelidir. CNN mimarilerinin giriş değerlerinin tutulduğu bölümden sonra, Evrişim Katmanı, Aktivasyon Katmanı, Havuzlama Katmanı, Flatten Katmanı ve FC Katmanı gibi çeşitli görev ve niteliklerde katmanları barındırmaktadır [106]. Şekil 5.1’de CNN ve yapılarının genel gösterim örneği verilmiştir [107].



Şekil 5.1. CNN genel gösterim [107].

Evrışim Katmanı: CNN yapılarındaki katmanların içinde en önemli katman olarak kabul edilmektedir. Bu katmanı önemli kılan, özel doğrusal işlem türü olan evrişim işlemi olarak karşımıza çıkmaktadır. Evrişimde temel amaç, görüntü verilerini özellik haritasına dönüştürerek matematiksel anlamda iki fonksiyon üzerinden üçüncü fonksiyon üretebilmek için yapılan işlemleri kapsamaktadır. CNN yapılarında görüntü üzerinde çeşitli işlemleri başlatan katmana evrişim katmanı denilmektedir. Belirli piksel değerleri olan görüntülerden matrisler elde edilmektedir. Görüntü matrisine karşılık daha küçük boyutlarda olan filtre ya da kernel matrisleri ile görüntünün düşük ya da yüksek seviyeli özellikleri ortaya çıkarılmaktadır.

Filtre matrisleri çoğunlukla 3x3, 5x5, 7x7 boyutlarında değerler alabilmektedir. Boyutu belli olan görüntüye daha küçük boyutlarda bir filtre matrisi sol köşeden uygulanarak görüntü üzerinde kaydırılmaktadır. Filtre matrisiyle bu işlem görüntünün tamamında gezdirilmektedir. Bu sürede filtre matrisine ait değerler ile görüntü matrisine ait değerler indis sayılarına göre çarpıma tabi tutulmaktadır. Sonuçlar toplanarak yeni bir matris olan çıktı matrisine kayıt edilmektedir. Görüntü özelliklerinin çıkarılması amacıyla yapılan bu işlemler sonucunda Özellik Haritası (Feature Map) elde edilmektedir. CNN modeli özellik çıkarma işlemini sürekli olarak tekrar ederek güncellemekte ve en iyi özellikleri çıkarmayı hedeflemektedir. Evrişim katmanında görüntülere keskinleştirme, gürültü ekleme ve kenar tespiti yapma gibi çeşitli işlemler de uygulanabilmektedir [92].

Temelde işlenecek olan görüntünün filtre ile kaydırma işleminde ilerleme sayısını veren işlem adım değeridir. Adım değeri özellik haritasının boyutunu etkileyen bir değerdir. Adım değeri büyümesi sonucunda özellik haritası daha çok kayacağı için boyutu küçülecektir [108].

Görüntüye uygulanan filtreler sonucunda görüntünün orjinal boyutlarında değişimler olacaktır. Filtre uygulansa da görüntü üzerindeki önemli bilgileri kaybetmemek için piksel doldurma (padding) işlemi yapılabilmektedir. Bu amaçla girdi görüntüsü ile çıktı görüntüsünün boyutlarının aynı olabilmesi için yapılan işlem padding işlemidir. Padding işleminde mantık görüntü etrafına sıfırların eklenmesiyle boyutun artırılmasıdır [108].

Kırmızı-Yeşil-Mavi (Red-Green-Blue, RGB) gibi üç kanallı görüntülerin her bir kanalına evrişim işlemi uygulanmakta ve bias değeri ile toplandıktan sonra çıktı matrisi elde edilmektedir. Eşitliklerde evrişim işleminin matematiksel gösterimi vardır. Eşitlik 5.1’de ve 5.2’de evrişim işleminde yapılan hesaplamaların aşamaları verilmiştir ve f ile giriş görüntüsü, h ile filtre ifade edilmektedir [92].

$$G[m, n] = (f * h)[m, n] \quad (5.1)$$

$$G[m, n] = \sum_j \sum_k h[j, k]f[m - j, n - k] \quad (5.2)$$

Aktivasyon Katmanı: Aktivasyon katmanı CNN modelinde sinir ağlarının arasına ya da sonuna konulan bir nöronu etkinleştirme işlemidir. Bu işlem giriş sinyaline yapılan doğrusal olmayan aktivasyon fonksiyonları sayesinde gerçekleştirilmektedir. Çalışma modelinde ReLU aktivasyon fonksiyonu sinir ağlarının arasında kullanılmıştır. ReLU aktivasyon fonksiyonunun tercih edilme sebebi tüm nöronları aynı ana aktif hale dönüştürmediği için, her seferinde birkaç nöronu etkinleştirerek hesaplama açısından avantaj sağlamasıdır. Çünkü şekildeki ReLU aktivasyon fonksiyonunun grafiğine bakılacak olunursa, negatif girdileri sıfıra dönüştüren bir fonksiyon olduğu anlaşılmaktadır. ReLU aktivasyon fonksiyonunda gradyanın sıfır olması sorunu negatif alanda doygun olmasından kaynaklanmaktadır. Bu sorunun çözümü için Leaky ReLU kullanılabilir [89].

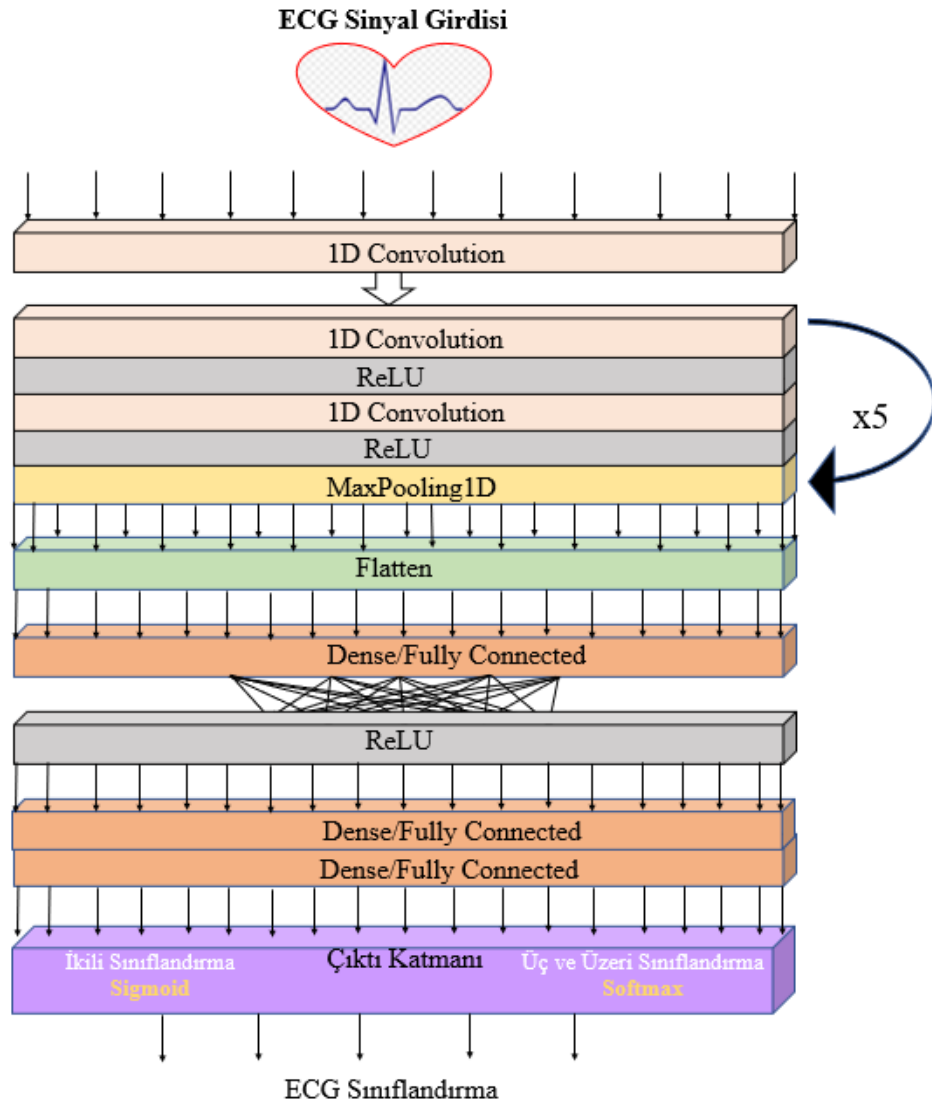
Havuzlama (Pooling) Katmanı: Öğrenme aşamasında fazla uydurmayı önlemek amacıyla evrişim katmanları arasında kullanılmaktadır. Çalışma mantığı evrişim katmanına benzemektedir. Havuzlama katmanı olan bir CNN modelinde hem parametre hem de hesaplama sayısının azaltılması hedeflenmektedir. Max Pooling ve Average Pooling (ortalama havuzlama) olmak üzere iki önemli havuzlama yöntemi mevcuttur. Max Pooling yöntemi ile görüntü üzerinde daha küçük boyutta olan kayan filtre aracılığıyla bulunduğu kısımdaki maksimum parametre alınarak çıkış matrisine iletilmektedir. Geçmiş yıllarda yöntemi Average Pooling daha yaygın kullanılsa da gürültü azaltma yeteneği sayesinde son zamanlarda Max Pooling daha yaygın kullanılmaktadır [109]. Bu tez çalışmasında Max Pooling havuzlama yöntemi kullanılmıştır.

Flatten Katmanı: Havuzlama işleminden sonra modelde kullanılan flatten katmanı ile havuzlanmış özellik haritasının düzleştirildiği yani bir sütun haline getirildiği katmandır. Görüntü verileri bu katmanda tek bir dizi haline gelmektedir.

FC Katmanı: FC katmanı, flatten katmanından gelen verilerle tam bağlantıya sahip olan katmandır.

Bu tez çalışmasında derin sinir ağlarının CNN ve LSTM yapılarının her ikisi de kullanılmıştır. CNN modeli, evrişim, ReLU, MaxPooling, Flatten, FC ve çıkış

katmanından oluşan 11 katmanlı bir model olarak geliştirilmiştir. Model, CNN katmanı EKG girdisine uygulandıktan sonra accuracy değerlerini daha iyi elde edebilmek için beş kez tekrar eden bir sıralama ile oluşturulmuştur. Çıktı katmanında ikili sınıflandırma yapabilmek için sigmoid aktivasyon fonksiyonu, üç ve üzeri sınıflandırma yapabilmek için ise softmax aktivasyon fonksiyonu seçilmiştir. CNN modelinde optimizör Adam, loss categorical_crossentropy olarak seçilmiştir. Bu tez çalışmasında geliştirilen CNN model blok diyagramı Şekil 5.2’de gösterilmiştir. Çizelge 5.3’te bu tez çalışmasında geliştirilen CNN modelinin bloğu için kullanılan parametrelerin bilgisi verilmiştir.



Şekil 5.2. CNN modeli blok diyagramı.

Çizelge 5.4. CNN modelinin yapısı.

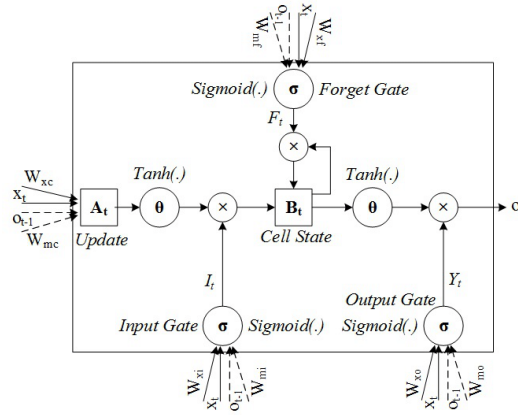
Layer	Type	Kernel size	Filters	Stride	Padding
1	Conv1D	5x5	32	1	-
2	Conv1D	5x5	32	1	same
	ReLU	-	-	-	-
3	Conv1D	5x5	32	1	same
	ReLU	-	-	-	-
	MaxPooling1D	5x5	-	2	-
4	Conv1D	5x5	32	1	same
	ReLU	-	-	-	-
5	Conv1D	5x5	32	1	same
	ReLU	-	-	-	-
	MaxPooling1D	5x5	-	2	-
6	Conv1D	5x5	32	1	-
	ReLU	-	-	-	-
7	Conv1D	5x5	32	1	same
	ReLU	-	-	-	-
	MaxPooling1D	5x5	-	2	-
8	Conv1D	5x5	32	1	same
	ReLU	-	-	-	-
9	Conv1D	5x5	32	1	same
	ReLU	-	-	-	-
	MaxPooling1D	5x5	-	2	-
10	Conv1D	5x5	32	1	same
	ReLU	-	-	-	-
11	Conv1D	5x5	32	1	same
	ReLU	-	-	-	-
	MaxPooling1D	5x5	-	2	-

5.4. UZUN KISA VADELİ BELLEK (LSTM)

RNN'nin bir türü olan LSTM, doğal davranış girdilerini uzun süre hatırlamak amacıyla özel gizli birimler kullanan derin sinir ağı modelidir. LSTM modeli önemli sayılabilecek bilgileri ağ boyunca iletip saklayan hafıza hücresine sahiptir.

RNN, zaman serisi şeklinde ifade edilen problemlerde çözüm olarak kullanılan bir derin sinir ağı modelidir. Ses zamanla meydana gelen bir girdi olduğu için özellikle doğal dil işleme ve konuşma gibi sıralı girdiler için RNN modelini kullanmak daha avantajlıdır. RNN yapılarında giriş dizisi her döngüde öge olarak işlenir ve gizli birimlerde dizinin geçmiş öğelerinin geçmişi hakkında örtük olarak bilgi içeren durum vektöründe tutulur. Bunun anlamı klasik derin öğrenme modellerinde giriş ve çıkışların birbiriyle bağlantısının olmamasına karşı RNN yapılarında girdiler arasında bağlantı olmasıdır. Hafıza yeteneğine sahip RNN'ler karar verme aşamasında daha önceden aldığı girdiden öğrendikleriyle mevcut olan girdiyi birlikte kullanmaktadır. Bu nedenden dolayı RNN'lerin kısa süreli hafıza karmaşık problemlerin çözümünde yetersiz kalabilmektedir [106]. Derin öğrenme modellerinde ileri beslemede yapılan toplama ve çarpım işlemleri, geri yayılımda ise türev işlemleri olarak karşımıza çıkmaktadır. Kullanılacak aktivasyon fonksiyonunun türevinin sıfır olması halinde öğrenme gerçekleşmemektedir. Bu olaya gradyanların yok olması problemi denilmektedir. RNN yapıları güçlü dinamik yapılar olduğu için geri yayılımda gradyanlar her zaman adımında büyüyebilir ya da küçülebilirler. Bu sebeple RNN 'de gradyanların yok olması problemi görülebilmektedir. RNN yapılarında oluşan problemlerin sonucu olarak zayıf performans, düşük doğruluk ve uzun eğitim süresi görülebilmektedir. RNN'ler tüm katmanlarda aynı ağırlıklar paylaştığı için çok derin sinir ağı olarak görülebilmektedir. RNN'lerde gradyanların yok olması problem ve bilgiyi uzun süre hafızada saklayamaması problemine çözüm sunmak amacıyla LSTM modeli geliştirilmiştir.

RNN'lerdeki unutma problemine çözüm sunmak için faydalı ya da silinmesi gereken bilgileri belirleyen üç çeşit kapı bulunmaktadır. Kapılar sayesinde bilgilerde RNN'e göre daha az değişim olmaktadır. Şekil 5.3'te LSTM modelinde bulunan giriş kapısı (input gate), çıkış kapısı (output gate), unutma kapısı (forget gate) ve güncelleme (update) bölümlerinin bulunduğu bir LSTM örneği verilmiştir [110].



Şekil 5.3. LSTM model diyagramı [110].

Unutma Kapısı: Bu kapı, hangi bilgilerin önemli olduğuna, önemli olan bilgilerin saklanması gerektiğine ve önemsiz bilgilerin ise unutulacağına karar vermektedir. Önemsiz gördüğü bilgileri nöronun hücrelerinden atmaktadır. Kapıda iki girdi bulunmaktadır; biri önceki hücreden üretilen bilgi değeri mevcut hücrenin girdisi. Bu bilgiler formüldeki gibi ağırlıklı çarpılıp bias değeri ile toplanarak sigmoid fonksiyonuna tabi tutulmaktadır. Aktivasyon fonksiyonu sayesinde 0 ile 1 arasında bir değer üretilmektedir. 1 değeri bilginin önemli olduğunu ve saklanması gerektiğini, 0 değeri ise bilginin önemsiz olduğunu ve unutulması gerektiğini göstermektedir [92].

Giriş Kapısı: Nörona bilgi eklemek için kullanılan kapı olarak isimlendirilmektedir. Aktivasyon fonksiyonuna tabi tutularak nörona eklenmesi gereken değerleri belirleyen kapıdır ve tanh işlevini kullanarak eklenmesi gereken bilgilerden bir dizi oluşturur. Aktivasyon fonksiyonu olan tanh görevi -1 ve +1 arasında bir değeri üreterek karar mekanizması oluşturmaktadır. Sigmoid fonksiyonu bu kapıda filtre görevi görür ve eklenmesi gereken bilgileri düzenler [111].

Çıkış Kapısı: Kapılarda görevler bilgilerin önemini belirlemektir. Çıktı kapısı da hücreden önemli bilgileri seçerek çıktı haline getirmekten sorumlu kapıdır. Çıkış kapısı mevcut hücre için, önceki hücreden gelen bilgi ile sonraki hücrenin giriş bilgisini belirleyen kapıdır. Eşitlik 5.3'te giriş kapısı (I_t), Eşitlik 5.4'te unutma kapısı (F_t), Eşitlik 5.5'te çıkış kapısı (Y_t), Eşitlik 5.6'da giriş kapısının ve giriş otomatik regresyon değeri (A_t), Eşitlik 5.7'de hafıza hücresinin değeri (B_t) ve Eşitlik 5.8'de çıkış değerini (O_t) göstermektedir.

Girdi deęerini x_t , bir önceli LSTM bloęunun çıktı deęerini o_{t-1} , sigmoid aktivasyon fonksiyonunu σ , tanh aktivasyon fonksiyonunu θ ifade etmektedir. Bulunduęu kapı için bias deęerini b_x , bulunduęu kapıya göre aęırlığı W_x ifade etmektedir [110].

$$I_t = \sigma(W_{xi}x_t + W_{mi}o_{t-1} + b_i) \quad (5.3)$$

$$F_t = \sigma(W_{xf}x_t + W_{mf}o_{t-1} + b_f) \quad (5.4)$$

$$Y_t = \sigma(W_{xo}x_t + W_{mo}o_{t-1} + b_o) \quad (5.5)$$

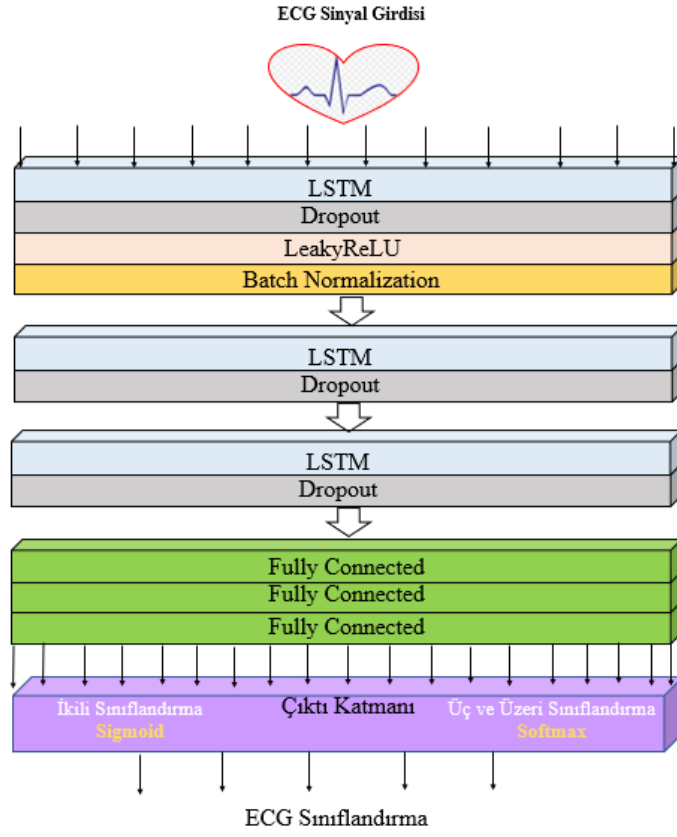
$$A_t = W_{xc}x_t + W_{mc}o_{t-1} + b_c \quad (5.6)$$

$$B_t = F_t * B_{t-1} + I_t * \theta(A_t) \quad (5.7)$$

$$o_t = Y_t * \theta(B_t) \quad (5.8)$$

Bu tez çalışmasında LSTM, Dropout, LeakyReLU, Batch Normalization, FC ve çıktı katmanlarından oluşan üç katmanlı bir LSTM modeli geliştirilmiştir. Modelde, çıktı katmanında ikili sınıflandırma yapabilmek için sigmoid aktivasyon fonksiyonu, üç ve üzeri sınıflandırma yapabilmek için ise softmax aktivasyon fonksiyonu seçilmiştir. LSTM modelinde optimizer Adam, loss ise categorical_crossentropy olarak seçilmiştir. Türevin sıfır olduęu yerlerde gradyanların yok olması problemini çözebilmek ve önemli bilgileri kaybetmemek için aktivasyon katmanında ReLU yerine Leaky ReLU seçilmiştir.

Şekil 5.4'te bu tez çalışmasında geliştirilen LSTM modelinin blok diyagramı verilmiştir. Çizelge 5.4'te bu tez çalışmasında geliştirilen LSTM modelinin bloęu için kullanılan parametrelerin bilgisi verilmiştir.



Şekil 5.4. LSTM modeli blok diyagramı.

Çizelge 5.5. LSTM modelinin yapısı.

Layer	Type	Parameter
1	LSTM	384
	Dropout	0.1
	LeakyReLU	-
	Batch Normalization	-
2	LSTM	384
	Dropout	0.2
3	LSTM	384
	Dropout	0.3
FC_RNN	Dense	128
FC_RNN	Dense	64
FC_RNN	Dense	32

5.5. HİPER PARAMETRE OPTİMİZASYONU

Hiper parametre optimizasyonu, iyi sonuçlar veren bir hiper parametre modelini anlamlandıran problem ya da grafik yapıları konfigürasyon alanı üzerinde bir kayıp fonksiyonunu optimize etme problemi şeklinde tanımlanabilir. Derin öğrenme modeli oluştururken kullanıcı tarafından çeşitli parametre değerleri manuel olarak ayarlanmaktadır [101].

CNN modelinde ağ yapısını Kernel Size, Kernel Type, Stride, Padding, hidden layer, aktivasyon fonksiyonu gibi hiper parametreler belirlemektedir. Eğitilmiş ağı etkileyen hiper parametreler ise: Öğrenme oranı, momentum, epoch sayısı, batch size'dır [101]. Modelde filtre boyutu (Kernel size) beş, evrişim katmanında strides bir, padding ise same olarak seçilmiştir. Padding'de iki seçenek vardır: sama ve valid. Valid seçildiğinde giriş görüntüsü doldurulmamaktadır. Eğer padding valid olarak belirlenirse filtre penceresi giriş görüntüsü içinde kalmaktadır. Bunun anlamı, sadece giriş görüntüsündeki original öğeleri dikkate aldığı için bilgi kaybolabilir. Pading same olarak strides değeri de bir olarak seçilirse eğer çıktı boyutu girdi boyutuyla aynı olmaktadır. Böylece filtre girişin tüm öğelerine uygulanır.

Aktivasyon fonksiyonu çıktıyı etkileyen bir hiper parametredir. CNN modelinde tanh, sigmoid, ReLU ve Leaky ReLU aktivasyon fonksiyonları denenmiştir. Modelde evrişim katmanından sonra ReLU aktivasyon fonksiyonunun uygulandığı bir katman eklenmiştir. ReLU fonksiyonu tüm nöronları etkinleştirdiği için eğitim süresinde avantaj sağlamıştır.

LSTM modelinde üç kez dropout kullanılmıştır. Dropout değerleri 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7 ve 0.8 olarak denenmiş olup LSTM modelinde sırasıyla 0.1, 0.2 ve 0.3 olarak belirlenmiştir.

Optimize işlemi için, Adam, Nadam, Adamax çeşitleri CNN ve LSTM modelinde denenmiştir. Bu tez çalışmasında her iki modelde de Adam optimizasyonu ile yapılan model değerlendirilmiştir. İki model için batch size 8, 16 ve 32 şeklinde denenmiştir.

Epoch sayısı hem CNN hem LSTM modelinde N-V-Q-Others, N-V-Q, S-F, N-V sınıf kombinasyonlarında 30-50-100 olarak her biri için ayrı ayrı denenmiştir. Toplamda 24 farklı şekilde modeller eğitilmiştir. Epoch sayısı arttıkça eğitim süresi uzamıştır. Epoch sayısının sınıflandırma sonucunda model performans değerlendirme skorlarına iyi ya da kötü şeklinde net bir etkisi yoktur. Sonuçlara bakıldığında bazen düşük epoch değerinde iyi sonuçlar alınırken bazen yüksek epoch değerinde sonuçlar alınabilmektedir. Düşük epoch değerine göre biraz daha yükseği olumlu sonuç verirken belli bir sayıdan sonra kötü sonuç verebilmektedir.

CNN modeli toplamda 11 katmandan oluşmaktadır. Her bir katmanda nöron sayısı 32, 64, 128 ve 256 şeklinde çeşitli kombinasyonlarla denenmiştir. Eğitim süresinde nöron sayısının etkisi olduğu gözlenmiştir. LSTM modelinde nöron sayısı ise 384-384-384, 32-32-32, 64-64-64, 128-128-128 şeklinde denenmiştir. LSTM modelinde çıktı katmanından önce üç katman FC eklenmiştir. Buradaki nöron sayıları 128-64-32 olarak belirlenmiştir.

Denenen bütün hiper parametre değerlerine bakıldığında, doğru hiper parametre değerini seçebilmek için çok fazla deneme yanılma yapmak gerekmektedir. Doğru seçim yapabilmek modelin çeşitine, veri setinin içeriğine, veri setinde bulunan sınıf dağılımına ve parametrelerin kendi arasındaki uyumuna bağlıdır. Sadece epoch sayısını üç farklı şekilde seçmek deneme süresini üç katına çıkarmıştır.

5.6. MODEL PERFORMANSI DEĞERLENDİRME

Sınıflandırma modellerinde değerlendirme yapabilmek için çeşitli performans değerlendirme metrikleri bulunmaktadır. Performans değerlendirme metriklerini hesaplayabilmek için karışıklık matrisindeki değerlere ihtiyaç duyulmaktadır. Karışıklık matrisi hata matrisi olarak da adlandırılmaktadır. Bu matris, geliştirilen uygulama ve modellerde, algoritmaların veya yöntemlerin performanslarını tabloda görselleştirmeyi sağlar. Karışıklık matrisi içerisinde Gerçek Pozitif (TP), Gerçek Negatif (TN), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) olmak üzere dört önemli parametre hakkında bilgi vermektedir [112].

TP: Gerçekte doğru olan gözlem doğru olarak tanımlanmış anlamına gelmektedir.

TN: Gerçekte yanlış olan gözlem yanlış olarak tanımlanmış anlamına gelmektedir.

FP: Gerçekte doğru olan gözlem yanlış olarak tanımlanmış anlamına gelmektedir.

FN: Gerçekte yanlış olan gözlem doğru olarak tanımlanmış anlamına gelmektedir.

TP ve TN’de gerçek ile tahmin durumları eşleşmektedir. Fakat, FP ve FN’de gerçek ile tahmin durumları eşleşmemektedir. Şekil 5.5’te karışıklık matrisi verilmiştir [112].

		Tahmini Sınıf	
		Pozitif (Hasta)	Negatif (Sağlıklı)
Gerçek Sınıf	Pozitif (Hasta)	TP	FN
	Negatif (Sağlıklı)	FP	TN

Şekil 5.5. Karışıklık matrisi [112].

Duyarlılık (Sensitivity): Kişinin hasta olduğu göz önüne alındığında pozitif bir test olasılığıdır. Başka bir deyişle, sensitivity, kişinin hasta olduğu göz önüne alındığında “hasta” şeklinde sınıflandırılma yeteneğidir. Eşitlik 5.9’da duyarlılık denklemi verilmiştir [113].

$$Sensitivity = \frac{TP}{TP+FN} \quad (5.9)$$

Özgüllük (Specificity): Kişinin hasta olmadığı göz önüne alındığında pozitif bir test olasılığıdır. Başka bir deyişle, specificity, kişinin hasta olmadığı göz önüne alındığında “sağlıklı” şeklinde sınıflandırılma yeteneğidir. Duyarlılık ve özgüllük ters orantılı performans değerlendirme metrikleridir. Eşitlik 5.10’da özgüllük denklemi verilmiştir [113].

$$Specificity = \frac{TN}{TN+FP} \quad (5.10)$$

Kesinlik (Precision): Gerçekte doğru olan gözlemlerin doğru olarak tahmin edildiği durumların, tahmini hasta olanlara oranını veren eşitlik. Eşitlik 5.11’de kesinlik denklemi verilmiştir [113].

$$Precision = \frac{TP}{TP+FP} \quad (5.11)$$

Doğruluk (Accuracy): Geliştirilen modelde elde edilen sonuçların doğruya ne kadar yakın olduğunu gösteren bir metrik değerdir. Hasta olanların hasta, sağlıklı olanların sağlıklı olarak tahmin edildiği durumların toplamının tüm tahmine oranından elde edilen eşitlik. Eşitlik 5.12’de doğruluk denklemi verilmiştir [114].

$$Accuracy = \frac{TN+TP}{TN+FP+TP+FN} \quad (5.12)$$

F1 Puanı (F1 Score): Sınıflandırma sonunda performans değerlendirmede kullanılan bu metrik duyarlılık ve kesinliğin harmonik ortalamasının hesaplanması ile bulunan, testin doğruluğu hakkında bilgi veren bir metriktir. Eşitlik 5.13’te F1 score denklemi verilmiştir [115].

$$F1\ Score = \frac{2*Precision*Sensitivity}{Precision+Sensitivity} \quad (5.13)$$

Matthews Korelasyon Katsayısı (MCC): Sınıflandırma sonunda modelin performansını ölçen bu metrik, dengesiz veri kümeleri probleminden etkilenmediği için performans açısından daha avantajlı bir metrik olarak değerlendirilmektedir. Eşitlik 5.14’te MCC ile ilgili hesaplamalar verilmiştir. Bu metrik sonuç olarak -1 ve +1 değerlerini almaktadır. -1 ve -1’e yakın değerler yanlış tahmin edildiği anlamına gelmektedir. +1 ve +1’e yakın değerler doğru tahmin edildiği anlamına gelmektedir. 0 ve 0’a yakın değerler tahminin gelişigüzel yapıldığı anlamına gelmektedir [115].

$$MCC = \frac{TP*TN-FP*FN}{\sqrt{(TP+FP)*(TP+FN)*(TN+FP)*(TN+FN)}} \quad (5.14)$$

Alıcı İşletim Karakteristiđi (Receiver Operating Characteristic, ROC): Aynı veriler üzerinde farklı deđişkenlere dayanan testler için bir analiz grafiđidir. ROC eğirisi, gözlemlenen deđişkenlerin hangi deđerlerinin normal olmadıđının kabul edileceđini belirleyebilmek için farklı gözlemlenen deđişkenler tarafından meydana getirilir. Bu oluřumdan sonra elde edilen sonuçlara karřılık gelen yanlış pozitif oranlara karřı duyarlılık deđerleri çizilerek eğri elde edilir. ROC eğrisi dođru eřik deđer, ayırt edici özellikler, çoklu sınıflandırma modelleri gibi performans deđerlendirmelerde kolaylıklar sađlamaktadır. AUC, ROC eğrisinin sayısal deđerini ifade etmek için kullanılmaktadır. AUC deđerinin bire yakın olması hedeflenen bir durum iken AUC deđerinin sıfıra yaklařması accuracy deđerinin kötü olduđu anlamına gelmektedir [116, 117].

BÖLÜM 6

ÇALIŞMA BULGULARI VE TARTIŞMA

Çalışmanın bu bölümünde, CNN ve LSTM modellerinden elde edilen performans değerlendirme metriklerinin sonuçlarının analizi detaylı bir şekilde anlatılmıştır. Modeller ilk olarak çeşitli kombinasyonlarda kendi aralarında karşılaştırıldıktan sonra önemli sonuçlar elde etmiş başka çalışmalarla kıyaslanarak değerlendirilmiştir.

6.1. GELİŞTİRİLEN MODELLERDE ELDE EDİLEN BULGULAR

Bu tez çalışmasında EKG sinyallerinde aritmi tespiti yapılmıştır. MIT-BIH aritmi veri setinde bulunan N, S, V, F, Q olmak üzere beş sınıf ile sınıflandırma yapılmıştır. Veri setinde N ve S sınıfının fragment sayısı diğer sınıflara göre çok daha azdır. Bu yüzden, F ve S sınıfında eşit sayıda fragment çekilerek Others isminde bir sınıf oluşturulmuştur. N, V, Q ve Others sınıfları için dörtlü CNN ve LSTM modellerinde sınıflandırma yapılmıştır. Sınıfların buldukları modelde yüksek olan performans değerlendirme metrikleri tespit edilerek veri setinden çıkarılmış ve o sınıfın olmadığı daha az sınıflı veri seti ile model tekrar çalıştırılmıştır. Böylece dörtlü, üçlü ve ikili sınıflandırmalar yapılarak tüm sınıflar için en iyi performans değerlendirme metrikleri tespit edilip hibrit bir model üzerinden tüm sınıflar belirlenmiştir.

Bu tez çalışmasında 24 sınıflandırılma yapılmıştır. N, V, Q ve Others sınıfları CNN ve LSTM modellerinde 30, 50 ve 100 epoch değerleri ile sınıflandırılmıştır. N, V ve Q sınıfları CNN ve LSTM modellerinde 30, 50 ve 100 epoch değerleri ile sınıflandırılmıştır. N ve V sınıfları CNN ve LSTM modellerinde 30, 50 ve 100 epoch değerleri ile sınıflandırılmıştır. F ve S sınıfları CNN ve LSTM modellerinde 30, 50 ve 100 epoch değerleri ile sınıflandırılmıştır.

Şekil 6.1’de bu tez çalışmasında geliştirilen hibrit model ve belirlenen sınıfların accuracy değerleri verilmiştir.

Çizelge 6.1’de N-V-Q-Others sınıfları için CNN ve LSTM modellerinde hesaplanan karışıklık matrisi değerleri verilmiştir.

Çizelge 6.2’de sınıf dağılımlarında N-V-Q-Others, N-V-Q, F-S ve N-V şeklinde kombinasyonlu tüm gruplar için hem CNN hem LSTM modellerinde epoch sayısı 30, 50, 100 olarak değişen 24 defa çalıştırılan modellerin genel performans değerlendirme sonuçları verilmiştir. N-V-Q-Others sınıfları için en iyi accuracy değerini %95.07 ile veren model epoch sayısı 50 olan LSTM modelidir. N-V-Q sınıfları için en iyi accuracy değerini %99.13 ile veren model epoch sayısı 100 olan LSTM modelidir. N-V sınıfları için en iyi accuracy değerini %98.75 ile veren model epoch sayısı 100 olan LSTM modelidir. F-S sınıfları için en iyi accuracy değerini %97.72 ile veren model epoch sayısı 30 olan LSTM modelidir. Bu çalışmada LSTM modelinde accuracy değerleri CNN’e göre daha iyi performans göstermiştir.

Çizelge 6.3’de N-V-Q-Others sınıflarının her biri için için hem CNN hem LSTM modellerinde epoch sayısı 30, 50, 100 olarak değişen modellerde performans değerlendirme sonuçları verilmiştir. N sınıfı için için en iyi accuracy değerini %96.66 ile veren model epoch sayısı 50 olan LSTM modelidir. V sınıfı için için en iyi accuracy değerini %96.00 ile veren model epoch sayısı 50 olan LSTM modelidir. Q sınıfı için için en iyi accuracy değerini %98.24 ile veren model epoch sayısı 50 olan LSTM modelidir. Others sınıfı için için en iyi accuracy değerini %99.27 ile veren model epoch sayısı 50 olan LSTM modelidir.

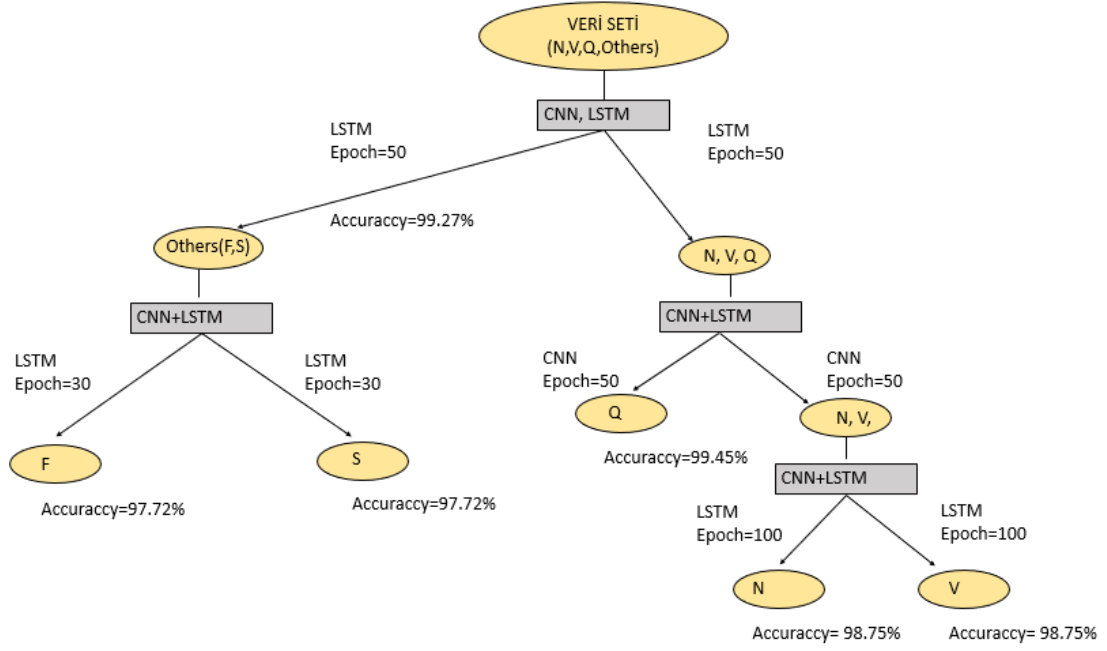
Çizelge 6.4’de N-V-Q sınıflarının her biri için için hem CNN hem LSTM modellerinde epoch sayısı 30, 50, 100 olarak değişen modellerde performans değerlendirme sonuçları verilmiştir. Bu çalışmada N sınıfı için için en iyi accuracy değerini %98.83 ile veren model epoch sayısı 50 olan LSTM modelidir. V sınıfı için için en iyi accuracy değerini %98.62 ile veren model epoch sayısı 100 olan LSTM modelidir. Q sınıfı için için en iyi accuracy değerini %99.45 ile veren model epoch sayısı 50 olan CNN modelidir.

Çizelge 6.5’de N ve V sınıfları için için hem CNN hem LSTM modellerinde epoch sayısı 30, 50, 100 olarak değişen modellerde performans değerlendirme sonuçları verilmiştir. N ve V sınıfları için için en iyi accuracy değerini %98.75 ile veren model epoch sayısı 100 olan LSTM modelidir.

Çizelge 6.6’de F ve S sınıfları için için hem CNN hem LSTM modellerinde epoch sayısı 30, 50, 100 olarak değişen modellerde performans değerlendirme sonuçları verilmiştir. F ve S sınıfları için için en iyi accuracy değerini %97.72 ile veren model epoch sayısı 30 olan LSTM modelidir.

Bu tez çalışmasında, derin öğrenme modellerinden CNN ve LSTM yapıları kullanılarak accuracy, specificity, sensitivity, F1 score, MCC, ROC eğrisi AUC değeri ile modeller değerlendirilmiştir. KVH içerisinde kardiyak aritmi teşhisi, EKG sinyallerinde otomatik yapılmıştır. Veri setinde veri dağılımı dikkate alınarak en az veriye sahip olan F ve S sınıfı birleştirilerek Others isminde yeni bir sınıf oluşturulup sınıflandırma yapılmıştır. Veri setinde veri dağılımının eşitliği sağlandıktan sonra, CNN ve LSTM modellerinde dördü, üçlü ve ikili sınıflandırma hibrit bir model üzerinden gerçekleştirilmiştir. Bütün sınıfları belirleyebilmek ve yüksek doğruluk oranlarını elde edebilmek için öncelikle iki model için de dördü bir sınıflandırma yapılmıştır. Bu işlemden sonra doğruluk oranı en yüksek olan sınıf ve model belirlenerek veri setinden çıkarılmış, her bir sınıf elde edilene kadar bu işlem devam etmiştir.

Elde edilen sonuçlara bakıldığında performans sonuçları; model hiper parametreleri, veri setinde bulunan veri türleri, veri dağılımı, model türüne bağlı olarak farklılık göstermektedir. Çalışmanın sonucunda epoch sayısının sınıflandırma üzerinde etkisi anlaşılmıştır.



Şekil 6.1. Çalışmada geliştirilen hibrit model.

Çizelge 6.1. N, V, Q ve Others sınıfları için karışıklık matrisi değerleri.

Class	Epoch	CNN				LSTM			
		TP	TN	FP	FN	TP	TN	FP	FN
N	30	482	1374	54	18	474	1370	58	26
	50	447	1387	41	53	474	1387	39	26
	100	483	1365	63	17	474	1386	42	26
V	30	414	1432	19	63	421	1429	22	56
	50	436	1393	58	41	432	1419	32	45
	100	414	1430	21	63	432	1414	37	45
Q	30	451	1436	25	16	443	1438	23	24
	50	439	1439	22	28	451	1443	18	16
	100	450	1435	26	17	437	1439	22	30
Others	30	476	1437	7	8	477	1434	10	7
	50	473	1432	12	11	476	1438	6	8
	100	469	1442	2	15	475	1435	9	9

Çizelge 6.2. CNN ve LSTM modellerinden elde edilen genel sonuçlar.

Class	Epoch	CNN						LSTM					
		Acc (%)	Spe (%)	Sens (%)	F1 (%)	MCC	AUC	Acc (%)	Spe (%)	Sens (%)	F1 (%)	MCC	AUC
N V Q Others	30	94.55	98.16	94.55	94.53	0.93	0.993	94.14	98.02	94.14	94.13	0.92	0.993
	50	93.10	97.69	93.10	93.11	0.91	0.992	<u>95.07</u>	98.34	95.07	95.07	0.94	0.995
	100	94.19	98.03	94.19	94.19	0.92	0.994	94.29	98.09	94.29	94.29	0.92	0.994
N V Q	30	97.79	98.90	97.79	97.79	0.97	0.998	97.51	98.78	97.51	97.51	0.96	0.998
	50	97.51	98.79	97.51	97.51	0.96	0.998	97.65	98.82	97.65	97.65	0.96	0.998
	100	98.20	99.10	98.20	98.20	0.97	0.999	<u>99.13</u>	99.07	98.13	98.13	0.97	0.998
N V	30	98.55	98.55	98.55	98.55	0.97	0.997	98.03	98.01	98.03	98.03	0.96	0.996
	50	98.34	98.33	98.34	98.34	0.97	0.997	98.55	98.55	98.55	98.55	0.97	0.997
	100	97.41	97.42	97.41	97.41	0.95	0.997	<u>98.75</u>	98.75	98.76	98.76	0.97	0.997
Others (S-F)	30	96.89	96.86	96.89	96.89	0.94	0.999	<u>97.72</u>	97.66	97.72	97.72	0.95	0.995
	50	93.98	93.98	93.98	93.96	0.88	0.991	97.30	97.29	97.30	97.30	0.95	0.993
	100	97.09	97.01	97.10	97.09	0.94	0.993	96.68	96.59	96.68	96.68	0.93	0.993

Çizelge 6.3. N, V, Q ve Others sınıflarından elde edilen accuracy değerleri.

Class	Epoch	CNN						LSTM					
		Acc (%)	Spe (%)	Sens (%)	F1 (%)	MCC	AUC	Acc (%)	Spe (%)	Sens (%)	F1 (%)	MCC	AUC
N	30	96.26	96.22	96.40	93.05	0.91	0.990	95.64	95.94	94.80	91.86	0.89	0.990
	50	95.12	97.13	89.40	90.49	0.87	0.990	96.66	97.27	94.80	93.58	0.91	0.993
	100	95.85	95.59	96.60	92.35	0.90	0.993	96.47	97.06	94.80	93.31	0.91	0.992
V	30	95.75	98.69	86.79	90.99	0.88	0.987	95.95	98.48	88.26	91.52	0.89	0.986
	50	94.86	96.00	91.40	89.80	0.86	0.986	96.00	97.79	90.57	91.82	0.89	0.990
	100	95.64	98.55	86.79	90.79	0.88	0.987	95.75	97.47	90.57	91.33	0.88	0.989
Q	30	97.87	98.29	96.57	95.65	0.94	0.996	97.56	98.43	94.86	94.96	0.93	0.995
	50	97.41	98.49	94.00	94.61	0.93	0.996	98.24	98.77	96.57	96.37	0.95	0.998
	100	97.77	98.22	96.36	95.44	0.94	0.995	97.30	98.49	93.58	94.38	0.93	0.995
Others (S-F)	30	99.22	99.52	98.35	98.45	0.98	0.999	99.12	99.31	98.55	98.25	0.98	0.999
	50	98.81	99.17	97.73	97.63	0.97	0.998	99.27	99.58	98.35	98.55	0.98	0.999
	100	99.12	99.86	96.90	98.22	0.98	0.999	99.07	99.38	98.14	98.14	0.97	0.999

Çizelge 6.4. N, V ve Q sınıflarından elde edilen accuracy değerleri.

Class	Epoch	CNN						LSTM					
		Acc (%)	Spe (%)	Sens (%)	F1 (%)	MCC	AUC	Acc (%)	Spe (%)	Sens (%)	F1 (%)	MCC	AUC
N	30	98.62	98.78	98.28	97.86	0.97	0.999	98.06	97.96	98.28	97.03	0.97	0.999
	50	97.79	97.55	98.28	96.62	0.95	0.998	98.83	99.18	96.56	97.40	0.96	0.998
	100	98.75	99.08	98.06	98.06	0.97	0.998	98.47	98.88	97.63	97.63	0.96	0.997
V	30	97.99	98.54	96.93	97.03	0.95	0.998	97.92	99.06	95.70	96.89	0.95	0.998
	50	97.79	98.96	95.49	96.68	0.95	0.997	97.92	97.91	97.95	96.96	0.95	0.997
	100	98.54	98.96	97.75	97.85	0.97	0.998	98.62	98.75	98.36	97.96	0.98	0.997
Q	30	98.96	99.37	98.17	98.47	0.98	0.999	99.03	99.27	98.58	98.58	0.98	0.999
	50	99.45	99.79	98.78	99.19	0.99	0.999	99.03	99.37	98.38	98.58	0.98	0.999
	100	99.10	99.27	98.78	98.68	0.98	0.999	99.17	99.58	98.38	98.78	0.98	0.999

Çizelge 6.5. N ve V sınıflarından elde edilen accuracy değerleri.

Class	Epoch	CNN						LSTM					
		Acc (%)	Spe (%)	Sens (%)	F1 (%)	MCC	AUC	Acc (%)	Spe (%)	Sens (%)	F1 (%)	MCC	AUC
N	30	98.55	98.74	98.36	98.57	0.97	0.996	98.03	97.26	98.77	98.07	0.96	0.996
	50	98.34	98.11	98.57	98.37	0.97	0.997	98.55	98.53	98.57	98.57	0.97	0.997
	100	97.41	97.89	96.93	97.43	0.95	0.997	98.75	98.74	98.77	98.77	0.97	0.997
V	30	98.55	98.36	98.74	98.53	0.97	0.996	98.03	98.77	97.26	97.99	0.96	0.996
	50	98.34	98.57	98.11	98.31	0.97	0.997	98.55	98.57	98.53	98.53	0.97	0.997
	100	97.41	96.93	97.89	97.38	0.95	0.997	98.75	98.77	98.74	98.74	0.97	0.997

Çizelge 6.6. F ve S sınıflarından elde edilen accuracy değerleri.

Class	Epoch	CNN						LSTM					
		Acc (%)	Spe (%)	Sens (%)	F1 (%)	MCC	AUC	Acc (%)	Spe (%)	Sens (%)	F1 (%)	MCC	AUC
S	30	96.8	96.19	97.56	96.97	0.94	0.996	97.72	96.19	99.19	97.80	0.95	0.996
	50	93.98	88.14	99.59	94.41	0.88	0.992	97.30	97.03	97.56	97.36	0.95	0.992
	100	97.09	94.92	99.19	97.21	0.94	0.992	96.68	94.49	98.78	96.81	0.93	0.992
F	30	96.89	97.56	96.19	96.80	0.94	0.995	97.72	99.19	96.19	97.63	0.95	0.995
	50	93.98	99.59	88.14	93.48	0.88	0.994	97.30	97.56	97.03	97.24	0.95	0.994
	100	97.09	99.19	94.92	96.97	0.94	0.993	96.68	98.78	94.49	96.54	0.93	0.993

6.2. TARTIŞMA

KVH ölüm oranları dünya genelinde oldukça artmıştır [1]. Bu yüzden EKG sinyal analizi ile hastalık sınıflandırma klinik açıdan büyük önem arz etmektedir. Makine öğrenmesi ve derin öğrenme temellerine dayanan KVH sınıflandırılması alanında geçmişten günümüze çok fazla çalışma mevcuttur. Bu çalışmada, MIT-BIH aritmi veri setinde kardiyak aritmi teşhisi geliştirilen hibrit bir model ile yapılmıştır. Derin öğrenme mimarilerinden CNN ve LSTM yapıları kullanılarak accuracy, specificity, sensitivity, F1 score, MCC, ROC eğrisi ve AUC değeri ile modeller değerlendirilmiştir.

Bu çalışmada kullanılan hibrit yöntem sayesinde, N, S, V, F ve Q sınıflarının tespiti için yüksek accuracy değerleri elde edilmiştir. Bu tez çalışmasını diğer çalışmalardan ayıran nokta, sınıfların yüksek doğruluk oranına sahip olan model ve epoch değerleri belirlendikten sonra veri setinden çekilerek kalan sınıflarda yeniden modellerin eğitime sokulmasıdır.

Tüm sınıflar için CNN modelinde bulunan accuracy, specificity, sensitivity, F1-score, MCC, AUC score ortalama değerleri sırasıyla %98.15, %98.58, %98.20, %98.09, 0.96, 0.997'dir. Tüm sınıflar için LSTM modelinde bulunan accuracy, specificity, sensitivity, F1-score, MCC, AUC score ortalama değerleri sırasıyla %98.42, %98.67, %98.46, %98.34, 0.97, 0.997'dir. Tüm sınıflar için geliştirilen hibrit model ile bulunan accuracy, specificity, sensitivity, F1-score, MCC, AUC score ortalama değerleri sırasıyla %98.48, %98.78, %98.58, %98.54, 0.97, 0.997'dir.

Çizelge 6.7'de yapılan çalışmaların yıl, veri seti, sınıf sayısı, model türü ve performans değerlendirme metriklerine göre kıyaslaması yapılmıştır. Kiranyaz vd. 1D CNN derin öğrenme modelini kullanarak yaptığı beş sınıflı çalışmada VEB için accuracy değerini %99.00, SVEB için accuracy değerini %97.60 olarak bulmuştur [95]. Luo vd. DNN-SDA ile yaptığı dört sınıflı çalışmada VEB için accuracy değerini %99.10, SVEB için accuracy değerini %98.8 olarak bulmuştur [118]. Zhai vd. yaptığı beş sınıflı derin öğrenme çalışmasında 2D CNN modelini kullanarak VEB için accuracy değerini %99.10, SVEB için accuracy değerini %97.30 olarak bulmuştur [119]. Yıldırım

yaptığı beş sınıflı derin öğrenme çalışmasında yedi katmanlı DBLSTM-ws ile accuracy değerini %99.39 olarak bulmuştur [99]. Plawiak vd 12, 15 ve 17 sınıflı derin öğrenme çalışmasında DGEC modeli ile accuracy değerini %98 olarak bulmuştur [120]. Li vd. yaptığı beş sınıflı derin öğrenme çalışmasında CNN modeli ile VEB için accuracy değerini %98.20 olarak, SVEB için accuracy değerini %99.50 olarak bulmuştur [98]. Yıldırım vd. yaptığı 13-15-17 sınıflı derin öğrenme çalışmasında 1D CNN modelini kullanarak accuracy değerini %95.20 olarak bulmuştur [121]. Hanbay yaptığı dört sınıflı derin öğrenme çalışmasında VEB için accuracy değerini %99.90, SVEB için accuracy değerini %99.90 olarak bulmuştur [122]. Kachuee yaptığı beş sınıflı derin öğrenme çalışmasında Deep residual CNN modeli ile accuracy değerini %95.9 olarak bulmuştur [123]. Guo vd. yaptığı beş sınıflı derin öğrenme modelinde CNN ve RNN modellerini kullanarak VEB için accuracy değerini %91.71, SVEB için accuracy değerini %88.99 olarak bulmuştur [124]. Alquran vd. yaptığı beş sınıflı derin öğrenme çalışmasında GoogleNet CNN modeli ile ortalama accuracy değerini %94.00 olarak hesaplamıştır [125]. Baloğlu vd. yaptığı 10 sınıflı derin öğrenme modelinde end to end CNN modelini kullanarak EKG sinyallerinden otomatik MI teşhisi için accuracy değerini %99.00'ın üzerinde elde etmiştir [100]. Hasan vd. yaptığı 4, 7 ve 9 sınıflı derin öğrenme çalışmasında 3 farklı veri seti ile çalışıp 1D CNN modeli kullanarak %99.71 accuracy değerini bulmuştur [126]. Shaker vd. yaptığı 15 sınıflı derin öğrenme çalışmasında Deep CNN ve Two stage deep CNN modellerini geliştirerek accuracy değerini %98.30 olarak hesaplamıştır [127]. Ullah vd. yaptığı sekiz sınıflı çalışmada 2D CNN modeli geliştirerek accuracy değerini %98.92 olarak bulmuştur [128]. Peinamankar vd. yaptığı dört sınıflı derin öğrenme çalışmasında geliştirdiği DENS-EKG modeli ile sensitivity değerini %99.61 olarak bulmuştur [129]. Şehirli vd. yaptığı yedi sınıflı makine öğrenmesi çalışmasında çeşitli modelleri geliştirerek %95.57 accuracy değerini, %94.75 sensitivity değerini, %95.96 specificity değerini elde etmiştir [103]. Farag vd. EKG sınıflandırmasında aritmi tespiti için kendi kendine yeten kısa süreli Fourier Dönüşümü (STFT) ile CNN modeli geliştirmişlerdir. Yaptıkları çalışmada Conv1D ile Conv2D'den oluşan hibrit model geliştirerek %99.08 accuracy değeri elde etmişlerdir [130].

Çizelge 6.7. Önerilen yöntem ve yapılan diğer çalışmaların karşılaştırılması.

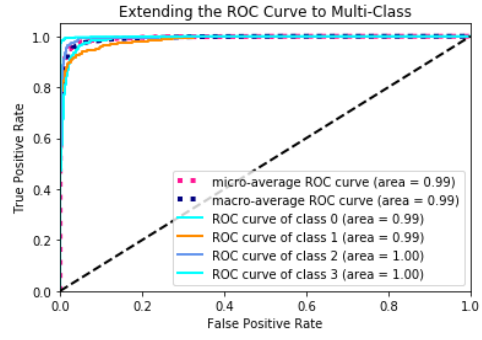

Çalışma	Sınıf	Model	Sonuçlar
[95] 2015	5	1D-CNN	VEB: Acc=99.00, Sens=93.90, Spe=98.90 SVEB: Acc=97.60, Sens =60.30, Spe=99.20
[118] 2017	4	DNN-SDA	VEB: Acc=99.10, Sens =93.30, Spe=99.50 SVEB: Acc=98.80, Sens =71.40, Spe=99.80
[119] 2018	5	2D-CNN	VEB: Acc=99.10, Sens =96.40, Spec=99.50, SVEB: Acc=97.30, Sens =85.30, Spe=98.00,
[99] 2018	5	7-layer DBLSTM-WS	DULSTM-WS2: Acc= 99.20 DBLSTM-WS3: Acc= 99.390
[120] 2018	12	DGEC	Acc=98.00
[98] 2018	5	CNN	VEB: Acc=98.20, Sens =99.30, Spe=87.30, SVEB: Acc=99.50, Sens = 99.40, Spe=99.90,
[121] 2018	13	1D-CNN	Acc= 95.20
[122] 2018	4	DNN	VEB: Acc= 99.90, Sens= 99.80, Spe= 100 SVEB: Acc= 99.90, Sens = 99.20, Spe= 100
[123] 2018	5	Deep residual CNN	Acc=95.90 Pre=95.20 Sens=95.10 Av. Acc=93.50
[124] 2019	5	CNN RNN	VEB: Acc=91.71 Sens = 81.80 Spe= 95.93 F1=85.49 SVEB: Acc=88.99 Sens =69.35 Spe=94.38 F1=73.07
[125] 2019	5	GoogleNet CNN	Ov. Acc= 96.00, Av. Acc = 94.00, Sens= 94.00, Spe= 98.50, Pre= 94.60
[100] 2019	10	End-to-end CNN	Acc=99.78
[126] 2019	9	1-D CNN	Acc = 99.71
[127] 2020	15	CNN	Av. Pre= 90.00 ,93,95 Ov. Acc= 98.30,98.00
[128] 2020	8	2-D CNN	Acc =98.92 Sens =97.26, Spec=99.67, Pre=98.69 F1=0.98
[129] 2021	4	DENS-EKG	Sens=99.61 P+=99.52 Err=0.87
[103] 2021	7	CDM, K-Means Clustering, Tracking Local Extreme Points	Acc = 95.57, Sens =94.75, Spec = 95.96, PPV= 91.86 PPV
[130] 2022	5	Conv1D+Conv2D	Acc=99.08
Önerilen yöntem 2022	5	CNN LSTM	Acc =98.48, Spec= 98.78, Sens = 98.58, F1=98.54, MCC=0.97 AUC= 0.997

Bu tez çalışması 2015 yılından 2022 yılları arasında literatürdeki diğer çalışmalarla kıyaslandığında, iyi sayılabilecek accuracy değerlerine sahiptir. Diğer çalışmalardan

daha fazla performans deęerlendirme metrięinin kullanılması alıřmanın gvenilirlięini artırmaktadır. Literatrdeki veri seti bilgilerine bakıldıęında, biroęunun MIT-BIH aritmi veri seti olduęu grlmektedir.



Bu tez alıřmasındaki modelde halka aık MIT-BIH aritmi veri seti kullanılmıřtır. Literatrde bu veri seti ile yapılmıř olduka fazla derin ęrenme ve makine ęrenmesi alıřmaları vardır. Literatrdeki alıřmaların byk oęunluęu ile aynı olan MIT-BIH aritmi veri seti zerinde alıřma yapılmıřtır.

řekil 6.2’de epoch sayısı 30 olan sınıflandırmalarda ROC eęrileri verilmiřtir. řekil 6.3’te epoch sayısı 50 olan sınıflandırmalarda ROC eęrileri verilmiřtir. řekil 6.4’te epoch sayısı 100 olan sınıflandırmalarda ROC eęrileri verilmiřtir.





N-V-Q-Others CNN

N-V-Q-Others RNN





N-V-Q CNN

N-V-Q RNN



N-V CNN

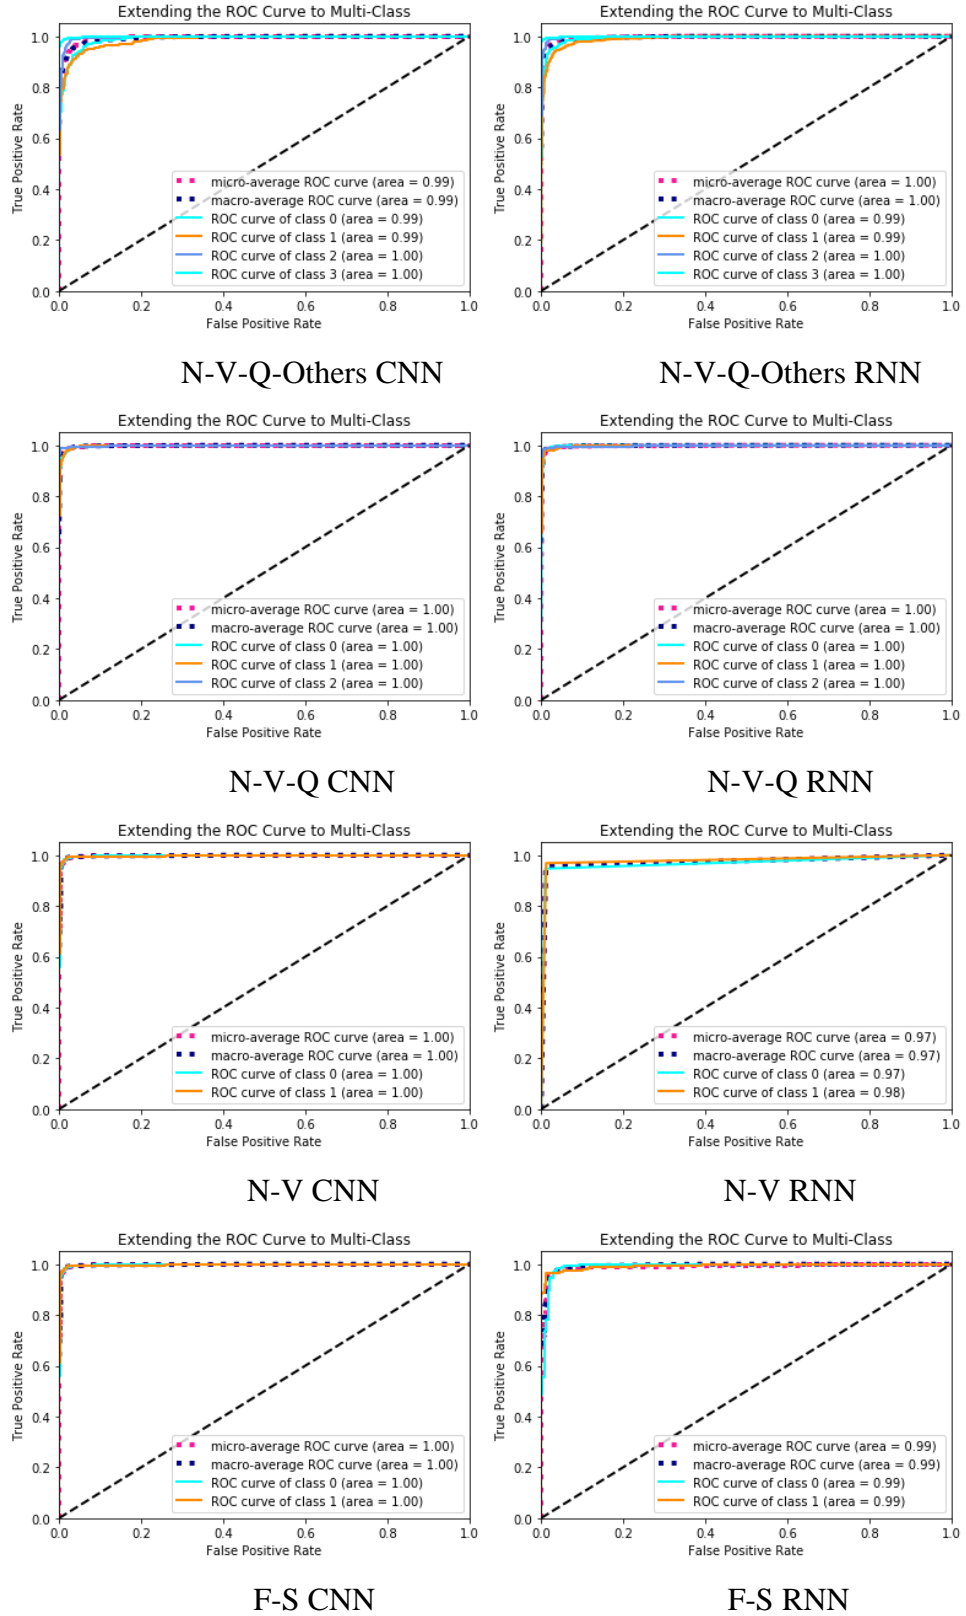
N-V RNN



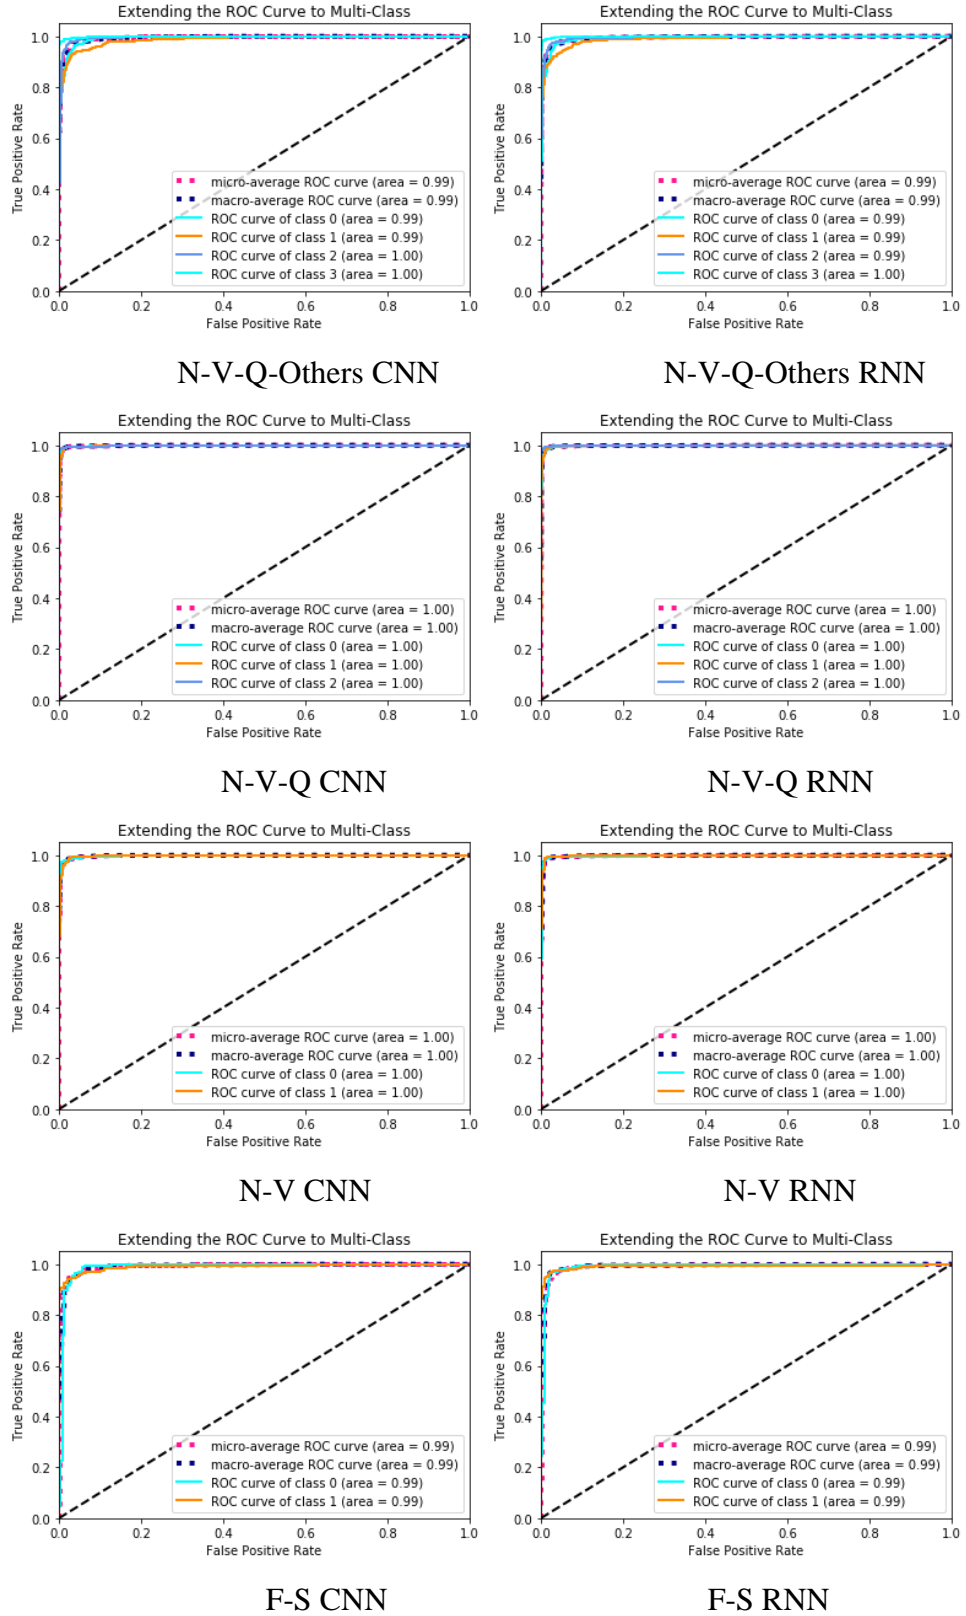
F-S CN

F-S RNN

Şekil 6.2. Epoch sayısı 30 olan sınıflandırmalarda ROC eğrileri.



Şekil 6.3. Epoch sayısı 50 olan sınıflandırmalarda ROC eğrileri.



Şekil 6.4. Epoch sayısı 100 olan sınıflandırmalarda ROC eğrileri.

BÖLÜM 7

SONUÇLAR

Bu tez çalışmasında, derin öğrenme modellerinden CNN ve LSTM yapıları kullanılarak accuracy, specificity, sensitivity, F1 score, MCC, ROC eğrisi AUC değeri ile modeller değerlendirilmiş olup EKG sinyallerinde otomatik kardiyak aritmi teşhisi yapılmıştır. Veri setinde veri dağılımı dikkate alınarak en az veriye sahip olan iki sınıf birleştirilip veri setine tek bir sınıf şeklinde dahil edilmiştir. Veri setinde veri dağılımının eşitliği sağlandıktan sonra, CNN ve LSTM modellerinde dördü, üçlü ve ikili sınıflandırma hibrit bir model üzerinden gerçekleştirilmiştir. Bütün sınıfları belirleyebilmek ve yüksek doğruluk oranlarını elde edebilmek için öncelikle iki model için de dördü bir sınıflandırma yapılmıştır. Bu işlemden sonra doğruluk oranı en yüksek olan sınıf ve model belirlenerek veri setinden çıkarılmış, her bir sınıf elde edilene kadar bu işlem devam etmiştir. EKG sinyalleri üzerinde beş sınıfta hibrit model kullanılarak otomatik kardiyak aritmi teşhisinin yapıldığı bu çalışma sonucunda;

1. Önerilen modelde tüm sınıfların her biri için accuracy, specificity, sensitivity, F1 score, MCC ve ROC eğrisi skorları hem CNN hem LSTM modellerinde hesaplanmıştır. Böylece çalışmayı kendi içinde iki model ile de sınıf sınıf karşılaştırabilme imkanı oluşmuştur.
2. Önerilen modelde halka açık MIT-BIH aritmi veri seti kullanılmıştır. Literatürde bu veri seti ile yapılmış oldukça fazla derin öğrenme ve makine öğrenmesi çalışmaları vardır. Kullanılan veri seti sayesinde literatürde belirtilen makine öğrenimi ve derin öğrenme çalışmaları ile kıyaslama yapma imkanı elde edilmiştir.
3. Dördü, üçlü ve ikili sınıflandırmalarda performans değerlendirme metriklerinin ortalama değerleri hesaplandığı için CNN ve LSTM modelleri kendi aralarında kıyaslanabilmiştir. Geliştirilen model için çoğunluk olarak LSTM modeli CNN modelinde göre daha yüksek doğruluk oranları verdiğini kanıtlar niteliktedir.

4. Makine öğreniminde özellik çıkarma aşamasında önemli bilgiler arařtırmacının tercihinine baęlı olarak hesaplanmaktadır. Önerilen model sayesinde derin öğrenme yapıları kullanılarak özellikler otomatik olarak çıkarılmıřtır.
5. Önerilen modelde hiper parametre deęerleri çok çeřitli kombinasyonlarda denenmiřtir. Özellikle her bir sınıflandırmada, üç farklı epoch deęeri ile model eęitildięinden hiper parametre deęerinin modeller üzerindeki etkisi ortaya çıkarılmıřtır. Önerilen çalıřma sonucunda elde edilen bilgilere bakıldıęında, sınıflar için farklı epoch deęerlerinin en yüksek accuracy deęerini elde ettięi gözlemlenmiřtir.
6. Önerilen modelde hibrit sistem sayesinde her bir sınıfın yüksek accuracy deęeri elde edilmiřtir. Yapılan dięer çalıřmalarla kıyaslandıęında, elde edilen başarı oranları klinik açıdan çok önemlidir. KVH sebebiyle meydana gelen ölüm oranları çok yüksek seviyelere ulařtıęı için önerilen beř sınıflı modelde otomatik aritmi teřhisinin önemi çok fazladır. Sınıflandırmanın otomatik olması hasta ve teřhis eden kiři için zaman kaybını önlemektedir.
7. Önerilen modelde 11 katmanlı 1D CNN ve üç katmanlı LSTM yapıları kullanılmıřtır. Modeller önce kendi içinde birbiri ile sonra yapılan dięer çalıřmalarla kıyaslanmıřtır. Modelde kullanılan katman çeřitlerinin ve katman sayısının başarı oranlarına etkisini anlamak amacıyla, ilerleyen dönemde katman sayısı ve katman çeřitleri deęiřtirilmiř 2D CNN ve 3D CNN modelleri ile birlikte LSTM yapılarının tek bir modelde kullanıldıęı bu modelde kullanılan veri setinden farklı bir veri seti ile yeni bir çalıřma yapılması planlanmaktadır.

KAYNAKLAR

1. İnternet: WHO, “Cardiovascular diseases (CVDs)”, [**https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)**](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)) (2021).
2. Keating, M. T., & Sanguinetti, M. C., “Molecular and cellular mechanisms of cardiac arrhythmias”, *Cell*, 104(4), 569-580 (2001).
3. Gaztañaga, L., Marchlinski, F. E., & Betensky, B. P., “Mechanisms of cardiac arrhythmias”, *Revista Española de Cardiología (English Edition)*, 65(2), 174-185 (2012).
4. Luz, E. J. D. S., Schwartz, W. R., Cámara-Chávez, G., & Menotti, D., “EKG-based heartbeat classification for arrhythmia detection: A survey”, *Computer methods and programs in biomedicine*, 127, 144-164 (2016).
5. Isin, Ali, Selen Ozdalili, “Cardiac arrhythmia detection using deep learning”, *Procedia computer science*, 120, 268-275 (2017).
6. Li, D., Zhang, J., Zhang, Q., & Wei, X., “Classification of EKG signals based on 1D convolution neural network”, *2017 IEEE 19th International Conference on e-Health Networking, Applications and Services (Healthcom)*, 1-6 (2017).
7. Mintz, Y., & Brodie, R., “Introduction to artificial intelligence in medicine”, *Minimally Invasive Therapy & Allied Technologies*, 28(2), 73-81 (2019).
8. Luo, G., “A review of automatic selection methods for machine learning algorithms and hyper-parameter values” *Network Modeling Analysis in Health Informatics and Bioinformatics*, 5(1), 1-16 (2016).
9. Lemley, J., Bazrafkan, S., & Corcoran, P., “Deep Learning for Consumer Devices and Services: Pushing the limits for machine learning, artificial intelligence, and computer vision”, *IEEE Consumer Electronics Magazine*, 6(2), 48-56 (2017).
10. Shaheen, F., Verma, B., & Asafuddoula, M., “Impact of automatic feature extraction in deep learning architecture”, *In 2016 International conference on digital image computing: techniques and applications (DICTA)*, 1-8 (2016).
11. Chen, X. W., & Lin, X., “Big data deep learning: challenges and perspectives”, *IEEE*, 2, 514-525 (2014).
12. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., ... & Farhan, L., “Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions”, *Journal of big Data*, 8(1), 1-74 (2021).

13. Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K., “Convolutional neural networks: an overview and application in radiology”, *Insights into imaging*, 9(4), 611-629 (2018).
14. Minaee, S., Boykov, Y. Y., Porikli, F., Plaza, A. J., Kehtarnavaz, N., & Terzopoulos, D., “Image segmentation using deep learning: A survey”, *IEEE transactions on pattern analysis and machine intelligence*, 44(7), (2021).
15. Wang, S., Cao, J., & Yu, P., “Deep learning for spatio-temporal data mining: A survey”, *IEEE transactions on knowledge and data engineering*, 34(8), (2020).
16. Peirlinck, M., Costabal, F. S., Yao, J., Guccione, J. M., Tripathy, S., Wang, Y., ... & Kuhl, E., “Precision medicine in human heart modeling”, *Biomechanics and modeling in mechanobiology*, 20(3), 803-831 (2021).
17. Keating, M. T., & Sanguinetti, M. C., “Molecular and cellular mechanisms of cardiac arrhythmias”, *Cell*, 104(4), 569-580 (2001).
18. Shah, S., Gnanasegaran, G., Sundberg-Cohon, J., & Buscombe, J. R., “The heart: Anatomy, physiology and exercise physiology”, *In Integrating cardiology for nuclear medicine physicians*, Springer, Berlin, Heidelberg, 3-22 (2009).
19. Baillargeon, B., Rebelo, N., Fox, D. D., Taylor, R. L., & Kuhl, E., “The living heart project: a robust and integrative simulator for human heart function”, *European Journal of Mechanics-A/Solids*, 48, 38-47 (2014).
20. Mikawa, T., & Hurtado, R., “Development of the cardiac conduction system”, *In Seminars in cell & developmental biology*, Academic Press, 18(1), 90-100 (2007).
21. Van Weerd, J. H., & Christoffels, V. M., “The formation and function of the cardiac conduction system”, *Development*, 143(2), 197-210 (2016).
22. Choudhury, M., Boyett, M. R., & Morris, G. M., “Biology of the sinus node and its disease”, *Arrhythmia & electrophysiology review*, 4(1), 28 (2015).
23. Fung, Y. C., "Biomechanics: Circulation, 2nd Edition", *Shock*, 9 (2): (1998).
24. Gordan, R., Gwathmey, J. K., & Xie, L. H., “Autonomic and endocrine control of cardiovascular function”, *World journal of cardiology*, 7(4), 204 (2015).
25. AL-Ziarjawey, H. A. J., & Çankaya, I., “Heart rate monitoring and PQRST detection based on graphical user interface with Matlab”, *International Journal of Information and Electronics Engineering*, 5(4), 311 (2015).
26. Jaiswal, G. K., & Paul, R., “Artificial neural network for EKG classification”, *Recent Research in Science and Technology*, 6(1), (2014).

27. Mr. Deshmukh Rohan, Dr. A. J. Patil, “Layered Approach for EKG beats Classification utilizing Neural Network functions”, *International Journal of Engineering Research and Applications (IJREA)*, 2(6), 1495-1500 (2012).
28. Meek, S., & Morris, F., “ii-basic terminology”, *Bmj*, 324(7335), 470-473 (2002).
29. Platonov, P. G., “P-wave morphology: Underlying mechanisms and clinical implications”, *Annals of Noninvasive Electrocardiology*, 17(3), 161-169.
30. Huang, H., Liu, J., Zhu, Q., Wang, R., & Hu, G., “A new hierarchical method for inter-patient heartbeat classification using random projections and RR intervals”, *Biomedical engineering online*, 13(1), 1-26 (2014).
31. Xue, Q., & Reddy, S., “Algorithms for computerized QT analysis”, *Journal of electrocardiology*, 30, 181-186 (1998).
32. Rooke, T. W., & Sparks Jr, H. V., “The electrical activity of the heart”, *Medical Physiology*, 219-222 (2003).
33. Klabunde, R. E., “Cardiac electrophysiology: normal and ischemic ionic currents and the ECG”, *Advances in physiology education*, 41(1), 29-37 (2017).
34. Hlaing, T., DiMino, T., Kowey, P. R., & Yan, G. X., “ECG repolarization waves: their genesis and clinical implications”, *Annals of noninvasive electrocardiology*, 10(2), 211-223 (2005).
35. Y. Singh and S. Singh, “Evaluation of Electrocardiogram for Biometric Authentication”, *Journal of Information Security*, 3(1), 39-48 (2012).
36. Das, M. K., & Ari, S., “ECG beats classification using mixture of features”, *International scholarly research notices*, 2014, 12 (2014).
- A. Almumri, E. Balakrishnan, and S. Narasimman, “Discrete Wavelet Transform Based Feature Extraction in Electrocardiogram Signals”, *Glob. J. Pure Appl. Math.*, 17(1), 63-77 (2021).
37. Kurnia, F., & Tjandrawinata, R. R., “Bioactive protein fraction DLBS1033 exerts its positive pleiotropic effects in the vascular cells via down regulation of gene expression”, *Medicinus*, 24(1), 18-24 (2011).
38. Çekik, R., & Telçeken, S., “EKG Sinyallerinin Kaba Kümeler Teorisi Kullanılarak Sınıflandırılması”, *Anadolu University of Sciences & Technology-A: Applied Sciences & Engineering*, 15(2), 125-135 (2014).
39. Luu, M., Stevenson, W. G., Stevenson, L. W., Baron, K., & Walden, J., “Diverse mechanisms of unexpected cardiac arrest in advanced heart failure”, *Circulation*, 80(6), 1675-1680 (1989).

40. Huikuri, H. V., Castellanos, A., & Myerburg, R. J., "Sudden death due to cardiac arrhythmias", *New England Journal of Medicine*, 345(20), 1473-1482 (2001).
41. Aehlert, B. J., "RAPID ACLS-Revised Reprint Second Edition", *Elsevier Health Sciences*, (2012).
42. Lofgren, B., "Atrial Fibrillation and Anticoagulation", *Blog: The Blonde Pharmacist*, 44 (2018).
43. Willems, J. L., Robles de Medina, E. O., Bernard, R., Coumel, P., Fisch, C., Krikler, D., ... & Wellens, H. J., "Criteria for intraventricular conduction disturbances and pre-excitation", *Journal of the American College of Cardiology*, 5(6), 1261-1275 (1985).
44. Richard N. Fogoros, M., "What Is a Bundle Branch Block: Learn More About This Abnormal ECG Pattern", *Very Well health*, (2019).
45. Ebrahimi, Z., Loni, M., Daneshtalab, M., & Gharehbaghi, A., "A review on deep learning methods for ECG arrhythmia classification", *Expert Systems with Applications: X*, 7, 100033 (2020).
46. Nabil, D., & Reguig, F. B., "Ectopic beats detection and correction methods: A review", *Biomedical Signal Processing and Control*, 18, 228-244 (2015).
47. Lu, L., Liu, M., Sun, R., Zheng, Y., & Zhang, P., "Myocardial infarction: symptoms and treatments", *Cell biochemistry and biophysics*, 72(3), 865-867 (2015).
48. Pollak, P., & Brady, W., "Electrocardiographic patterns mimicking ST segment elevation myocardial infarction", *Cardiology clinics*, 30(4), 601-615 (2012).
49. Conover, M. B., "Understanding electrocardiography", *Elsevier Health Sciences*, (2002).
50. Spodick D. H., "Normal sinus heart rate: sinus tachycardia and sinus bradycardia redefined", *American heart journal*, 124(4), 1119-1121 (1992).
51. Fox, D. J., Tischenko, A., Krahn, A. D., Skanes, A. C., Gula, L. J., Yee, R. K., & Klein, G. J., "Supraventricular tachycardia: diagnosis and management", *In Mayo Clinic Proceedings*, 83(12), 1400-1411 (2008).
52. Ray, A., & Ray, H., "Secured Pulse Rate Monitoring System using IoT and Cloud", In 2020 International Conference on Emerging Frontiers in Electrical and Electronic Technologies (ICEFEET), *IEEE*, 1-6 (2020).
53. Edited by Douglas L. Mann, D. P. Z., Peter Libby, Robert O. Bonow; founding editor and online editor Eugene Braunwald, "Braunwald's Heart Disease: A Textbook of Cardiovascular Medicine Tenth Edition", Philadelphia, PA: *Elsevier/Saunders*, (2015).

54. Baldzizhar, A., Manuylova, E., Marchenko, R., Kryvalap, Y., & Carey, M. G., “Ventricular tachycardias: characteristics and management”, *Critical Care Nursing Clinics*, 28(3), 317-329 (2016).
55. Denes, P., Gabster, A., & Huang, S. K., “Clinical, electrocardiographic and follow-up observations in patients having ventricular fibrillation during Holter monitoring: role of quinidine therapy”, *The American journal of cardiology*, 48(1), 9-16 (1981).
56. Hamet, P., & Tremblay, J., “Artificial intelligence in medicine”, *Metabolism*, 69, 36-40 (2017).
57. Holzinger, A., Langs, G., Denk, H., Zatloukal, K., & Müller, H., “Causability and explainability of artificial intelligence in medicine”, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(4), 1312 (2019).
58. Mintz Y, Brodie R., “Introduction to artificial intelligence in medicine”, *Minim Invasive Ther Allied Technol*, 28, 73–81 (2019).
59. Moran, M. E., “Evolution of robotic arms”, *Journal of robotic surgery*, 1(2), 103-111, (2007).
60. Weizenbaum, J., “ELIZA a computer program for the study of natural language communication between man and machine”, *Communications of the ACM*, 9(1), 36-45, (1966).
61. Kuipers, Benjamin, Edward A. Feigenbaum, Peter E. Hart, and Nils J. Nilsson., “Shakey: from conception to history”, *Ai Magazine*, 38(1), 88-103, (2017),
62. Kulikowski, C. A., “An opening chapter of the first generation of artificial intelligence in medicine: the first Rutgers AIM workshop, June 1975”, *Yearbook of medical informatics*, 24(01), 227-233, (2015).
63. Shortliffe, E. H., Davis, R., Axline, S. G., Buchanan, B. G., Green, C. C., & Cohen, S. N., “Computer-based consultations in clinical therapeutics: explanation and rule acquisition capabilities of the MYCIN system”, *Computers and biomedical research*, 8(4), 303-320, (1975).
64. Kulikowski, C. A., “Beginnings of artificial intelligence in medicine (AIM): computational artifice assisting scientific inquiry and clinical art—with reflections on present aim challenges”, *Yearbook of medical informatics*, 28(01), 249-256, (2019).
65. Weiss, S., Kulikowski, C. A., & Safir, A., “Glaucoma consultation by computer”, *Computers in Biology and Medicine*, 8(1), 25-40, (1978).
66. Amisha, M. P., Pathania, M., & Rathaur, V. K., “Overview of artificial intelligence in medicine”, *J Family Med Prim Care*, 8 (7): 2328-31, (2019).
67. Kaul, V., Enslin, S., & Gross, S. A., “History of artificial intelligence in medicine”, *Gastrointestinal endoscopy*, 92(4), 807-812, (2020).

68. Yang, Y. J., & Bang, C. S., “Application of artificial intelligence in gastroenterology”, *World journal of gastroenterology*, 25(14), 1666, (2019).
69. Ferrucci, D., Levas, A., Bagchi, S., Gondek, D., & Mueller, E. T., “Watson: beyond jeopardy”, *Artificial Intelligence*, 199, 93-105, (2013).
70. Ni, L., Lu, C., Liu, N., & Liu, J., “Mandy: Towards a smart primary care chatbot application”, *In International symposium on knowledge and systems sciences*, Springer, Singapore, 38-52, (2017).
71. Gargeya, R., & Leng, T., “Automated identification of diabetic retinopathy using deep learning”, *Ophthalmology*, 124(7), 962-969, (2017).
72. Zhang, J. S., Gu, L. Y., & Jiang, S. Y., “Blood pressure measurement model based on convolutional recurrent neural network”, *Beijing Biomed. Eng*, 37(5), 494-501(2018).
73. Kooi, T., Litjens, G., Van Ginneken, B., Gubern-Mérida, A., Sánchez, C. I., Mann, R., ... & Karssemeijer, N., “Large scale deep learning for computer aided detection of mammographic lesions”, *Medical image analysis*, 35, 303-312 (2017).
74. Glickstein, M., Strata, P., & Voogd, J., “Cerebellum: history”, *Neuroscience*, 162(3), 549-559, (2009).
75. Jain, A. K., Mao, J., & Mohiuddin, K. M., “Artificial neural networks: A tutorial”, *Computer*, 29(3), 31-44 (1996).
76. Uhrig, R. E., “Introduction to artificial neural networks”, Proceedings of IECON ‘95-21st Annual Conference on IEEE Industrial Electronics, Orlando, FL, USA: *IEEE*, 33–37 (1995).
77. Vandoni, J., “Ensemble Methods for Pedestrian Detection in Dense Crowds”, *Doctoral dissertation, Université Paris Saclay (COMUE)*, (2019).
78. Ayşe, A. R. I., & Berberler, M. E., “Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı”, *Acta Infologica*, 1(2), 55-73 (2017).
79. İnternet: Simplilearn, “What is Perceptron: A Beginners Guide for Perceptron”, <https://www.simplilearn.com/tutorials/deep-learning-tutorial/perceptron> (2022).
80. İnternet: Javatpoint, “Single Layer Perceptron in TensorFlow”, <https://www.javatpoint.com/single-layer-perceptron-in-tensorflow> (2022).
81. İnternet: Medium, “Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması”, <https://ayyucekizrak.medium.com/derin-ogrenme-icin-aktivasyon-fonksiyonlarinin-karsilastirilmasi-cee17fd1d9cd> (2019).
82. Jain, A. K., Mao, J., & Mohiuddin, K. M., “Artificial neural networks: A tutorial”, *Computer*, 29(3), 31-44 (1996).

83. İnternet: International Business Machines, “Supervised vs. Unsupervised Learning”, <https://www.ibm.com/cloud/blog/supervised-vs-unsupervised-learning> (2021).
84. Kotsiantis, S. B., Zaharakis, I., Pintelas, P., “Supervised machine learning: A review of classification techniques”, 249-268 (2007).
85. İnternet: Turhost, “Makine Öğrenmesi (Machine Learning) Nedir?”, <https://blog.turhost.com/makine-ogrenmesi-machine-learning-nedir/> (2021).
86. Chao, W. L., “Machine learning tutorial”, *Digital Image and Signal Processing* (2011).
87. Pedro Domingos, “The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World”, Basic Books, Inc., USA, **ISBN 0465094279** (2018).
88. Sharma, S., Sharma, S., & Athaiya, A., “Activation functions in neural networks”, *Towards Data Science*, 6(12), 310-316 (2017).
89. KILIÇARSLAN, S., Kemal, A. D. E. M., & Çelik, M., “An overview of the activation functions used in deep learning algorithms”, *Journal of New Results in Science*, 10(3), 75-88 (2021).
90. S. Kılıçarslan, M. Çelik, “RSigELU: A nonlinear activation function for deep neural networks”, *Expert Systems with Applications*, 174, 114805 (2021).
91. V. Nair, G. E. Hinton, “Rectified linear units improve restricted Boltzmann machines”, *In Proceedings of the 27th international conference on machine learning (ICML-10)*, 807–814 (2010).
92. Varlı, M., “Derin Öğrenme Tabanlı Epileptik Nöbet Teşhisi”, (Doctoral dissertation) (2022).
93. Krittanawong, C., Johnson, K. W., Rosenson, R. S., Wang, Z., Aydar, M., Baber, U., ... & Narayan, S. M., “Deep learning for cardiovascular medicine: a practical primer”, *European heart journal*, 40(25), 2058-2073 (2019).
94. Das, M. K., & Ari, S., “ECG beats classification using mixture of features”, *International scholarly research notices*, 2014, 12 (2014).
95. Kiranyaz, S., Ince, T., Hamila, R., & Gabbouj, M., “Convolutional neural networks for patient-specific ECG classification”, *In 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2608-2611 (2015).
96. Xiong, Z., Stiles, M. K., & Zhao, J., “Robust ECG signal classification for detection of atrial fibrillation using a novel neural network”, *In 2017 Computing in Cardiology (CinC)*, 1-4 (2017).

97. Li, D., Zhang, J., Zhang, Q., & Wei, X., “Classification of ECG signals based on 1D convolution neural network”, *In 2017 IEEE 19th International Conference on e-Health Networking, Applications and Services (Healthcom)*, 1-6 (2017).
98. Li, J., Si, Y., Xu, T., & Jiang, S., “Deep convolutional neural network based ECG classification system using information fusion and one-hot encoding techniques”, *Mathematical problems in engineering*, 2018 (2018).
99. Yildirim, Ö., “A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification”, *Computers in biology and medicine*, 96, 189-202 (2018).
100. Baloglu, U. B., Talo, M., Yildirim, O., San Tan, R., & Acharya, U. R., “Classification of myocardial infarction with multi-lead ECG signals and deep CNN”, *Pattern Recognition Letters*, 122, 23-30 (2019).
101. Shaker, A. M., Tantawi, M., Shedeed, H. A., & Tolba, M. F., “Generalization of convolutional neural networks for ECG classification using generative adversarial networks”, *IEEE Access*, 8, 35592-35605 (2020).
102. Mousavi, S., Afghah, F., Khadem, F., & Acharya, U. R., “ECG Language processing (ELP): A new technique to analyze ECG signals”, *Computer Methods and Programs in Biomedicine*, 202, 105959 (2021).
103. Şehirli, E., & Turan, M. K., “A novel method for segmentation of QRS complex on ECG signals and classification of cardiovascular diseases via a hybrid model based on machine learning”, *International Journal of Intelligent Systems and Applications in Engineering*, 9 (1), 12-21 (2021).
104. G. B. Moody, and R. G. Mark, “The impact of the MIT-BIH Arrhythmia Database”, *IEEE Engineering in Medicine and Biology Magazine*, 20 (3), 45-50 (2001).
- A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C. K. Peng, H. E. Stanley, “PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals”, *Circulation*, 101 (23), 1-6 (2000)
105. LeCun, Y., Bengio, Y., & Hinton, G., “Deep learning”, *Nature*, 521(7553), 436-444 (2015).
106. Jeny, A. A., Junayed, M. S., & Atik, S. T., “PassNet-Country Identification by Classifying Passport Cover Using Deep Convolutional Neural Networks”, *In 2018 21st International Conference of Computer and Information Technology (ICCIT)*, 1-6 (2018).
107. Traore, B. B., Kamsu-Foguem, B., & Tangara, F., “Deep convolution neural network for image recognition”, *Ecological Informatics*, 48, 257-268 (2018).

108. Indolia, S., Goswami, A. K., Mishra, S. P., and Asopa, P., "Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach", *International Conference on Computational Intelligence and Data Science*, 132: 679–688 (2018)
109. Venna, S. R., Tavanaei, A., Gottumukkala, R. N., Raghavan, V. V., Maida, A. S., & Nichols, S., "A novel data-driven model for real-time influenza forecasting", *Ieee Access*, 7, 7691-7701, (2018).
110. Landi, F., Baraldi, L., Cornia, M., & Cucchiara, R., "Working memory connections for LSTM", *Neural Networks*, 144, 334-341, (2021).
111. Visa, S., Ramsay, B., Ralescu, A. L., & Van Der Knaap, E., "Confusion matrix-based feature selection", *MAICS*, 710(1), 120-127 (2011).
112. Parikh, R., Mathai, A., Parikh, S., Sekhar, G. C., & Thomas, R., "Understanding and using sensitivity, specificity and predictive values", *Indian journal of ophthalmology*, 56(1), 45 (2008).
113. Fawcett, T., "An introduction to ROC analysis", *Pattern Recognition Letters*, 27 (8): 861-874 (2006).
114. Chicco, D., & Jurman, G., "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation", *BMC genomics*, 21(1), 1-13 (2020).
115. DeLong, E. R., DeLong, D. M., and Clarke-Pearson, D. L., "Comparing the areas under two or more correlated receiver operating characteristic curves: a nonparametric approach", *Biometrics*, 44 (3): 837-845 (1988).
116. Powers, D. M. W., "Evaluation: From precision and recall and F-Measure to ROC, informedness, markedness & correlation", *Journal of Machines Learning Technologies*, 2 (1): 37-63 (2011).
117. Luo, K., Li, J., Wang, Z., & Cuschieri, A., "Patient-specific deep architectural model for ECG classification", *Journal of healthcare engineering*, 2017, 13 (2017).
118. Zhai, X., & Tin, C., "Automated ECG classification using dual heartbeat coupling based on convolutional neural network", *IEEE Access*, 6, 27465-27472 (2018).
119. Pławiak, P., & Acharya, U. R., "Novel deep genetic ensemble of classifiers for arrhythmia detection using ECG signals", *Neural Computing and Applications*, 32(15), 11137-11161 (2020).
120. Yıldırım, Ö., Pławiak, P., Tan, R. S., & Acharya, U. R., "Arrhythmia detection using deep convolutional neural network with long duration ECG signals", *Computers in biology and medicine*, 102, 411-420 (2018).

121. Hanbay, K., “Deep neural network based approach for ECG classification using hybrid differential features and active learning”, *IET Signal Processing*, 13(2), 165-175 (2018).
122. Kachuee, M., Fazeli, S., & Sarrafzadeh, M., “Ecg heartbeat classification A deep transferable representation”, *In 2018 IEEE International Conference on Healthcare Informatics (ICHI)*, 443-444 (2018).
123. Guo, L., Sim, G., & Matuszewski, B., “Inter-patient ECG classification with convolutional and recurrent neural networks”, *Biocybernetics and Biomedical Engineering*, 39(3), 868-879 (2019).
124. Alquran, H., Alqudah, A. M., Abu-Qasmieh, I., Al-Badarneh, A., & Almashaqbeh, S., “ECG classification using higher order spectral estimation and deep learning techniques”, *Neural Network World*, 29(4), (2019).
125. Hasan, N. I., & Bhattacharjee, A., “Deep learning approach to cardiovascular disease classification employing modified ECG signal from empirical mode decomposition”, *Biomedical Signal Processing and C*, 52, 128–140 (2019).
126. Shaker, A. M., Tantawi, M., Shedeed, H. A., & Tolba, M. F., “Generalization of convolutional neural networks for ECG classification using generative adversarial networks”, *IEEE Access*, 8, 35592-35605 (2020).
127. Ullah, A., Anwar, S. M., Bilal, M., & Mehmood, R. M., “Classification of arrhythmia by using deep learning with 2-D ECG spectral image representation”, *Remote Sensing*, 12(10), 1685 (2020).
128. Peimankar, A., & Puthusserypady, S., “DENS-ECG A deep learning approach for ECG signal delineation”, *Expert Systems with Applications*, 165, 113911 (2021).
129. Farag, M. M. A., “Self-Contained STFT CNN for ECG Classification and Arrhythmia Detection at the Edge”, *IEEE Access*, 10, 94469-94486, (2022).

ÖZGEÇMİŞ

Tuğba TAŞBAŞI ilk ve orta öğrenimini 60. Yıl Vali Nafiz Kayalı İlköğretim Okulu'nda tamamlamıştır. Lise öğrenimini 2009-2013 yılları arasında Karabük'ün Karabük Anadolu Öğretmen Lisesi'nde okumuştur. 2014-2019 yılları arasında, ilk sene hazırlık olmak üzere Karabük Üniversitesi Tıp Mühendisliği lisans eğitimini tamamlamıştır. 2020 Ocak ayında Karabük Üniversitesi Biyomedikal Mühendisliği bölümünde yüksek lisansa başlamıştır. Güncel çalışma ve ilgi alanları; veri bilimi, veri analizi, makine öğrenmesi, derin öğrenme, istatistik, görüntü işleme ve Python, Matlab, C#, Labview programlama dilleridir.