

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DERİN ÖĞRENME ALGORİTMALARININ EKG ARİTMİLERİNİN
SINIFLANDIRILMASINDA DEĞERLENDİRİLMESİ

DOKTORA TEZİ

Özgür TOMAK

TRABZON
ARALIK 2018



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DERİN ÖĞRENME ALGORİTMALARININ EKG ARİTMİLERİNİN
SINIFLANDIRILMASINDA DEĞERLENDİRİLMESİ

Özgür TOMAK

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
DOKTOR (ELEKTRONİK MÜHENDİSLİĞİ)
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 12 / 11 /2018

Tezin Savunma Tarihi : 14/ 12 /2018

Tez Danışmanı Prof. Dr. Temel KAYIKÇIOĞLU

Trabzon 2018

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALINDA
Özgür TOMAK Tarafından Hazırlanan

DERİN ÖĞRENME ALGORİTMALARININ EKG ARİTMİLERİNİN
SINIFLANDIRILMASINDA DEĞERLENDİRİLMESİ

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 27 /11/2018 gün ve 1780 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
DOKTORA TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

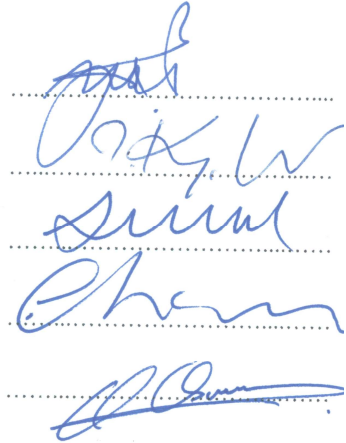
Başkan : Prof. Dr. Yaşar BECERİKLİ

Üye : Prof. Dr. Temel KAYIKÇIOĞLU

Üye : Prof. Dr. Ali GANGAL

Üye : Prof. Dr. Cemal KÖSE

Üye : Prof. Dr. ONUR OSMAN



Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü

ÖNSÖZ

Elektrokardiyogram (EKG) kalbe ait elektriksel aktivitenin kaydedilmesiyle elde ettiğimiz biyoelektriksel bir sinyaldir. Bu tezin temel amacı EKG kayıtlarında dalgacık katsayılarının, Hjorth parametrelerinin ve morfolojik özniteliklerin öznitelik olarak kullanıldığı aritmi sınıflandırılmasında derin öğrenme ve temel sınıflandırma yöntemlerinin karşılaştırılmasıdır.

Çalışmamın her aşamasında önerileri ile beni yönlendiren, ihtiyaç duyduğum her an benden yardımını esirgemeyen, öğrencisi olmaktan onur duyduğum sayın Prof. Dr. Temel KAYIKÇIOĞLU'na verdiği cesaret ve desteğinden dolayı sonsuz teşekkür ve şükranlarımı sunarım. Ayrıca Bu süreç boyunca ve hayatımın her anında yanımda olan, her türlü fedakârlığı gösteren aileme saygı ve sevgilerimi sunarım.

Özgür TOMAK
Trabzon 2018

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduđum “Derin Öğrenme Algoritmalarının EKG Aritmilerinin Sınıflandırılmasında Deđerlendirilmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Temel KAYIKÇIOĐLU ‘nun sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, başka kaynaklardan aldıđım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiđimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 14/12/2018

Özgür TOMAK

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	IX
SUMMARY	X
ŞEKİLLER DİZİNİ.....	XI
TABLolar DİZİNİ.....	XIII
SEMBOLLER DİZİNİ	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Elektrokardiyogram	2
1.2.1. Tekli dipol modeli.....	4
1.2.2. EKG Derivasyonları	8
1.3. Aritmiler.....	13
1.3.1. Erken Ventriküler Kasılma	13
1.3.2. Atriyal Prematüre Atım	15
1.3.3. Ventriküler ve Normal Atım Füzyonu.....	15
1.3.4. Dal Bloğu Atımı.....	16
1.3.5. Sağ Dal Bloğu Atımı.....	16
1.3.6. Supraventriküler Prematür veya Ektopik Atım.....	17
1.3.7. Düğüm Kaçış Ritmi	19
1.3.8. Sınıflandırılmaz Vuruşlar.....	19
1.4. Literatür Araştırması.....	20
1.4.1. Dalgacık Dönüşümü Kullanılarak Yapılan Çalışmalar	20
1.4.2. Hjørth Tanımlayıcıları Kullanılarak Yapılan Çalışmalar	24
1.4.3. Morfolojik Öznitelikler Kullanılarak Yapılan Çalışmalar.....	26
1.4.4. Yapay Zekâ Tekniklerini Kullanan Çalışmalar	28

1.4.5.	Gerçek Zamanlı Aritmi Tespiti Alanında Yapılan Çalışmalar	29
1.4.6.	Derin Öğrenme Alanında Yapılan Çalışmalar	32
1.5.	Tezin Motivasyonu ve Konusu	35
2.	YAPILAN ÇALIŞMALAR	38
2.1.	Önişleme Yöntemleri	38
2.1.1.	Dalgacık Tabanlı Sıkıştırma	38
2.1.2.	Dalgacık Yöntemiyle Gürültüden Kurtulma	40
2.1.3.	Trend Eliminasyonu, Başlangıç Düzeltmesi ve Normalleştirme	40
2.2.	Öznitelik Çıkarma Yöntemleri	41
2.2.1.	Dalgacık Yöntemi Kullanılarak Aritmi Tespiti	41
2.2.2.	Hjorth Tanımlayıcılar Kullanarak Aritmi Tespiti	45
2.2.3.	Morfolojik Öznitelikler Kullanılarak EKG Sinyalinde Aritmi Tespiti	48
2.3.	Sınıflandırma Yöntemleri	50
2.3.1.	Destek Vektör Makinesi	51
2.3.1.1.	Doğrusal DVM	51
2.3.1.2.	Kuadratik DVM	53
2.3.1.3.	Kübik DVM	53
2.3.1.4.	Hassas Gauss DVM	53
2.3.1.5.	Orta Seviye Gauss DVM	54
2.3.1.6.	Yüzeysel Gauss DVM	54
2.3.2.	K-En Yakın Komşu Sınıflandırması	54
2.3.2.1.	Hassas K-EYK	55
2.3.2.2.	Orta Seviye K-EYK	55
2.3.2.3.	Yüzeysel K-EYK	56
2.3.2.4.	Kosinüs K-EYK	56
2.3.2.5.	Kübik K-EYK	56
2.3.2.6.	Ağırlıklı K-EYK	56
2.3.3.	Karar Ağaçları	57
2.3.3.1.	Basit Karar Ağacı	57
2.3.3.2.	Orta Seviye Karar Ağacı	58
2.3.3.3.	Kompleks Karar Ağacı	58
2.3.4.	Diskriminant Analiz	58

2.3.4.1.	Doğrusal Diskriminant Analiz	58
2.3.4.2.	Kuadratik Diskriminant Analiz.....	59
2.3.5.	Lojistik Regresyon	59
2.3.6.	Topluluk Sınıflandırıcıları	59
2.3.6.1.	Geliştirilmiş Karar Ağaçları.....	60
2.3.6.2.	Torbalama Karar Ağaçları	61
2.3.6.3.	Altuzay Ayırımı	61
2.3.6.4.	Altuzay K-EYK	61
2.3.6.5.	RUSGeliştirilmiş Ağaçlar	61
2.3.7.	Derin Öğrenme	62
2.3.7.1.	Derin Öğrenmenin Biyoinformatik Araştırmalarda Kullanımı	62
2.3.7.2.	Konvolüsyonel Sinir Ağı	70
2.3.7.2.1.	Konvolüsyon Tabakası	72
2.3.7.2.2.	Rektifiye Edilmiş Doğrusal Birim.....	75
2.3.7.2.3.	Havuzlama Katmanı	76
2.3.7.2.4.	Tamamen Bağlanmış Katman	77
2.3.7.2.5.	Dropout Katmanı	77
2.3.7.2.6.	Softmax.....	79
2.3.7.2.7.	KSA Mimarisi	80
2.3.7.3.	İğnecikli Sinir Ağı	82
2.4.	Eğitim ve Test.....	90
2.4.1.	Veri Tabanı	90
2.4.2.	Doğruluk, Hassaslık ve Özgünlük	97
2.5.	Gerçek Zamanlı Aritmi Tespiti.....	98
3.	BULGULAR	103
3.1.	Dalgacık Katsayıları Kullanılarak Yapılan Analizin Sonuçları.....	103
3.2.	Hjorth Tanımlayıcıları Kullanılarak Yapılan Analizin Sonuçları.....	114
3.3.	Morfolojik Öznitelikler Kullanılarak Yapılan Analizin Sonuçları.....	120
3.4.	EKG Verilerinin Öznitelik Olarak Kullanılması	124
3.5.	Değişik Özniteliklerin Aritmi Türlerine Göre Performans Değerleri.....	126
3.6.	Gerçek Zamanlı Aritmi Tespitinde Başarı Seviyeleri.....	132
4.	SONUÇLAR	135

5. KAYNAKLAR.....	141
ÖZGEÇMİŞ.....	155



Doktora Tezi

ÖZET

DERİN ÖĞRENME ALGORİTMALARININ EKG ARİTMİLERİNİN
SINIFLANDIRILMASINDA DEĞERLENDİRİLMESİ

Özgür TOMAK

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Temel KAYIKÇIOĞLU
2018, 155 Sayfa

Ritim bozukluğu olarak da bilinen aritmi erken bir aşamada tespit edilmelidir. Bu süreçte doktorlara yardım edebilmek ve hızlı bir şekilde teşhis için klinik karar destek sistemlerine ihtiyaç duyulmaktadır. Çalışmada öznitelik olarak dalgacık katsayıları, morfolojik öznitelikler ve Hjorth parametreleri incelenmiş ve karşılaştırılmıştır. Dokuz aritmi sınıfını sınıflandırmak hedeflenmiştir. Sınıflandırma aşamasında temel sınıflandırıcılar olarak Ağaç yöntemleri, K En Yakın Komşuluk algoritmaları, Destek Vektör Makineleri, Topluluk sınıflandırıcıları, Lojistik Regresyon ve Diskriminant Analiz kullanılmıştır. Derin öğrenme ile sınıflandırmada ise Konvolüsyonel Sinir Ağları ve İğnecikli Sinir Ağları analizi yapılmıştır. Ayrıca gerçek zamanlı aritmi tespiti için bir modelde geliştirilmiştir. Tüm analizler için hızlı karar verme imkânı veren ve doğruluğu yüksek sistemler oluşturulması hedeflenmiştir.

Sinyali, bir öznitelik kümesi kullanmadan girdi olarak kullanarak, hesaplama yükünü azaltmak ve konvolüsyonel sinir ağındaki sınıflandırmaya yönelik işlemleri basitleştirmek mümkündür. Öznitelik seçimi ve konvolüsyonel sinir ağının birlikte kullanımı ile daha başarılı sonuçlar elde edilebilir. Böylece, hızlı bir şekilde öğrenebilen ve yüksek doğruluk elde edebilen optimize edilmiş bir konvolüsyonel sinir ağı tanımlanabilir.

Anahtar Kelimeler: Elektrokardiyogram (EKG), Aritmi, Sınıflandırma, Derin Öğrenme.

PhD. Thesis

SUMMARY

Evaluation of Deep Learning Algorithms in Classification of ECG Arrhythmias

Özgür TOMAK

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical-Electronics Engineering Graduate Program
Supervisor: Prof. Dr. Temel KAYIKÇIOĞLU
2018, 155 Pages

Arrhythmia, also known as rhythm disturbance, should be detected at an early stage. Clinical decision support systems are needed to help doctors and diagnose quickly. The wavelet coefficients, morphological properties, and Hjorth parameters are studied and compared in the study. It is aimed to classify nine arrhythmia classes. Tree methods, K Nearest Neighborhood algorithms, Support Vector Machines, Ensemble classifiers, Logistic Regression and Discriminant Analysis, were used as basic classifiers in the classification phase. Convolutional neural networks and spiking neural networks were analyzed in the classification with deep learning. Also, a model for real-time arrhythmia detection have been developed. It is aimed to create systems with quick decision making and high accuracy for all analyzes.

By using the signal as input without using a set of features, it is possible to reduce the computational load and simplify the operations for classification in the convolutional neural network. More successful results can be achieved with the combination of feature selection and usage of the convolutional neural network. Thus, an optimized convolutional neural network which can learn quickly and achieve high accuracy can be defined.

Key Words: Electrocardiogram (ECG), Arrhythmia, Classification, Deep Learning.

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.1. Bir miyokardiyal hücredeki akım nedeniyle dipol alanı (Clifford vd., 2006)....	4
Şekil 1.2. Merkezi olarak yerleştirilmiş idealize edilmiş küresel gövde(Clifford vd., 2006)	5
Şekil 1.3. Kalp döngüsünde normal kalbin geometrisi (Clifford vd., 2006)	7
Şekil 1.4. Oniki kanal EKG standart elektrot dizilimi (Goldberger vd., 2017).....	8
Şekil 1.5. Kalp eksen ve derivasyon açısı bilgisi (Goldberger vd., 2017)	9
Şekil 1.6. Normal bir EKG yapısı(Clifford vd., 2006)	11
Şekil 1.7. 12 kanallı EKG’de EVK (URL-6, 2018).....	14
Şekil 1.8. 12 kanallı EKG’de APA(URL-6, 2018).....	15
Şekil 1.9. 12 kanallı EKG’de VNAf (URL-7, 2018).....	16
Şekil 1.10. 12 kanallı EKG’de DBA(URL-7, 2018)	17
Şekil 1.11. 12 kanallı EKG’de SDBA(URL-7, 2018).....	18
Şekil 1.12. 12 kanallı EKG’de SPEA(URL-7, 2018).....	18
Şekil 1.13. 12 kanallı EKG’de DKR(URL-7, 2018).....	19
Şekil 2.1. Ön işlem adımları	41
Şekil 2.2. Örnek bir konvolüsyon tabakası (URL-4, 2018).....	73
Şekil 2.3. ReDB katmanının nasıl çalıştığını gösteren bir örnek (URL-3, 2018).....	75
Şekil 2.4. Havuzlama katmanının nasıl çalıştığını gösteren bir örnek (URL-3, 2018)	76
Şekil 2.5. Tamamen bağlı bir tabakanın işlenmesi süreci (URL-3, 2018).....	78
Şekil 2.6. Örnek bir Dropout yapısı (URL-4, 2018).....	79
Şekil 2.7. Kullandığımız ilk KSA mimarisi.	82
Şekil 2.8. Kullandığımız ikinci KSA mimarisi.....	82
Şekil 2.9. KSA ve İSA modellerinin karşılaştırılmalı gösterimi (URL-5, 2018).....	84
Şekil 2.10. Gerçek zamanlı aritmi tespitinde geliştirilen simulink modeli.	101
Şekil 2.11. Simulink modeline ait giriş.	101
Şekil 2.12. Gerçek zamanlı aritmi tespitinde çıkış ekranı.	102
Şekil 3.1. Torbalama Karar Ağaçları metodunun blok diyagramı.....	105
Şekil 3.2. Dalgacık katsayılarıyla yapılan ilk KSA ile analiz doğruluk seviyeleri.	112
Şekil 3.3. Dalgacık katsayılarıyla yapılan ikinci KSA ile analiz doğruluk seviyeleri.....	113
Şekil 3.4. Dalgacık katsayılarıyla yapılan İSA’nın zamana göre doğruluğu.....	114

Şekil 3.5. Hjorth Tanımlayıcılarla ilk KSA ile analiz doğruluk seviyeleri.	116
Şekil 3.6. Hjorth Tanımlayıcılarla ikinci KSA'da doğruluk seviyeleri.	116
Şekil 3. 7. Hjorth Tanımlayıcılarla İSA'nın zamana göre doğruluğu.	117
Şekil 3.8. Morfolojik özniteliklerle ilk KSA'nın analiz doğruluk seviyeleri.	121
Şekil 3.9. Morfolojik özniteliklerle ikinci KSA'nın analiz doğruluk seviyeleri.	121
Şekil 3.10. Morfolojik özniteliklerin kullanıldığı İSA'nın zamana göre doğruluğu.	122
Şekil 3.11. EKG verilerinin öznitelik olarak kullanıldığı ilk KSA'nın doğruluğu.	125
Şekil 3.12. EKG verilerinin öznitelik olarak kullanıldığı ilk KSA'nın doğruluğu.	125



TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. EKG'nin Dalgaları Ve Karşılık Geldiği Olaylar (Houghton ve Gray, 2008).....	13
Tablo 2.1. Aritmi veri tabanı dosyalarının içeriğinde tespit edilenler.....	91
Tablo 3. 1. Db1 kullanarak 5. seviye ayrıştırılma sonuçları.....	108
Tablo 3. 2. Sıkıştırılmış sinyallerde Db1 kullanarak 5. seviye ayrıştırılma sonuçları.....	109
Tablo 3.3. Db6 dalgacık 5. seviye sıkıştırılmış sinyallerde sulunan sonuçlar.....	110
Tablo 3.4. Torbalama karar ağaçlar sınıflandırması 12 kanal kayıt sonuçları.	111
Tablo 3.5. Hjorth Tanımlayıcılarla Eğitim Ve Test Başarıları.	118
Tablo 3.6. Hjorth Tanımlayıcılarla St. Petersburg veri tabanının sonuçları.	119
Tablo 3.7. Morfolojik Özniteliklerin Kullanıldığı Sınıflandırma Sonuçları.	123
Tablo 3.8. Dalgacık Katsayılarıyla Dokuz Sınıflı Kümede Performans Karşılaştırması ..	126
Tablo 3.9. Hjorth Tanımlayıcılarıyla Dokuz Sınıflı Kümede Performans Karşılaştırması	128
Tablo 3.10. Morfolojik Özniteliklerin Dokuz Sınıflı Kümede Performansları	130
Tablo 3.11. Gerçek zamanlı aritmi tespitinde kullanılan modelin sinyal başarısı.....	132
Tablo 4.1. Dalgacık yöntemin benzer çalışmalarla karşılaştırılması.....	137

SEMBOLLER DİZİNİ

ADD	:Ayrık Dalgacık Dönüşümü
AEK	:Atriyal Erken Kasılma
AF	:Atriyal Fibrilasyon
AKÖ	:Ani Kardiyak Ölüm
APA	:Atriyal Prematüre Atım
AV	:Atriyovenriküler
BBA	:Bağımsız Bileşen Analizi
ÇDD	:Çapraz Dalgacık Dönüşümü
ÇKA	:Çok Katmanlı Algılayıcı
DBA	:Dal Bloğu Atımı
DD	:Dalgacık Dönüşümü
DİA	:Derin İnanç Ağı
DSA	:Derin Sinir Ağı
DVM	:Destek Vektör Makinesi
EEG	:Elektroensefalografi
EMG	:Elektromiyografi
EKG	:Elektrokardiyogram
EOG	:Elektrookofiyografi
EVK	:Erken Ventriküler Kasılma
GTB	:Geçmeli Tekrarlayan Birimler
İSA	:İğnecikli Sinir Ağı
K-EYK	:K En Yakın Komşuluk
KHD	:Kalp Hızı Değişkenliği
KKY	:Konjestif Kalp Yetmezliği
KSA	:Konvolüsyonel Sinir Ağı
ReDB	:Rektifiye Edilmiş Doğrusal Birim
SA	:Sinoatriyal
SDBA	:Sağ Dal Bloğu Atımı
SDD	:Sürekli Dalgacık Dönüşümü
SPEA	:Supraventriküler Prematür veya Ektopik Atım

TBA	:Temel Bileşen Analizi
TSA	:Tekrarlayan Sinir Ağı
UKSBB	:Uzun Kısa Süreli Bellek Birimleri
VEK	:Ventriküler Erken Kasılma
VNAF	:Ventriküler ve Normal Atım Füzyonu
YOK	:Yığılmış Otomatik Kodlayıcı
YSA	:Yapay Sinir Ağı



1. GENEL BİLGİLER

1.1. Giriş

Ölüme yol açabilen oldukça yaygın karşılaşılan kalp hastalıkları günümüzde özellikle çevresel koşullar nedeniyle artış göstermektedir. Gelişen teknolojinin yardımıyla kalp hastalıklarının erken teşhisi daha kolaylaşmıştır. Bunun için en kolay yöntem EKG kayıtlarını incelemektir. EKG sinyallerinin hızlı ve doğru şekilde incelemesi için geliştirilen sistemler sayesinde pek çok kişinin hayatının kurtulması mümkün olabilir.

Kalp, ritmik olarak kasılan ve dolayısıyla vücudun her tarafındaki kan dolaşımını yönlendiren kaslardan (miyokard) oluşur. Kalp insanlarda yapı olarak iki karıncık (ventriküller) ve iki kulakçık (atriyumlar) olarak dört odacıktan oluşur. Kalp kapakçıkları, kanın bu dört odacıқта akışını kontrol eder. Ventriküller ve atriyumlar kanı pompalamak amacıyla sırayla kasılır ve rahatlar. Kalpte oluşan özel bir elektrik sinyali kalp atışlarını tetikler. Her normal kalp atışından veya sistolden önce, kalbin tamamı boyunca bir elektrik akımı dalgası geçer ve miyokard kontraksiyonunu tetikler. Elektriksel yayılım koordine bir düzen içinde kalbin yapısında yayılır ve etkili, eşgüdümlü bir sistol oluşturur. Bu da sonuçta, kişinin vücut yüzeyinde potansiyel farkın ölçülebilir bir şekilde değişmesine neden olur. Ortaya çıkan yükseltilmiş (ve filtrelenen) sinyal EKG olarak bilinir (Clifford vd., 2006). EKG analizi tıbbi değerlendirmelerin rutin bir parçasıdır. İnsan sağlığı ve hastalığında kalbin önemli rolü, EKG'nin kolay elde edilmesi ve EKG'nin elde edilme sürecinde kişiye zarar verme ihtimalinin olmaması çok sık tercih edilme sebeplerindedir. Kalp hastalıklarının erken teşhis edilmesinin tedavi sürecinde başarı sağlanmasında çok önemli bir yeri vardır. EKG sinyalinin otomatik analiz edilmesi için yapılan çalışmada sınıflandırmayı az hatayla yapılabilmesi için sinyalin ön işleme sürecinden geçirilmesi gerekmektedir. Böylece sinyalde bulunan istenmeyen etkiler ve gürültü azaltılabilir. EKG sinyallerine ait genel bir yapı vardır ancak yine de bu sinyaller kişiye göre önemli değişiklikler gösterir. Ayrıca EKG sinyallerinde pek çok nedenden dolayı gürültü oluşur. Düşük frekans gürültüleri elektrot ve vücut arasında oluşan empedans değişiminden kaynaklanır. Kas gürültüleri kişinin hareketlerinden kaynaklanmaktadır. Elektromanyetik gürültüler çevredeki cihazların oluşturduğu elektromanyetik alanlardan dolayı oluşur.

1.2. Elektrokardiyogram

Hücrelerin elektriksel aktivitesinin bir sonucu olarak vücudun içinde akım akar ve cilt yüzeyinde potansiyel farklılıklar meydana gelir ve bunlar uygun donanım kullanılarak ölçülebilir. Bu vücut yüzey potansiyellerinin zamanın bir fonksiyonu olarak grafiksel kaydı EKG olarak bilinir. EKG tıp alanında en çok kullanılan ve bilinen biyomedikal sinyaldir.


1786'da, Bologna Üniversitesi'ndeki bir İtalyan hekim ve fizikçi olan Dr. Luigi Galvani, elektrik akımının iskelet kaslarından kaydedilebilir olduğunu gösterdi. Parçalanmış kaslardan elektrik aktivitesi kaydetti. 1842 yılında, Pisa Üniversitesi'ndeki fizik profesörü Dr. Carlo Matteucci, elektrik akımının bir kurbağada her kalp atışına eşlik ettiğini gösterdi. Otuz beş yıl sonra, Londra'daki St. Mary Tıp Okulunun İngiliz fizyoloğu Augustus Waller, ilk insan EKG'si bir insanın göğsüne ve arkasına yerleştirilen bir kılcal elektrometre ve elektrotlar kullanarak yayınladı. Elektrik aktivitesinin ventriküler kasılmadan önce olduğunu gösterdi. 1891'de, University College London'ın İngiliz fizyologları William Bayliss ve Edward Starling, gelişmiş kılcal bir elektrometre kullanıp her vuruşta trifazik-kardiyak elektriksel aktivite gösterdi. Waller'in eserlerinden etkilenen Hollandalı bir fizyolog olan Dr. Willem Einthoven, kapiller elektrometreyi daha da geliştirdi ve ABCDE diye adlandırdığı beş sapma gösterdi. Kılcal sistemdeki ataleti ayarlamak için, bugün gördüğümüz eğrilerle sonuçlanan bir matematiksel düzeltme uyguladı. Descartes tarafından kurulan matematiksel geleneğin ardından, bu sapmaları adlandırmak için alfabe dizisini PQRST son kısmını kullandı. Bu dalga formlarını isimlendirmek için kullanılan EKG terimi ilk olarak 1893 tarihli Hollanda Tıbbi Toplantısında Einthoven tarafından ele alınmıştır. 1901 yılında, EKG'sinde kullandığı çok yüksek hassasiyetli yeni bir dizgi galvanometresini başarıyla geliştirdi. Onun cihazının ağırlığının 270 kg idi. Dize galvanometre EKG klinik kullanım için uygun hale geldikçe, daha pratik hale getirmek için iyileştirmeler yapıldı. Waller tarafından kaydedilen erken EKG'LER, dört ekstremitte ve ağız üzerinde beş elektrot kullandı ve farklı kombinasyonlar sonucunda elde edilen 10 derivasyon alındı. Einthoven, en düşük verimi, sağ bacak ve ağız elektrotlarının sağladığını düşündüğünden elektronların sayısını üçe indirdi. Ortaya çıkan bu bilgi, bugün için önemli bir kavram olan Einthoven üçgenini inşa etmek için kullanıldı. 1924 yılında, Einthoven, EKG icadından dolayı fizyoloji ve tıp dalına ait Nobel Ödülü'nü aldı. İlk elektrotlar, ekstremitelerin durulandığı elektrolit çözeltisi silindirleriydi. Kalbin normal elektriksel aktivasyonu sağ üst kadrandan sol alt kadrana

dođru olduđu için EKG izlemede pozitif sapmalar oluşturmak için pozitif elektrotlar sol bacak ve kol üzerine yerleřtirildi. Edinburgh Üniversitesi'nden Sir Edward Schafer, 1908 yılında klinik kullanım için bir dize galvanometre elektrografı satın alan ilk kiři olmuřtur ve ilk EKG makinesi, 1909 yılında ABD'de Dr. Alfred Cohn tarafından New York'taki Mt. Sinai Hastanesinde tanıtıldı. 20. yüzyılın ilk 30 yılında, üçlü EKG kullanımını özellikle daha taşınabilir hale getirmek için geliřtirildi. EKG'ler bařlangıçta aritmileri incelemek için kullanıldı. 1909'da, Londra Üniversitesi Koleji Hastanesi'nden Sir Thomas Lewis, düzensiz kalp atıřı tanısı konan "Delirium Cordis" in EKG kullanılarak atriyal fibrilasyonun (AF) bir sonucu olduđunu keřfetti. 1910'da miyokart enfarktüsünün klinik bir varlık olarak tanınmasından sonra, iskemik kalp hastalıđını düřündüren EKG paternlerini tanımak için giriřimlerde bulunulmuřtur. 1930'a kadar, kardiyak olmayan göđüs ağrısından farklılařan kardiyak EKG'nin önemi iyi bilinmektedir; Aslında, bazı modellerin tek bařına EKG'nin miyokard enfarktüsü tanısını dođrulamak için kullanılabileceđi kadar karakteristik olduđu düřünüldü. Üç uçlu EKG aritmileri deđerlendirmek için tatmin edici bir yöntem olsa da, yakın zamanda kalpte sessiz alanlar olduđu ve miyokard enfarktüsünün tespit edilemeyeceđi fark edildi. 1934'te Michigan Üniversitesi'nden Dr. Frank N. Wilson, "merkez terminal" kavramını geliřtirdi. Üç ekstremite elektrotunu bađlayarak, bir 'zemin' veya referans terminalini yansıtan bir merkezi negatif kanal yaratıldı. Bir galvanometreden bu zemine bađlanan vücut yüzeyinden gelen bir elektrot, bu noktadaki potansiyel farkı ve sıfır olarak düřünülen řeyleri ölçtü. 1938'de Amerikan Kalp Derneđi ve Büyük Britanya Kardiyak Cemiyeti, V1'den V6'ya kadar olan kaydetme önerilerini yayınladı. Böylece, göđüs derivasyonları belirlendi. 1942'de, New York'taki Lincoln Hastanesi'nden Dr. Emanuel Goldberger, Wilson'un merkez terminalini kullanarak, sol ve sađ kolların her birinde ve sol bacakta ek pozitif tek kutuplu uçlara bađlandı ve merkezi terminal ile tek kutuplu kanallar oluşturdu. Bu yöntem, 30 derecelik artıřlarla ön düzlemin daha ayrıntılı bir řekilde kapsanmasını sađladı. Bu yöntem ile řimdi bildiđimiz 12 kanallı EKG için temel atıldı. 1954 yılında Amerikan Kalp Derneđi, 12 kanallı EKG'nin standardizasyonu için önerilerini yayınladı. 1961 yılında Hubert Pipberger, EKG sinyallerindeki anormal yapıyı tespit eden bilgisayar sistemi tasarladı. 1974'de Minnesota Üniversitesi Tıp Fakültesi'nden Jay Cohn, akut inferior duvar miyokart enfarktüsünde sađ ventrikül disfonksiyon sendromunu tanımladı (Burch ve DePasquale, 1990). Bu yavař süreçteki her adımda, doktorlar EKG'yi temel bir klinik cihaz olarak benimsedi; ancak zamanla, önceki sınırlı yapılardaki eksiklikleri fark ettiler. Bu cihazın optimizasyonuna yol ačan bu teknolojiyi geliřtirmek için

doktorların ve bilim adamlarının tarafından eksikliklerin belirlenmesiydi. Ayrıca son yıllarda EKG alanında bilgisayarların kullanımının yaygınlaştı. Bilgisayarların bu alandaki kullanımı ve modern EKG cihazları yardımıyla EKG analizleri çok daha kolaylaşmıştır.


1.2.1. Tekli dipol modeli

Tekli dipol modeli, klinik EKG çalışması için bir çerçeve sağlamakta son derece yararlı basit matematiksel modeldir. Dipol modelinin iki bileşeni vardır. Bunlar kalbin elektriksel aktivitesinin bir gösterimi (dipolün kendisi) ve kalbi çevreleyen gövdenin geometrisi ve elektriksel özellikleri şeklinde ifade edilir (Clifford vd., 2006). İlk olarak, kalbin elektriksel aktivitesinin gösterimini göz önünde bulunduralım. Bir hareket potansiyeli bir hücreden (miyokarda) yayılırken, yayılım yönünde üretilen ilişkili bir hücre içi akım vardır. Bu, akım dipolü olarak adlandırılan EKG yüzeyinin temel elektrik kaynağıdır. Ayrıca, yayılma yönüne karşı akan eşit hücre dışı bir akım vardır ve bu nedenle yük muhafaza edilir. İletken ortamdaki tüm akım döngüleri kendilerini kapatır ve bir dipol alanı oluşturur. Kalbin herhangi bir zamanda elektriksel aktivitesi, aktif akım dipollerinin bir dağılımı ile temsil edilebilir. Genel olarak, sınıra karşılık gelen depolarize ve polarize doku arasındaki düzensiz bir yüzeyde bulunacaklardır. Bir miyokardiyal hücredeki akımın dipol alanı Şekil 1.1’de verilmiştir.



Şekil 1.1. Bir miyokardiyal hücredeki akım nedeniyle dipol alanı (Clifford vd., 2006)

Eğer kalp homojen bir izotropik iletken ortam içinde bulunduğu varsayılırsa ve büyüklüğüne göre yeterince büyük bir mesafeden gözlemlendiyse, o zaman bu bireysel akım dipollerinin tümü uzayda tek bir noktadan kaynaklandığı düşünülebilir. Kalbin toplam elektriksel aktivitesi, büyüklüğü ve yönü, tüm dakika dipollerinin vektör toplamı olan tek bir eşdeğer dipol olarak temsil edilebilir. Akımların ve potansiyellerin ortaya çıkan yüzey dağılımı, gövdenin elektriksel özelliklerine bağlıdır. Makul bir yaklaşım olarak, dipol modeli gövdenin bilinen homojenliğini göz ardı eder ve vücudu yarıçap, R ve iletkenlik σ doğrusal, izotropik, homojen, küresel bir iletken olarak ele alır. Kaynak, kürenin merkezinde yer alan yavaşça değişen zamana bağlı bir tek kutuplu dipol olarak temsil edilir. Gövde içindeki (ve yüzeyindeki) statik elektrik alanı, akım yoğunluğu ve elektrik potansiyeli, herhangi bir zamanda kalp vektörü ile dinamik olmayacak şekilde ilişkilidir. Doku empedansına bağlı reaktif terimler ihmal edilebilir (Clifford vd., 2006). Laplace denklemi daha sonra gövde üzerinde potansiyel dağılım sağlamak için çözülebilir. Merkezi olarak yerleştirilmiş idealize edilmiş küresel gövde yapısı Şekil 1.2’de verilmiştir.



Şekil 1.2. Merkezi olarak yerleştirilmiş idealize edilmiş küresel gövde(Clifford vd., 2006)

$$\phi(t) = \frac{\cos\theta(t)3|M(t)|}{4\pi\sigma R^2} \quad (1.1)$$

Denklem 1.1’de verilen $\theta(t)$, $M(t)$ kalp vektörünün yönü ile OA kürenin merkezini birleştiren kanal vektörü arasındaki açıdır. $|M|$ kalp vektörünün büyüklüğüdür. Daha genel olarak, gövde yüzeyindeki iki nokta arasındaki potansiyel fark Denklem 1.2’de verilmiştir.

$$V_{AB}(t) = M(t) \cdot L_{AB}(t) \quad (1.2)$$

L_{AB} , gövde üzerindeki A ve B noktalarını bağlayan kanal vektörüdür. Üç uzuv kanalından gelen potansiyellerin ortalaması alınarak bir referans merkezi terminali (CT) tanımlamak yararlıdır. Denklem 1.3’de ϕ_{CT} her zaman sıfır olmalıdır.


$$\phi_{CT}(t) = \phi_{RA}(t) + \phi_{LA}(t) + \phi_{LL}(t) \quad (1.3)$$

Denklem 1.3’de RA sağ kolunu gösterir, LA sol kolunu gösterir ve LL sol bacağı gösterir.

Kalbin bir pompa olarak performansı, öncelikle miyokardın kasılma ve gevşeme özelliklerine bağlıdır. Ayrıca göz önünde bulundurulması gereken diğer faktörler şunlardır: miyokard hücrelerinin geometrik yapısı, kalp dokusunun özellikleri, kalbin elektriksel ritmi, miyokardın metabolik taleplerini karşılamak için valvüler fonksiyon ve oksijenli kanın koroner arterler aracılığıyla verilmesinin yeterliliği. Kalbin duvarları mekanik bir sinsiyosit miyokardiyal hücrelerden oluşan dört adet kavite bölmesi vardır. Her haznenin çıkışında, kasılmasından sonra kapanan ve hazne gevşerken ve akış aşağı basınçları oda basıncını aştığında önemli ölçüde gerilemeyi önleyen bir valf bulunmaktadır. Sağ kalp, daha büyük bir sağ ventriküle giden küçük bir atriyumu içerir. Sağ atriyum, vücudun çoğundan kan alır ve sağ ventriküle besler. Sağ ventrikül kasıldığında kan, kanın oksijenli olduğu ve karbondioksitten kurtulduğu akciğerlere iletir. Sol atriyum akciğerlerden kan alır ve sol ventrikül içine iletir. Sol ventrikülün kuvvetli kasılmaları kanı aortadan vücudun geri kalanına doğru iter.

Şekil 1.3’de kalp döngüsünde normal kalbin geometrisi ve ortaya çıkan anlık elektriksel kalp vektörleri gösterilmiştir. Şekil, kalp atımının Sinoatriyal (SA) düğümündeki kökenini, atriyoventriküler (AV) düğümündeki bir gecikmeyi (böylece, ventriküller başlamadan önce, atriyum, kasılmayı bitirir), ve özel iletken lifler aracılığıyla

depolarizasyon dalgasının hızlandırılmış iletimi (böylece kalbin farklı bölümleri daha senkronize bir şekilde depolarize edilir) gösterir. İlk olarak, atriyal depolarizasyon gösterilmektedir. Depolarizasyon dalgası her iki atriyumda da azaldıkça, toplanma vektörü büyük ölçüde aşağıya, konunun sola ve biraz ön yüzüne doğru uzanır. Ardından AV düğümündeki gecikme vardır.



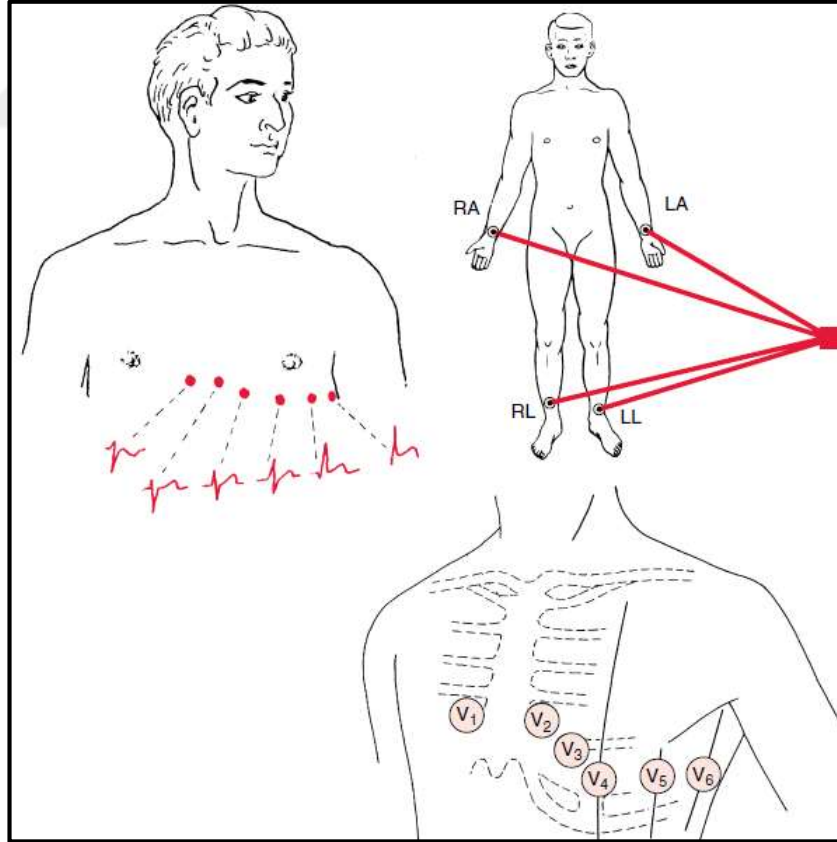
Şekil 1.3. Kalp döngüsünde normal kalbin geometrisi (Clifford vd., 2006)

Bu sırada, özel ortalama teknikleri kullanılmadığı sürece vücut yüzeyinde ölçülebilir bir elektriksel aktivite yoktur. Aktivite AV düğümde ortaya çıkar, sonra dallar ardından His demeti, depolarize olur. Sonraki aşama septal depolarizasyonudur. Septum, ventriküller arasındaki duvardır ve septumun sol tarafı boyunca uzanan büyük bir iletken lif demetidir. Aksiyon potansiyeli dalgası septal miyokarda girdiğinde soldan sağa doğru yayılma eğilimi gösterir ve sonuçta ortaya çıkan kalp vektörü kişinin sağına işaret eder. Daha sonra apikal depolarizasyon var ve sola hareket eden depolarizasyon dalgası, sağa doğru hareket eden dalga tarafından dengelenir. Ortaya çıkan vektör, kalbin tepesine doğru, büyük ölçüde aşağıya, kişinin sola ve biraz ön yüzüne doğru işaret eder. Sol ventrikül depolarizasyonunda ve geç sol ventrikül depolarizasyonunda sağ ventrikülde elektriksel aktivite vardır, ancak sol ventrikül daha iri olduğundan aktivitesi baskındır. Miyokardiyumun çeşitli bölümleri depolarize ettikten sonra, uyarma-kasılma vasıtasıyla daralırlar. Miyokardiyumun ölçülebilir

kardiyak vektör olmadığı depolarize olduğu bir dönem vardır. Son olarak, tek tek hücreler repolarize olmaya başlar ve başka bir şarj dalgası kalpten geçer, Süreç bu kez depolarize ve repolarize edici dokunun arayüzünde oluşturulan dipollerden kaynaklanır. Kalp daha sonra döngüyü yeniden başlatan başka bir elektriksel uyarana kadar dinlenme durumuna döner. EKG'deki repolarizasyon dalgaları genellikle depolarizasyon dalgaları ile aynı polaritede bulunur (Clifford vd., 2006).

1.2.2.EKG Derivasyonları


Kalpte oluşan elektriksel aktivitenin ölçülebilmesi vücudun belirli noktalarına elektrot yerleştirilmesi gereklidir. Konumlarına göre farklı derivasyonlar elde ederiz (Goldberger vd., 2017). Gövdenin etrafına altı elektrot yerleştirilirse, EKG, bu elektrotların (V1–6) ve merkezi terminalin her biri arasındaki farkı temsil eder. Kalbin yatay düzlemde aktivitesini bu elektrotlar ile kaydedebiliriz. Oniki kanal EKG standart elektrot dizilimi Şekil 1.4'de verilmiştir.



Şekil 1.4. Oniki kanal EKG standart elektrot dizilimi (Goldberger vd., 2017)

Ek elektrotlar, hastanın dört uç noktalarına yerleştirilir ve merkez terminal, uzuv kanallarından gelen potansiyellerin ortalamasıdır. EKG incelenirken derivasyonlardaki V harfi voltajı, 1. sıradaki R harfi sağ, 1. sıradaki L harfi solu, 2. sıradaki A harfi kolu, 2. sıradaki L harfi bacağı ifade eder. Başa konan a harfi güçlendirilmiş anlamındadır. Merkezi terminal ile uzuvlara takılan elektrotlar arasındaki potansiyel farklar diğer üç standart EKG kablosu için temeldir. Kanal I I, sol kol ve sağ kol arasındaki farkı verir. Kanal II, sol bacak ve sağ kol arasındaki farkı verir. Kanal III, sol bacak ve sol kol arasındaki farkı verir. Güçlendirilmiş uzuv kanalları, diğer iki uç noktasının potansiyellerinin ortalamalarına göre belirli bir uzuvdaki potansiyeli temsil eder. aVF, sol bacak ile kol uçlarının ortalaması arasındaki farktır. aVR, sağ kol ile sol bacak ve sol kolun ortalaması arasındaki farktır. aVL, sol kol ile sağ kol ve sol bacağın ortalaması arasındaki farktır.

Üç boyutlu aktivitenin görüntülenmesi için 12 kanal bulunmakta, bundan dolayı bilgi fazlalığı bulunmaktadır. Bununla birlikte, kalp vektörünü dikey olmayan eksenlere yansıtarak bu aşırı örnekleme, insan yorumlaması için daha kolay bir temsil sunma eğilimindedir ve elektrot yerleştirmedeki küçük tutarsızlıkları telafi eder. Dahası, vücut homojen bir küre değildir. Kalp vektörünün zamansal yapısı, standart ön düzlem uzuv uçlarının geometrisi ile birleştirilir. QRS eksenini, izoelektrik kanala (pozitif ve negatif yönde eşit kuvvetlere sahip kanal) diktir. QRS eksenindeki önemli değişiklikler, kardiyak problemlerin göstergesi olabilir (Clifford vd., 2006). Kalp eksen ve derivasyon açısı bilgisi (90°) Şekil 1.5’de verilmiştir.




Şekil 1.5. Kalp eksen ve derivasyon açısı bilgisi (Goldberger vd., 2017)

Şekil 1.6'da normal bir EKG yapısını görmekteyiz. Şekildeki analiz, EKG'deki tipik grafik-kâğıt sunum formatını kullanmaktadır. Her kutu 1 mm²'dir ve EKG kâğıdı genellikle 25 mm / s hızla hareket edecek şekilde ayarlanır. Bu nedenle, her bir kutu 0.04 saniyeyi temsil eder. Genlik ölçeği kare başına 0,1 mV olarak ayarlanır. EKG'deki farklı dalgaların konumları P, Q, R, S, T ve U harfleri kullanarak işaretlenmiştir.

Her bir dalga, kalbin belirli bir bölgesinin depolarizasyonunu (elektriksel boşalma) veya repolarizasyonu (elektriksel yeniden şarj etme) temsil eder. Normal kalpte her vuruş, sağ atriyumda kadar yükselen SA düğümün deşarjı (depolarizasyon) ile başlar. Bu, her dakika 60–100 kez meydana gelen bir olaydır. SA düğümünün depolarizasyonu standart EKG'de belirgin bir dalgaya neden olmaz. İlk tespit dalgası, elektriksel uyarının, SA düğümünden yayılıp atriyumda depolarize ettiği zaman ortaya çıkar ve bu P dalgasını üretir (Houghton ve Gray, 2008).

Atriyum nispeten az kas içerir, bu nedenle atriyal depolarizasyon ile üretilen voltaj nispeten küçüktür. Çoğu elektrotun bakış açısına göre, elektrik onlara doğru akar ve P dalgası pozitif (yukarı doğru) bir sapma oluşturur. Buna istisna, elektriğin dışarı akıyor görüldüğü aVR'dir. Atriyumdan geçtikten sonra, elektriksel uyarı, sağ atriyumda alçakta bulunan AV düğümüne ulaşır. AV düğümü, normalde, bir elektriksel uyarıların ventriküllere ulaşabildiği tek yoldur, atriyal miyokardın geri kalanı, ventrikülden, lifli dokunun bir iletken olmayan halkası ile ayrılmaktadır. AV düğümünün aktivasyonu, EKG'de belirgin bir dalga oluşturmaz, fakat P dalgası ile müteakip Q veya R dalgası arasındaki zaman aralığına katkıda bulunur. Bu, iletimi geciktirerek yapar ve bunu yaparken bir güvenlik mekanizması olarak görev yapar, hızlı atriyal dürtülerin (örneğin atriyal çarpıntı veya fibrilasyon sırasında) aynı hızda ventriküllere yayılmasını önler. Depolarizasyon dalgasının SA düğümündeki başlangıç noktasından, atriyumdan ve AV düğümünden ventriküler kas içine geçmesi için geçen zaman PR aralığı olarak adlandırılır. Bu, P dalgasının başlangıcından R dalgasının başlangıcına kadar ölçülür ve normalde 0.12 s ve 0.20 s arasında veya EKG kâğıdında üç ila beş küçük kare boyutundadır. Uyarı, AV düğümünü geçtikten sonra, interventriküler septuma geçen ve sol ve sağ dal kollarına ayrılan özel bir iletken yol olan His'in demetine girer.



Şekil 1.6. Normal bir EKG yapısı(Clifford vd., 2006)

Akım normalde interventriküler septumdaki demet dalları arasında, soldan sağa doğru akar ve bu, QRS kompleksinin ilk sapmasından sorumludur. Eğer QRS kompleksinin ilk sapması aşağıysa, buna Q dalgası denir. İlk yukarı sapma, bir Q dalgası takip edip etmese de, bir R dalgası olarak adlandırılır. Bir R dalgasından sonra aşağıya doğru bir sapma S dalgası olarak adlandırılır. Sağ dal dalı, sağ ventriküle depolarizasyon dalgasını yürütürken, sol dal kolunu, sol ventriküle dalga veren anterior ve posterior fasiküllere ayırır. İletim yolları, her iki ventrikülde hızla depolarizasyon dalgasını dağıtan Purkinje liflerine bölünerek sona ermektedir. QRS kompleksiyle temsil edilen ventriküllerin depolarizasyonu normal olarak 0.12 sn içinde tamamlanır. R dalgası veya S dalgasının büyük olup olmadığına bağlı olarak QRS kompleksleri pozitif veya negatif olur. Sol ventrikül sağdan çok daha fazla miyokard içerir ve bu nedenle depolarizasyon tarafından üretilen gerilim QRS kompleksinin şeklini belirleme eğiliminde olacaktır. QRS kompleksine bir S dalgası hâkim olacak ve negatif olacaktır. ST segmenti, miyokarddan daha fazla elektrik akımının geçemediği geçici bölgedir. S dalgasının sonundan T dalgasının başlangıcına kadar ölçülür. ST segmenti miyokard enfarktüsü ve iskeminin tanısında özellikle önemlidir. T dalgası, ventriküler miyokardın dinlenme durumunda doğru repolarizasyonunu temsil eder. QT aralığı, ventriküllerin aktivasyonu için toplam süreyi ve normal istirahat halindeki iyileşmeyi ölçer. U dalgasının kaynağı belirsizdir, ancak interventriküler septumun repolarizasyonunu veya ventriküllerin yavaş repolarizasyonunu temsil edebilir. U dalgaları tanımlamak zor olabilir ancak mevcut olduğunda en belirgin göğüs $V_2 - V_4$ 'de görülürler. SA ve AV düğümlerinin depolarizasyonları önemli olaylardır, ancak standart EKG'de kendiliğinden saptanabilir bir dalga oluşturmazlar. EKG'nin dalgaları ve karşılık geldiği olaylar Tablo 1.1'de verilmiştir. Tek kanallı EKG devresi insan vücudundan alınan sinyallerin elektriksel sinyal şekline dönüştürülmesi ile başlar. Sistemdeki sinyaller milivoltlar veya mikrovolt seviyelerinde olduğu için sinyallerin algılanması ve işlenmesi zor olur. Sinyallerin seviyesini yükseltmek için çok yüksek kazançla sahip enstrümantasyon yükselteçleri gereklidir. Sonrasında izolasyon yükselteci kullanılır. İzolasyon yükselteci muhtemel herhangi bir kaçak olması durumunda insan ve cihaz arasındaki korumayı sağlar. Yükseltmeden sonra EKG cihazı çalışma frekansının haricindeki sinyallerden kurtulmak amacıyla alçak ve de yüksek geçiren filtre kullanılır. 50 Hz'lik şehir şebekesine ait gürültü Notch filtre kullanılarak bastırılır. Filtre işlemleri takiben Analog Sayısal Filtreler ile sinyal sayısal yapıya çevrilir. Opto izolatör kullanarak cihaz ile kaydedici arasındaki izolasyon sağlanır.

Tablo 1.1. EKG'nin Dalgaları Ve Karşılık Geldiği Olaylar (Houghton ve Gray, 2008).

EKG olayı	Kardiyak olay
P dalgası	Atriyal depolarizasyon
PR aralığı	Atriyal depolarizasyon başlangıcından ventriküler depolarizasyon başlangıcına
QRS kompleksi	Ventriküler depolarizasyon
ST segmenti	Repolarizasyondan önce ventriküler elektrik aktivitesinde duraklama
T dalgası	Ventriküler repolarizasyon
QT aralığı	Ventriküler depolarizasyon ve repolarizasyon ile alınan toplam süre
U dalgası	Muhtemel nedenler yavaş ventriküler repolarizasyon, interventriküler septal repolarizasyon

1.3.Aritmiler


Aritmi tespiti sürecinde 12 kanallı EKG kaydı doktorların ihtiyaç duyduğu en önemli kaynaktır. Burada çalışmamızda özellikle tespit etmeyi hedeflediğimiz aritmi türlerinden bahsedilecektir. Bu aritmiler iskemi, iletim anormallikleri, koroner arter rahatsızlıkları ile ilişkilidir ve erken teşhisleri hayati öneme sahiptir. Normal bir EKG kaydında P dalgasından sonra QRS kompleksi gelir. P dalgalarının oluşma oranı dakikada 60 ile 100 arasındadır. P dalgalarının kanal 2'de yüksekliği 2.5 mm ve genişliği 0.11 saniyedir. PR aralığı 0.12 ile 0.20 saniye aralığındadır. QRS kompleksi 0.12 saniyedir. Q-T aralığı 0.42 saniyedir(URL-6, 2018).

1.3.1.Erken Ventriküler Kasılma

Kalbin sağ tarafında ortaya çıkan bir Erken Ventriküler Kasılma (EVK), önce sağ ventrikülü ve ardından sol ventrikülü aktive edecektir. Bu, sol dal bloğu olan bir hastada ventriküler aktivasyon dizisine benzerdir. EKG'de sağ taraftaki bir EVK sol dal bloğu bloğunda görülen QRS kompleksine benzemektedir. EVK'ları veya korunmamış ventriküler taşikardinin morfolojisini tanımlarken, sol dal bloğu paterni ve sağ dal bloğu paterni terimleri V1'e işaret eder. EVK, V1'de negatif (veya çoğunlukla negatif) ise, EVK'nın bir sol dal bloğu paterni vardır. V1'de pozitif olan bir EVK'nın sağ dal bloğu paternine sahip olduğu ve kalbin sol tarafından ima edildiği söylenir. Kalbin üst noktalarından çıkan bir EVK

yukarıdan aşağıya doğru hareket edecektir. EVK'nın elektrik eksenini aşağıya doğru yönlendirilecektir. Bu, EVK'nın, alt uçlarda, yani II, aVF ve III'de kuvvetli bir şekilde pozitif olacağı anlamına gelir. EVK sol ventrikül çıkış yolundan çıkarsa da, eksen hala aşağıya doğru yönlendirilir. Bununla birlikte, EVK'nın solunda, EVK'nın prekordiyal derivasyonlarda negatiften daha pozitif olduğu nokta da prekordiyal geçiş meydana gelecektir. Şekil 1.7'de gösterilen EKG, sağ ventrikül çıkış yolu EVK'nın tipik görünümünü göstermektedir (Akdemir vd., 2016).


Aritmojenik sağ ventrikül kardiyomyopatisi, sağ ventrikül çıkış yolu PVC'leri ve ventriküler taşikardininkine benzer morfolojilere sahip EVK'lar veya gözlenmeyen ventriküler taşikardiye neden olabilir. Aritmojenik kardiyomyopatiyi komplike eden ventriküler taşikardi, sağ ventrikül çıkış yolundan kaynaklanan ve sıklıkla egzersiz veya aktivite ile ilişkili olan EVK'lar gibidir. Normal sağ ventrikül büyüklüğünü ve fonksiyonunu gösteren iyi kalitede EKG, güven verici ve ekokardiyografi kesin değilse, özellikle aritmojenik kardiyomyopati, kardiyak sarkoidoz veya kardiyak amiloidoz şüphesi varsa, kardiyovasküler manyetik rezonans görüntüleme ek tanı ve prognostik veriler sağlayabilir (Akdemir vd., 2016). EVK için QRS kompleksi geniş yani 0.12 saniyeden daha uzundur.



Şekil 1.7. 12 kanallı EKG'de EVK (URL-6, 2018).

1.3.2.Atriyal Prematüre Atım

Sinoatriyal düğüm, kalp atımını normal olarak düzenlerken, atriyumun başka bir bölgesi sinoatriyal düğümden önce depolarize olursa ve böylece erken kalp atımını tetiklenirse ortaya çıkar. Atriyal Prematüre Atım (APA) anormal bir P dalgası içerir. P dalgaları küçük ve oldukça şekilsiz olduğundan, bir APA'daki fark genellikle incedir. Beklenenden daha erken gerçekleşir ve bunu telafi edici bir duraklama izler ancak bu tam telafi edici duraklama değildir(URL-6, 2018). Şekil 1.8'de gösterilen EKG, APA'ya ait tipik bir kaydı göstermektedir.




Şekil 1.8. 12 kanallı EKG'de APA(URL-6, 2018).

1.3.3.Ventriküler ve Normal Atım Füzyonu

Farklı kaynaklardan gelen elektriksel impulslar aynı zamanda kalbin aynı bölgesine hareket ettiğinde füzyon atımı meydana gelir. Kalbin doğal ritmi ve kalp pilinden gelen tetikleme aynı zamanda bir ventrikülün aynı parçasını aktive etmek için aynı zamana denk geldiğinde ve QRS kompleksinin yüksekliğinde ve konfigurasyonunda görünür değişikliğe neden olduğunda ventriküler füzyon atımları meydana gelebilir (Huff, 2006). Ventriküler ve Normal Atım Füzyonu (VNAF) Genellikle herhangi bir dengeleyici duraklama olmadan ortaya çıkar ve eş zamanlı kalp atış hızını önemli ölçüde değiştirmez. QRS konfigurasyonu, hem normal sinüs yapısının hem de VNAF'nun karakteristiklerini içerir ve genellikle bir P dalgası ile gerçekleşir. PS aralığı PR'dan daha kısa olamaz. Kompleksin terminal vektörü,

supraventriküler yapı tarafından üretilen şeklinden daima farklıdır(URL-7, 2018). Şekil 1.9'da gösterilen EKG ventriküler ve normal atım füzyonuna ait tipik bir kaydı göstermektedir.



Şekil 1.9. 12 kanallı EKG'de VNAf (URL-7, 2018).

1.3.4. Dal Bloğu Atımı

Dal Bloğu Atımı, DBA, kalbin atmasını sağlayan elektrik sinyallerinin bir gecikmeye uğraması veya gelmemesi durumudur. Bu kalp atışını yavaşlatabilir, bayılmaya ve ciddi komplikasyonlara neden olabilir. Geniş QRS kompleksine sahiptir. EKG, V1'de bir R ucu dalgası ve kanal I'de bir S dalgası gösterecektir. Başka normal bulgu, T dalgası uyumsuzluğudur. Başka bir deyişle, T dalgası QRS kompleksinin terminal sapmasının tersine sapacaktır. Şekil 1.10'da gösterilen EKG DBA'ya ait tipik bir kaydı göstermektedir.


1.3.5. Sağ Dal Bloğu Atımı

Sağ Dal Bloğu Atımı (SDBA) elektrik iletim sisteminin sağ dal kolundaki bir kalp bloğudur, V1'de dominant R dalgası ile sağ dal bloğu morfolojisine sahiptir(URL-7, 2018). SDBA geniş QRS kompleksine (120 ms'den uzun, 3 küçük kare) sahiptir. QRS kompleksi


sıklıkla sağ ventrikülün hızlı depolarizasyonunu yansıtan ve ardından sağ ventrikülün daha yavaş depolarizasyonunu gösteren ekstra bir sapma gösterir. V1'de ikincil R dalgası görülür. Diğer özellikler lateral derivasyonlarda yuvarlanmış uzun S dalgası ve septal derivasyonlarda T dalgası değişikliklerini içerir(URL-6, 2018). Şekil 1.11'de gösterilen EKG SDBA'ya ait tipik bir kaydı göstermektedir.

1.3.6.Supraventriküler Prematür veya Ektopik Atım


Supraventriküler Prematür veya Ektopik Atım (SPEA) , kalbin elektriksel iletimiyle ilişkili olan bir rahatsızlıktır. Bu, ventriküler veya atriyal miyokard içindeki ektopik odakların veya elektrik iletim sisteminin daha ince dallarından ek atımlara neden olan bir aritmi çeşididir. Şekil 1.12'de gösterilen EKG SPEA'ya ait tipik bir kaydı göstermektedir.



Şekil 1.10. 12 kanallı EKG'de DBA(URL-7, 2018)



Şekil 1.11. 12 kanallı EKG’de SDBA(URL-7, 2018).




Şekil 1.12. 12 kanallı EKG’de SPEA(URL-7, 2018).

1.3.7. Dügüm Kaçış Ritmi

Sinoatriyal düğümün depolarizasyon oranı, atriyoventriküler düğüm oranının altına düştüğünde, tek bir kaçış ritmi olarak ya da bir dizi kaçış ritmi olarak AV düğümünde bir yerlerden bir depolarizasyon meydana gelecektir. Dügüm (birleşim) kaçış ritminde (DKR) P-dalga morfolojisi ektopik odak alanına bağlıdır, tersine dönmüştür ve QRS kompleksinden önce, sırasında veya sonrasında görünebilir. P-dalgası QRS kompleksinden önce meydana gelirse, PR aralığı 0.12 saniyeden daha az olacaktır. QRS kompleksi genellikle süre ve morfolojik olarak normal olacaktır(URL-7, 2018). Şekil 1.13'de gösterilen EKG Dügüm Kaçış Ritmine ait tipik bir kaydı göstermektedir

1.3.8. Sınıflandırılmaz Vuruşlar

Sınıflandırılmaz vuruşlar diğer aritmi sınıflara girmeyen ancak normal olarak sınıflandıramadığımız yapılardır. Araştırmamızdaki sınıflandırma türleri ve veri tabanındaki açıklama kodları normal (sağlıklı), N, erken ventriküler kasılma, V, atriyal prematüre atım, A, ventriküler ve normal atım füzyonu, F, sağ dal bloğu atımı, R, dal bloğu atımı, B, supraventriküler prematür veya ektopik atım (atriyal veya nodal), S, nodal (birleşim) kaçış ritmi, j, sınıflandırılmaz vuruşlar, Q şeklindedir.



Şekil 1.13. 12 kanallı EKG'de DKR(URL-7, 2018).

1.4.Literatür Araştırması

Bu alanda yapılan çalışmalar Dalgacık dönüşümü (DD) kullanılarak yapılan çalışmalar, Hjorth Tanımlayıcıları kullanılarak yapılan çalışmalar, morfolojik öznitelikler kullanılarak yapılan çalışmalar, yapay zekâ tekniklerini kullanan çalışmalar, gerçek zamanlı aritmi tespiti alanında yapılan çalışmalar, derin öğrenme alanında yapılan çalışmalar şeklinde bölümlere ayrıldı.

1.4.1.Dalgacık Dönüşümü Kullanılarak Yapılan Çalışmalar

DD'nün, EKG sinyallerinde aritmi sınıflandırılmasında kullanıldığı bazı çalışmaları inceleyelim. Dokur ve diğerleri (1999), öznitelik çıkarma yöntemleri olarak dalgacık analizi ve Fourier analizini araştırmışlardır. On farklı EKG dalga formu, genetik algoritmalarla eğitilmiş bir sinir ağı kullanılarak sınıflandırıldı. Önerilen yöntemin performansı incelendiğinde, DD kullanarak %99.4 doğruluk ve ayrık Fourier dönüşümü kullanarak %92,2 doğruluk değerlerine ulaştı.

Prasad ve Sahambi (2003), dalgacıkları kullanarak EKG'deki aritmileri tespit edecek bir yöntem geliştirdiler. Ayrık dalgacık dönüşümünden (ADD) elde edilen tüm katsayılar öznitelikler olarak kullanılmıştır. 12 farklı aritminin sınıflandırılması için Yapay Sinir Ağlarını (YSA) tercih ettiler. %96.77'lik bir doğruluk oranı elde edildi. Bu yöntemin gürültüye karşı dayanıklı olduğu bulundu.

Shyu ve diğerleri (2004), ventriküler erken kasılmayı (VEK) sınıflandırmak için bir yöntem geliştirdi. QRS tespiti ve öznitelik çıkarımı DD kullanılarak yapıldı. Diğer yöntemlere daha az karmaşıklık ve daha az hesaplama bu tekniğin başlıca avantajlarıydı. Bulanık sinir ağları kullanılarak VEK sınıflandırmasındaki doğruluk oranı %99,79 olarak bulundu.

Zhao ve Zhang (2005), katsayıları çıkarmak için DD kullandı. Aynı zamanda, otoregresif modelleme uyguladılar. Böylece, EKG dalga formlarının geçici yapıları elde edildi. Ardından, altı kalp ritmi tipini sınıflandırma Gauss çekirdeği ile DVM ile desteklendi ve %99.68 genel doğruluk elde edildi.

Jiang ve diğerleri (2006) DD ve bağımsız bileşen analizi (BBA) kombinasyonundan öznitelik çıkarma yöntemi geliştirmişlerdir. DVM sınıflandırıcı, on dört farklı kalp atışı aritmisini tanımak için kullanıldı ve %98,65 genel doğruluk elde ettiler.

Yu ve Chen (2007), altı EKG atış tipini sınıflandırmak için bir sistem önermişlerdir. Bu sistem, farklı alt bantlardaki EKG sinyallerini ayırtmak için ADD'nü kullanmıştır. Sınıflandırma için olasılıksal sinir ağını kullandılar. 11 öznitelik ile %99,65'lik bir doğruluk oranı elde edildi. Bu öznitelik kümesi, diğer yöntemlerin öznitelik kümesinden önemli ölçüde daha küçüktü.

İşler ve Kuntalp (2007), kalp hızı değişkenliği (KHD) ve dalgacık entropi ölçümlerinden en iyi öznitelikleri seçmek için bir genetik algoritma kullanmışlardır. Bu analizleri yapmak için MIT/BIH veri tabanını kullanmayı tercih etmişlerdir. İki grubu yani Konjestif Kalp Yetmezliği (KKY) ve sağlıklı durumu sınıflandırmak için K-en yakın komşu (K-EYK) sınıflandırıcı kullanıldı. En iyi doğruluk %96.39 olarak bulundu.

Son derece hassas bir EKG aritmi tespit sistemi Zellmer ve diğerleri (2009) tarafından önerildi. Her vuruş için üç ayrı öznitelik vektörü oluşturuldu. Bu öznitelik vektörlerini oluşturmak için zaman bölgesi morfolojisi bilgisine ek olarak sürekli dalgacık dönüşümü (SDD) gereklidir. Altı farklı vuruş için bu öznitelik vektörleri tarafından üç farklı DVM sınıflandırıcısı eğitilmiştir. Üç bağımsız sınıflandırıcı arasında oylama yaparak çok-sınıflandırıcı tabanlı sınıflandırmayı kullanarak %99,72 doğruluk oranı elde ettiler.

Emanet (2009) ADD'nü kullanarak beş tip atımı sınıflandırmıştır. Sınıflandırma için rasgele orman algoritması kullanıldı. MIT-BIH aritmi veri tabanından yirmi üç kayıt rasgele seçildi. Ayrıca beş kalp atışı tipi %99.8 başarı oranı ile sınıflandırıldı.

Llamedo ve Martínez (2011), RR aralığındaki sinyallerden ve DD'lerinin farklı ölçeklerinden öznitelikler kullanmışlardır. En iyi model MIT-BIH Aritmi veri tabanının bir bölümünde eğitildi. Sınıflandırma bir lineer sınıflandırıcı tarafından yapıldı ve genel %93 doğruluk elde edildi.

Rai ve diğerleri (2012), Daubechies dalgacıkları ile çok katmanlı algılayıcı (ÇKA) ve radyal temel fonksiyon sinir ağı kullanarak EKG aritmi sınıflandırması üzerine bir çalışma yürütmüşlerdir. EKG atımları, beş tip atım için 21 öznitelik ile karakterize edildi. Simülasyon, %0,12'lik bir hata oranı ile %99.8'lik bir ortalama doğruluk oranı ile sonuçlandı.

Rai ve Trivedi (2012), EKG sinyallerini ADD temelli öznitelikleri ve morfolojik öznitelikleri kullanarak iki sınıfa ayırdı. Sınıflandırma için Geri Yayılım Sinir Ağı kullanmış ve %97.8 doğruluk elde edilmiştir.

Li ve diğerleri (2012), ventriküler fibrilasyonu saptamak için Kompleks Fizyolojik Sinyaller için Araştırma Kaynaklarından aldıkları EKG sinyallerini kullanmışlardır. Öznitelik çıkarımı için SDD kullanıldı. Bu yöntem, devam eden göğüs kompresyonunu

kesintiye uğratmadan ventriküler fibrilasyonu tespit edebilir. Sonuçta %93 doğruluk elde edilmiştir.

Ye ve diğerleri (2012), dinamik ve morfolojik özniteliklerin birleşimine dayanan bir sınıflandırma yaklaşımı önermişlerdir. MIT-BIH aritmi veri tabanı kullanıldı. Morfolojik öznitelikler elde etmek için sinyallere DD ve ayrıca BBA uygulandı. Dinamik özniteliklerin sağlanması için RR aralıklarının kesin yerleri hesaplandı. Bu öznitelikler birleştirildi ve DVM kullanılarak sınıflandırıldı. Toplam doğruluk %99,3 olarak bulundu.

Llamedo ve Martínez (2012), hastaya uyarlanabilir bir algoritma geliştirdiler. DD ve RR aralık özniteliklerinden hesaplanan morfoloji tanımlayıcıları kullanılmıştır. Amerikan kalp derneği veri tabanı ve Physionet üzerinde mevcut veritabanları normal, supraventriküler, ventriküler kalp atımlarını sınıflandırmak için kullanıldı. Otomatik sınıflandırıcı, küme ve sentroid tanımlama gerçekleştirdi. Son performans değerlendirmesinde MIT BIH-SUP ve MIT BIHAR alt kümesi kullanıldı ve %96 doğruluk elde edildi.

Faziludeen ve Sabiq (2013), üç vuruş tipi için otomatik bir sınıflandırma yöntemi uygulamıştır. Her vuruş için yirmi beş öznitelik dalgacık analizinden çıkarıldı. Sınıflandırma için üç DVM tasarlandı. Son gruplama maksimum oylama ile yapıldı. Prematüre ventriküler kasılma, normal ve sol dal bloğu atımları için sırasıyla %99.92, %98.47 ve %98.46 doğruluk elde edildi.

Chen ve diğerleri (2013), doğrusal diskriminant analizine dayanan EKG sinyallerinin sınıflandırılması için bir sistem geliştirdi. Doğrusal diskriminant analizi basitliğinden dolayı tercih edildi. EKG sinyallerinin spektral enerjisi, PQRST kompleksinin ADD elde edilerek öznitelik olarak kullanılmıştır. Haar dalgacığı temel fonksiyon olarak kullanıldı. PTB veri tabanı ve Southampton Genel Hastanesi Kardiyoloji Bölümü'nden örnekler sınıflandırma için kullanıldı ve %85,57 doğruluk elde edildi.

Dima ve diğerleri (2013), EKG ve vektörel kardiyogramdan miyokardiyal hastalığın varlığını saptamak için bir sistem geliştirdiler. Dört farklı yöntem uygulandı. Bunlardan biri dalgacık koherens analizi ile birlikte bir şablon EKG kalp atışı kullanımıydı. Sınıflandırma için DVM kullanmışlardır. Ayrıca ekstra öznitelikleri kaldırmak için öznitelik seçimi yaptılar. Southampton Kardiyoloji Bölümü üniversite Hastanesinden 3 farklı veri tabanından 260 kayıt kullanılmış ve %89.22 doğruluk elde edilmiştir.

Saminu ve diğerleri (2014), R-T aralığının ADD değerini hesaplamış ve istatistiksel parametreler zaman-frekans alanı öznitelikleri olarak kullanılmıştır. Üç tip EKG atımı, sinir

ağı geri yayılım algoritması kullanılarak sınıflandırıldı. %98.22 doğruluk oranı elde ettiler. Bu teknik, mobil cihazlar için uygun olan sağlam bir EKG özelliği çıkarma yöntemidir.

Banerjee ve Mitra (2014), EKG sinyallerinin sınıflandırılması için çapraz dalgacık dönüşümü (ÇDD) kullanmışlardır. ÇDD kullanarak EKG sinyallerini analiz ettiler ve sonuçta ortaya çıkan spektral farklılıkları keşfettiler. Ayrıca, ÇDD sinyallere uygulayarak dalgacık çapraz spektrumunu ve dalgacık tutarlılığını elde ettiler. EKG sinyallerinin dalgacık çapraz spektrumu ve dalgacık tutarlılığı QRS kompleksi ve T dalga parçası olmak üzere iki spesifik parçaya göre farklı öznitelikler gösterdi. Sınıflandırıcı eşik tabanlı olarak tercih edildi. Analizle sonucunda anormal ve normal kardiyak paternlerin sınıflandırılması için genel doğruluk, özgünlük ve hassaslık sırasıyla %97.6, %98.8 ve %97.3 olarak elde edildi.

Sahoo ve diğerleri (2015), EKG sinyallerinden DD kullanarak kardiyak aritmi saptamayı planlamışlardır. MIT-BIH aritmi veri tabanından ilk 23 dosya kullanıldı. Bu çalışmada analiz için beş anormal ve beş normal EKG sinyali seçilmiştir. Sınıflandırma için en küçük kareler DVM kullanıldı. %98.11 doğruluk elde ettiler.

Jacob ve Joseph (2015), iki sınıf için ÇDD ve DVM'leri kullanarak sınıflandırma yaptılar. Yapılan simülasyon, DVM için % 94.8 ve iki boyutlu DVM için % 96.2 doğruluk oranı ile sonuçlandı.

Saini ve diğerleri (2015), K-EYK sınıflandırıcısını kullanarak on kalp hastalığını sınıflandırmışlardır. Sınıflandırma, DD yapılmış EKG sinyalleri ve orijinal EKG sinyalleri kullanılarak yapıldı ve %87.5'lik bir doğruluk oranı elde edildi.

Sharma ve diğerleri (2015), çok ölçekli dalgacık enerjileri ve çok ölçekli kovaryans matrislerinin özdeğerleri öznitelik olarak kullanmışlardır. Sınıflandırıcılar olarak hem doğrusal hem de radyal temel fonksiyon çekirdeği ve K-EYK'su olan DVM'leri kullandılar. Sınıflandırma için PTB tanı EKG veri tabanı kullanıldı. Veri kümeleri çeşitli miyokard enfarktüslerini içeriyordu. Doğruluk, özgünlük ve hassaslık değerleri sırasıyla %96, %99 ve %93'dür.

Dewangan ve Shukla (2016), öznitelik çıkarma ve ön işleme için ADD kullanarak EKG sinyallerini analiz ettiler. YSA, beş tip aritminin sınıflandırılması için kullanılmıştır. Dalgacık katsayılarının ve morfolojik özniteliklerin sınıflandırma için birlikte kullanılmasının doğruluk oranını artırabileceğini belirlemişlerdir. Önerilen yöntem %87 doğrulukla geliştirilmiş bir performans sağlamıştır.

Sayilgan ve diğerleri (2017), yedi tip aritmi belirlemek için kümeleme algoritmalarını kullanmışlardır. MIT-BIH Aritmi Veri Tabanı'ndan aldıkları verileri incelediler.

Sınıflandırıcılar olarak K-Ortalama, Bulanık C-Ortalama, Aşırı Öğrenme Makinesi ve Naive Bayes kullanılmıştır. Naive Bayes %92 doğrulukla en başarılı sınıflandırıcı olarak tespit edildi.

Rad ve diğerleri (2017), ventriküler taşikardi, ventriküler fibrilasyon, nabızsız elektriksel aktivite, asistol ve nabız üreten ritimin otomatik sınıflandırılması için algoritmalar geliştirmişlerdir. 1631 tane 3 saniyelik EKG sinyallerini içeren bir veri tabanı kullandılar. Bu sinyaller 298 kardiyak arrest hastasından toplandı. 47 dalgacık ve zaman alanı tabanlı öznelikler hesaplamışlardır. 14 öznelik seçmek için bir sarıcı tabanlı öznelik seçim mimarisi kullanıldı. Bayesian regülasyon ile YSA sınıflandırıcısı kullanıldı. Toplam doğruluk %78.5 olarak bulundu.

1.4.2.Hjorth Tanımlayıcıları Kullanılarak Yapılan Çalışmalar

Hjorth tanımlayıcıların elektroensefalografi elektromiyogram, akciğer ses işleme ve benzeri biyolojik sinyal işleme alanında kullanımına rastlanılabilir. Hjorth tanımlayıcılar kullanılarak EKG sinyallerinde aritmi tespiti yapan çalışmalara bakalım. Blanco-Velasco ve diğerleri (2010) yaptığı çalışmada ani gelişen kardiyak ölümü için bir risk belirleyicisi olarak bilinen T-dalga alternansı araştırılmıştır. Bu çalışmada Ampirik Mod Ayırma yönteminden ve Hjorth tanımlayıcılardan yararlanmışlardır. Sonuç olarak, ST-T kompleksinin eğilimini çıkarmak için sağlam bir teknik elde edilmiştir. Yöntemin değerlendirilmesi, farklı frekanslarda örneklenen EKG'lere sahip çeşitli veri tabanları üzerinde spektral yöntem ile gerçekleştirilmiştir. Sonuçlar, önerilen teknikle spektral yöntemin geleneksel yöntemi 2 dB'den fazla aştığını göstermektedir. Ayrıca, bu tekniğin sağlamlığı, gürültüsüz koşullarda dedektöre herhangi bir ek bozulma getirmediği için bilinmektedir.

Valderrama ve diğerleri (2012), tarafından EEG-EKG kayıtlarından türetilen içinde Hjorth Hareketlilik ve Karmaşıklık özellikleri bulunan 34 algoritmik öznelikler ile sınıflandırma yapılmıştır. Bu algoritma 12 hastanın (108 nöbet ve 3178-saat) sürekli kayıtları üzerinde değerlendirildi. En ayırt edici EEG-ECG özneliklerinin incelenmesi, iyi sınıflandırma oranlarına bakarak, özellikle belirli uyku evrelerine bağlı olarak, spesifik fizyolojik öncülleri gösterdiği ortaya çıkarmıştır. Bu gözlemlerden yola çıkarak, algoritmanın, yüksek nöbet üretimi riski taşıyan durumları tanımlamak için nicel bir yol sağladığı söylenebilir.

De Cooman ve diğerleri (2014) tarafından yapılmış çalışmada gürültülü EKG sinyallerinde R noktasını bulmada Hjorth tanımlayıcılardan biri olan hareketlilik öznelik olarak kullanmıştır. Algılanan sinyallerin kalp atışı etiketleri, çoğunluk oyu, kalp atışı konumu tahmini ve Hjorth'ın hareketlilik parametresi kullanılarak birleştirilir. Ortalama performans, eğitim seti için %99.95 ve 2014 Kardiyolojide Bilgisayar Kullanımı yarışmasının son aşaması için %85.62 idi. Sinyallerin mevcut etiketleri kullanılıyorsa, gizli test setindeki performans %86.61'dir.

Rizal ve Hadiyoso (2015) tarafından Hjorth Tanımlayıcı öznelik çıkarmak için bir yöntem olarak kullanılmıştır. Sınıflandırma aşamasında K-EYK ve ÇKA kullanılmıştır. Deneme sonucu, K-EYK ve ÇKA'nın, test verilerinin %50'si için %100'e kadar doğruluk sağladığını gösterdi. 10 kat çapraz doğrulama için %99.33 doğruluk elde edildi. Rizal ve diğerleri (2015) tarafından yapılmış olan başka bir çalışmada yine Hjorth tanımlayıcılar kullanılmıştır. Hjorth tanımlayıcısı biyolojik sinyalin karmaşıklığını ortaya çıkarmak için ölçülmüştür. EKG sinyalinin özneliğini çıkarmak için Hjorth Tanımlayıcısının Yüksek Mertebeden Kompleksliği kullanıldı. Test verileri, Normal Sinüs Ritmi, AF ve KKY olmak üzere üç tip EKG sinyalinden oluşur. K-EYK ve ÇKA kullanarak %94 doğruluk üretildi. Deneysel sonuçlar, zaman alanındaki Hjorth tanımlayıcısının, bir öznelik olarak kullanılmak üzere umut verici olduğunu göstermektedir.

Fujita ve diğerleri (2016), Ani kardiyak ölüm (AKÖ) riskli bireylerin KHD sinyallerini doğrusal olmayan teknikleri kullanarak otomatik olarak sınıflandıran yeni bir metodoloji sunmuştur. Bu çalışmada, AKÖ oluşumundan önce dört saatlik KHD sinyallerinin (her bir birer dakikalık aralıklarla), Renyi entropisi, bulanık entropi, Hjorth parametreleri (etkinlik, hareketlilik ve karmaşıklık), Tsallis entropisi ve ADD katsayıları gibi doğrusal olmayan öznelikleri kullanılarak analiz edilmesiyle AKÖ'nü tahmin edilmiştir.. Elde edilen klinik açıdan önemli tüm öznelikler sıralanır ve K-EYK, karar ağacı ve DVM gibi sınıflandırıcılara verilir. Bu çalışmada, AKÖ'nün başlangıcından önce DVM sınıflandırıcı kullanılarak, iki, üç ve dört dakika önce %97.3, %89.4, %89.4 ve %94.7'lik bir doğruluk elde edildi. Ayrıca, normal ve AKÖ eğilimli KHD sinyallerini sınıflandırmak için lineer olmayan KHD sinyal özelliklerini kullanarak yeni bir AKÖ İndeksi geliştirildi. Önerilen teknik, AKÖ geliştirilme riskini taşıyan kişiyi dört dakika önce belirleyebildi ve böylece Klinisyenlerin yoğun bakım ünitelerinde tedaviye yanıt vermeleri için yeterli zaman sağlandı. Bu nedenle, bu önerilen teknik, birçok kalp hastalarının hayatta kalma oranını arttırmak için değerli bir araç olarak hizmet edebilir.

Leite ve Moreno (2017), RR aralığı, genlik ve Hjorth parametrelerinin değerlerini kullanılarak kalp atımlarının otomatik olarak sınıflandırılması için bir yöntem sunmuşlardır. Bu makale aynı zamanda kalp atışı bölümlenmesine yeni bir yaklaşım getirmekte, bu da bitişik vuruşlardan gelen bilgileri karıştırmamakta ve sınıflandırma performansını iyileştirmektedir. Önerilen model Massachusetts Teknoloji Enstitüsü - Beth Israel Hastanesi (MIT-BIH) Aritmi veri tabanında doğrulanmıştır ve %90.4'lük genel bir doğruluk sunmaktadır. Elde edilen sonuçlar, bu çalışmada kullanılan tekniklerin otomatik kalp atışı sınıflandırması problemine başarıyla uygulanabileceğini göstermektedir. Buna ek olarak, bu yeni yaklaşım, sınırlı kaynaklara sahip donanım cihazlarında uygulanmasına olanak veren düşük hesaplama maliyetine sahiptir.

Hadiyoso ve Rizal (2017) yaptıkları çalışmadaki amaç en basit algoritmayı bulmak, daha az hesaplama ile ama yine de iyi bir performansa sahip olmaktır. Bu çalışmada, EKG sinyalinin özelliğini çıkarmak için Hjorth Tanımlayıcı Yüksek Düzeyi Kompleksliği kullanılmıştır. Test verileri, Normal Sinüs Ritmi, AF ve KKY olmak üzere üç tip EKG sinyalinden oluşur. K-EYK ve ÇKA, sinyalin özelliğini sınıflandırmak için kullanılır. Bu yöntem kullanılarak hem ÇKA hemde K-EYK için %94 doğruluk elde edildi.

1.4.3. Morfolojik Öznitelikler Kullanılarak Yapılan Çalışmalar

EKG sinyallerinde morfolojik özniteliklerin incelenmesi kullanılan başka bir özel özniteliktir. Literatürde bu alanda yapılan çalışmaları incelersek Horowitz (1975) kısmen doğrusal yaklaşım ve tablo ayrıştırma tekniklerini birleştiren bir algoritma ile sayısallaştırılmış dalga formunda tepe noktalarını tespit etmiştir. Pek çok parametre, R tepe noktasının genliğinin, süresinin ve şeklinin doğru bir şekilde ölçülmesini sağlayan dalga şekli yapısını tanımlamaya hizmet eder. Algoritma gerçek zamanlı işleme izin vermek için yeterli hızlıdır.

Aritmileri tespit etme alanında Udupa ve Murphy (1980) tarafından EKG sinyallerinin ritim analizinde sözdizimsel (sentaktik) bir yaklaşım uygulanmıştır. Önerdikleri yöntem, seçilen kümeler açısından belirgin bir şekilde farklı öznitelikler oluşturmak için aritmik ve normal EKG modelleri arasındaki şekil ve yapıdaki farklılığı kullanır. Belirli bir sinyal çerçevesi ilk olarak uzunlukları ve eğim değerleri açısından tamamen belirlenmiş bir dizi bölüme doğrusal olarak parçalanır. Eğim değerleri yedi ayrı seviyeye ayrılır ve bu seviyelerin her birinde bir eğim değerine sahip birim uzunluklu bir parça bir eğim sembolü

olarak belirlenir. Verilen sinyal, sinyale benzeyen parçalarının uzunluğuna ve açısına bağlı olarak bu sembollerin bir dizisi olarak temsil edilir. Gerçek EKG verilerinin analiziyle, varolan yöntemlerinkiyle karşılaştırılabilir olduğu ve verimliliğiyle işlem süresinde tasarruf sağladığı tespit edildi.

Papakonstantinou ve Gritazali (1981) EKG sinyal filtreleme konusuna odaklanarak çalışmalar yapmışlardır. Algoritma EKG dalga şeklini temsil eden noktaların sayısını azaltmak için de kullanılabilir. Gürültü olarak değerlendirilecek darbelerin boyutunu tanımlamak için iki parametre kullanıldı ve bu da algoritmanın esnekliğini arttırdı.

Otomatik EKG işlemede, QRS komplekslerinin saptanması temel öneme sahiptir. Bu amaçla birçok algoritma geliştirilmiştir. Bu algoritmalar üç kategoriye ayrılabiliriz. Bunlar sözdizimsel olmayan, sözdizimsel ve melezdir. Papakonstantinou ve diğerleri (1986) tarafından yapılan araştırmada özellik temel prensipleri tarafından tanımlanan sözdizimsel bir algoritma sunulmuştur.

Trahanias ve Skordolakis (1990) EKG'nin sözdizimsel (sentaktik) örüntü tanınması konusunda çalışmalar yapmışlardır. Temel model seçimi, temel model çıkarımı, dilbilimsel gösterim ve model temel prensiplerine ait formülasyonu ile ilgili problemlere çözüm yolları oluşturuldu. Özellikle ilgili temel prensipler, tanımsal gücü nedeniyle, sözdizimsel ve semantik bilgileri ele alma becerilerine dayanarak model için kullanılır. Bu yaklaşım uygulanmış ve ortaya çıkan sistemin performansı açıklamalı standart bir EKG Kütüphanesi kullanılarak değerlendirilmiştir.

EKG sinyalinin zamana bağlı incelemesini yapan çalışmalardan birisi Ruha ve diğerleri (1997) tarafından yapılmış seyyar QRS algılayıcı dizayn, test metotlarını içeren çalışmadır. Yöntemde hızlı Fourier Dönüşümü kullanılmıştır. Bu sayede frekans uzayında sistemin özelliklerini incelemeyi hedeflemişlerdir. Bu çalışmada oluşturulan yapıyla, hem ambulatuvar hem de klinik kullanımda KHD'nin doğru şekilde ölçülmesi ve güvenilir QRS tespitinin yapılması mümkün olmaktadır. Dedektör sisteminin QRS algılama zamanlaması doğruluğu ve algılama güvenilirliği, çeşitli gürültü tipleri ile bozulan yapay olarak üretilmiş bir EKG sinyali ile test edildi ve çoğu gürültü tipi ve karşılaşılanlara benzer seviyelerde 1 ms'den daha az bir zamanlama standart sapması elde edildi. Sırasıyla MIT-BIH Aritmi veri tabanından 103 ve 105 kayıtları ile %0.1 ve %2.2'lik bir QRS saptama hata oranı gözlemlendi.

1.4.4.Yapay Zekâ Tekniklerini Kullanan Çalışmalar

Yapay zekâ tekniklerini kullanan çalışmalardan biri EKG sinyallerinin analizine uygulanan anlamsal ağlar şeklindedir. Stockman ve Kanal (1983) çalışmasında sinyal VE/VEYA grafiği formunda gösterilmiş ve sınıflandırma süreci grafik araştırma şeklinde yapılmıştır. Bu yapısal analiz paradigmasını uygulayan WAPSYS (dalga biçimi ayrıştırma sistemi) adı verilen bir yazılım sistemi tanımlanmıştır.

Başka bir kural temelli sistemde EKG sinyali if-then kuralları şeklinde tanımlanmıştır. Kundu ve diğerleri (1993) tarafından yapılan bu çalışmada sistemin karar verme mekanizması doğrulama metoduna (modus ponens) dayanmaktadır. Kontrol modülü, her eşleştirme-çözme-işlem döngüsünde üretim seviyesi paralelliği ve durum seviyesi paralelliğini dikkate alan ve iki etken arasında dağıtılmak üzere tasarlanmıştır. Sinyalin çevrim içi yorumu için çıkarım prosedürünü hızlandırmak için özel alan bağımlı bir algoritma ile çalışır.

Sinirsel ağlar (neural networks) tabanlı sınıflandırma çalışmalarından biri Iwata ve diğerleri (1990) tarafından yapılan Holter EKG sistemlerinde toplanan sinyallere uygulanan sinyal sıkıştırma. Gizli katman birimlerinin aktivasyon seviyelerinin bir fonksiyonu olarak EKG dalga formunun özniteliklerini çıkarmak için birkaç üniteye sahip gizli bir katmanı olan üç katmanlı bir YSA kullanıldı. Çıkış ve giriş ünitelerinin sayısı aynıydı. Geri yayılma algoritması, öğrenme için kullanıldı. Ağ, giriş sinyalleri ile aynı olan denetimli sinyallerle ayarlandı. Veri sıkıştırma için bir ağ kullanıldı ve diğer ağ ise mevcut sinyallerle öğrenmede kullanıldı.

Bu alandaki bir diğer çalışma Xue ve diğerleri (1992) tarafından QRS algılama alanında yapılmıştır. Doğrusal olmayan ve durağan olmayan EKG düşük frekanslarını modellemek için bir ANN uyarlamalı beyazlatıcı filtre kullanıldı. QRS algılama için çoğunlukla daha yüksek frekanslı QRS kompleks enerjisi içeren sinyal daha sonra doğrusal eşleşmiş bir filtreden geçirildi. EKG sinyalindeki tespit edilen QRS kompleksinden eşleşen filtre şablonunu uyarlamak için bir algoritma geliştirildi, böylece şablon kişiye göre özelleştirilebilirdi.

Sinirsel ağların ventriküler geç potansiyelleri tespitinde kullanımı Xue ve Reddy (1997) tarafından incelendi. Ventriküler geç potansiyeller, sinyal ortalamalı EKG'lerden elde edilen yüksek frekanslı düşük genlikli sinyallerdir. Elektrofizyoloji testi sırasında spontan veya indüklenebilir ventriküler taşikardiye eğilimli hastaların belirlenmesinde yararlıdır.

Geç potansiyelleri kullanarak negatif elektrofizyoloji testi olan hastalarda indüklenabilir ventriküler taşikardi için pozitif elektrofizyoloji testi olan hastaları tanımlamak için kendi kendini organize eden ve denetlenen YSA modelleri geliştirildi. Vektör büyüklük dalga formunun morfoloji bilgisini, toplam QRS süresi, yüksek frekans düşük genlikli sinyal süresi ve kök-ortalama-kare voltajı olan, geç potansiyellerin üç zaman alanlı bir orijinal setine eklendi.

1.4.5.Gerçek Zamanlı Aritmi Tespiti Alanında Yapılan Çalışmalar

Gerçek zamanlı aritmi tespitinde pek çok çalışma yapılmıştır. Bunlardan bazıları aşağıda verilmiştir. Jekova ve Krasteva (2004) ventriküler fibrilasyon ve taşikardi tespiti için, gerçek zamanlı çalışmada uygulanması çok basit olan, tamsayı katsayılarına sahip bir bant geçişli dijital filtre kullanılan bir algoritma önermiştir. Kalp hızı ölçümü ve yardımcı parametre hesaplaması için dalga tespit sınıfı etkinleştirildi. Yöntem, Amerikan Kalp Derneği ve Massachusetts Teknoloji Enstitüsü'nün tanınan veritabanlarından alınan EKG kayıtları ile test edilmiştir ve %95.93'lük bir duyarlılık ve %94.38'lik bir özgünlük elde edildi.

Chiu ve diğerleri (2005) EKG sinyalinde korelasyon katsayısı kullanılarak aritmilerin morfoloji özneliklerine dayanan etkin bir aritmi tespit algoritması geliştirmektedir. Normal denekler, atriyal erken kasılma (AEK) olan hastalar ve VEK olan hastalardan oluşan bir veri tabanında çalışıldı. QRS komplekslerinin yerlerini bulmak için Chan'ın algoritması kullanıldı. QRS kompleksleri tespit edildiğinde, aritmilerin benzerliğini hesaplamak için korelasyon katsayısı ve RR intervali kullanıldı. Farklı aritmik atım kategorilerinin sınıflandırılması için yüksek genel performans (%99.3) sağlandı. Sistemin pozitif tahmin sonuçları, normal vuruşlar, AEK'ler ve VEK'ler için sırasıyla %99,44, %100 ve %95,35'lere ulaşmaktadır. Sistemin duyarlılık sonuçları, normal atım, AEK ve VEK'ler için sırasıyla %99.81, %81.82 ve %95.83'tür.

Rodriguez ve diğerleri (2005) tarafından P, QRS ve T dalgalarının tepe noktaları ve limitleri, PR ve QT aralıkları, P, QRS kompleksinin büyüklüğü ve T dalgaları, frekansları ve ayrıca ST ve PQ segmentlerinden oluşan öznelikler karar ağaçları ile sınıflandırılmıştır. Bir saatten kısa bir sürede tıbbi yardım gerektiren aritmiler için %97.95 ve genellikle kötü aritmiler için %95 doğruluk elde edilmiştir.

Wen ve diğerleri (2008) sınıflandırma için EKG sinyalinin QRS bölümünü kullanmıştır. R dalgasını tespit edildikten sonra, R dalgası üzerinde merkezlenmiş 73 örnek (yaklaşık 200 ms) penceresi kullanarak atımdan çıkarıp ve bunu sınıflandırmada kullanılabilir. Giriş EKG'lerini birkaç vuruş türüne sınıflandırmak için bir yazılım programı kullanır. Deney sonuçları, önerilen sistemin, %98.98'lik bir genel sınıflandırma doğruluğuyla gerçek zamanlı olarak EKG sınıflandırmasına ulaşabileceğini göstermiştir.

Lim (2009), ağırlıklı bulanık üyelik fonksiyonları ile sinir ağlarını kullanarak prematür ventriküler kasılmaları (VEK) tespit etmek için bir yaklaşım oluşturdu. Bu sistem, MIT-BIH VEK veri tabanından dalgacık dönüştürülmüş katsayıları kullanarak, bulanık üyelik fonksiyonları tarafından normal ve VEK vuruşlarını sınıflandırır. Zaman sinyaline lokal olarak bağlı olan sekiz genelleştirilmiş katsayı, toparlanma alanı dağılımı ölçüm yöntemiyle çıkarılmaktadır. Sekiz genelleştirilmiş katsayı, sırasıyla %99,80, %99,21 ve %98,78 doğruluk oranlarına sahip üç VEK veri setinde kullanıldı.

Dash ve diğerleri (2009) kalp atım aralığı (RR) zaman serilerinin rasgelelik, değişkenlik ve karmaşıklığına dayanarak AF'un otomatik olarak saptanması için bir algoritma tanımlamıştır. Aritmiyi karakterize etmek için Dönüm Noktaları Oranı, Kök Ortalama Ardışık RR Farkı ve Shannon Entropi kullanılmıştır. Algılama algoritması iki veri tabanında, yani MIT-BIH AF Veri Tabanı ve MIT-BIH Aritmi Veri Tabanı üzerinde test edilmiştir. ROC eğrileri ile belirlenen eşik ve veri segment uzunlukları kullanılarak MIT-BIH için %94.4 ve AF Veri Tabanı %95.1 doğruluk elde edildi.

Oresko ve diğerleri (2010) Holter cihazlarının taşınabilirliğini ve gerçek zamanlı işleme yeteneğini birleştirmeyi amaçladı. öznitelik çıkarma ve sınıflandırma, akıllı telefonda ana HeartToGo uygulamasından ayrı bir dinamik bağlantılı kitaplık (dll) olarak uygulanır ve kendi iş parçacığı üzerinde çalışır. Makine öğrenme platformu, MIT-BIH aritmi veri tabanından normal ritimleri ve dört aritmi durumunu kapsayan 5421 QRS karmaşık şablonunu kullandı. Sınıflandırma doğruluğunu tahmin etmek için, sonlu boyutlu veri örneklerinin rastgele örneklemeinden kaynaklanan varyasyonları en aza indirecek şekilde tasarlanmış üç yönlü çapraz doğrulama yöntemi benimsendi. Ventriküllerin bölümlerine bağlı olarak değişen füzyon komplekslerinin değişen morfolojilerine atfedilebilecek, hızlı ve normal atımın füzyonu için %81 tahmin doğruluğu hariç, %90'dan daha büyük bir tahmin doğruluğu elde edildi.

Ye ve diğerleri (2010) morfolojik ve dinamik özniteliklerin bir kombinasyonuna dayalı aritmi sınıflandırması için yeni bir yaklaşım önerir. DD ve BBA, her bir kalp atımına

ayrı olarak, morfolojik öznitelikler olarak kategorize edilen ilgili katsayıları çıkarmak için uygulanır. Buna ek olarak, dinamik öznitelikler sağlayan karşılık gelen kalp atışı etrafında ritmi karakterize eden RR aralığı bilgisi de elde edilir. Bu iki farklı öznitelik daha sonra birleştirilir ve kalp atışı sınıflarının 15 sınıfa ayrılması için DVM kullanılır. Prosedür iki EKG yolundan bağımsız olarak verilen verilere uygulanır ve iki sonuç nihai karar için kaynaştırılır. Önerilen yöntem MIT-BIH Aritmi Veri Tabanı üzerinde test edilmiştir %99.66 genel doğruluk sağlamaktadır,

Gradl ve diğerleri (2012) EKG parametrelerini analiz ederek gerçek zamanlı EKG izleme ve otomatik aritmi tespitine izin veren Android tabanlı mobil cihazlar için bir uygulama geliştirdi. Uygulama QRS tespiti için Pan-Tompkins algoritmasına dayanır ve anormal kalp atımlarını tespit etmek için başka algoritma blokları içerir. Seçilen öznitelikler mutlak alandaki fark, maksimal çapraz korelasyon katsayısı, QRS genişliği ve RR aralığı şeklindedir. Algoritma MIT-BIH Aritmi ve MIT-BIH Supraventriküler Aritmi veri tabanları kullanılarak analiz edildi. Tüm QRS komplekslerinin %99'undan fazlası algoritma tarafından doğru bir şekilde tespit edildi. Anormal atım tespiti için genel duyarlılık %80.6 özgüllük ile %89.5 idi.

Patel ve diğerleri (2012) tarafından yapılan çalışma, EKG sinyalinin kullanıldığı etkin bir aritmi tespit algoritmasının geliştirilmesi ile ilgilidir. İlk aşamada aritmi tespitinin, tüm sistemi mobil hale getiren herhangi bir yerde kolayca bulunabilen bir akıllı telefon kullanılarak yapılması mümkündür. Algoritma MIT-BIH aritmi veri tabanı kullanılarak test edildi. Analizler normal durum, Bradikardi, Taşikardi, AEK, VEK ve Uyku Apnesi olan hastaları içermektedir. Pan-Tompkins algoritması, QRS kompleksleri ve R Peaks konumlarını bulmak için kullanıldı. Farklı aritmi tespit etmek için algoritma, P dalgası, QRS kompleksi, R Tepe ve T dalgasının pozisyonu ve bu dalgaların aralığına dayanmaktadır. Sonuçlar, aritmileri sınıflandırmak için sistemin doğru ve verimli olduğunu ortaya koydu ve performans %97.3 olarak bulundu.

Cheng ve Dong (2017) tarafından QRS komplekslerinde farklı kişiler arasındaki ince farkları hesaba katmak için, hastaya özgü bir normal QRS-kompleks şablonu ile gerçek zamanlı EKG verileri arasındaki korelasyon katsayısına dayanarak yeni kişiselleştirilmiş öznitelikler önerilmiştir. EKG dalga biçimlerini karakterize eden genel öznitelikler, ventriküler aritmi saptaması için ayıklanır. En etkili özniteliklerin küçük setleri, verimli performans ve gerçek zamanlı çalışma için yeni çıkarılan 11 ve daha önceden mevcut 15

öznitelikten DVM ile seçilir. En iyi iki öznitelik ile %94.66±1.97, En iyi üç öznitelik ile %95.46±1.36 doğruluğa ulaşıldı.

1.4.6. Derin Öğrenme Alanında Yapılan Çalışmalar

Son zamanlarda artan veri miktarı, gelişen donanım ve algoritmalarla birlikte kullanılmaya başlayan derin öğrenmenin biyomedikal sinyallerin analizinde de faydalı olduğu görülmektedir. Henüz bu konuda çok fazla çalışma yoktur. Ancak bu konuda insanların dikkatini çekmeye başlamıştır. Biyomedikal sinyal işleme, araştırmacıların biyoinformatikteki problemleri çözmek için insan vücudundan kaydedilen elektriksel aktiviteyi kullandıkları bir alandır. Bu alanda EEG, EKG, elektromiyografi (EMG) ve elektrookofiyografi (EOG) gibi çeşitli veriler kullanılmıştır. Bu çalışmalar en çok EEG üzerinde yoğunlaşmıştır. Kaydedilen sinyaller genellikle gürültülü olduğu ve birçok yapaylığı içerdiği için, ham sinyaller genellikle derin öğrenme algoritmalarında girdi olarak kullanılmadan önce dalgacık veya frekans bileşenlerine ayrıştırılır. Ayrıca, sonuçları iyileştirmek için bazı çalışmalarda normalleştirilmiş bozulma ve tepe noktası varyasyon gibi insan tarafından tasarlanan öznitelikler kullanılmıştır.

Biyomedikal sinyaller genellikle gürültü ve yapaylıklar içerdiğinden, ayrılmış öznitelikler ham sinyallerden daha sık kullanılır. Beyin kod çözmede, An ve diğerleri (2014) sol ve sağ motor görüntü becerilerini sınıflandırmak için Derin İnanç Ağlarını (DİA) EEG sinyallerinin frekans bileşenlerine uyguladılar. Ayrıca, Jia ve diğerleri (2014) duygu sınıflandırması için sırasıyla DİA ve YOK kullanmışlardır. Turner ve diğerleri (2014) yüksek çözünürlüklü, çok kanallı EEG verilerinde nöbet tespiti amacıyla uygulanan çeşitli işaretler ve makine öğrenimi algoritmalarının kullanımını araştırdı. Az sayıda çalışma, ham EEG sinyallerini kullanmıştır. Wulsin ve diğerleri (2011) hem ham EEG sinyalleri hem de girdi olarak özütlenmiş öznitelikler ile DİA kullanarak, DİA kullanarak bireysel ikinci-uzun dalga formu anormalliklerini analiz ederken, Zhao ve diğerleri (2014), Alzheimer hastalığını teşhis etmek için DİA için sadece ham EEG sinyallerini kullandı. Ham EEG sinyalleri beyin kodlamasında ve konvolüsyonel sinir ağı (KSA) aracılığıyla anomali sınıflaması (Mirowski ve Madhavan, 2009) analiz edilerek tek boyutlu konvolüsyonlar ile gerçekleştirilmiştir. Örneğin, Stober ve diğerleri (2014) katılımcıların dinlediği ritim türünü ve türünü sınıflandırdı ve Cecotti ve Graser (2011) katılımcıların görüntülediği karakterleri sınıflandırdı. Biyomedikal sinyal işlemeye KSA'lari uygulamak için başka bir yaklaşım

Mirowski ve diğerkleri (2009) faz-kitleme senkronizasyonu ve dalgacık uyumu gibi öznitelikleri ayıklayıp iki boyutlu desenleri formüle etmek için bunları piksel renkleri olarak kodladılar. Daha sonra, biyomedikal görüntüleme de kullanılanlar gibi sıradan iki boyutlu KSA'lar, nöbetleri öngörmek için kullanıldı.

Anomali sınıflandırmasında Huanhuan ve Yue (2014), EKG sinyallerine DİA uygulayan az sayıdaki çalışmadan birini yayınladı ve her bir atımı normal veya anormal bir atım olarak sınıflandırdı. DİA ve zamanlama aralığı özelliği ile elde edilen özniteliklerde dâhil olmak üzere tüm öznitelikler orijinal EKG sinyalinden çıkardılar. EKG atımını sınıflandırmak için birkaç sınıflandırıcı seçildikten sonra ve Gauss çekirdeği ile doğrusal olmayan DVM en iyi sınıflandırma doğruluğunu elde ettiler ve %98.49'a ulaştılar.

Kutlu ve diğerkleri (2016) DİA kullanarak ham EKG'de çok aşamalı bir sınıflandırma sistemi oluşturmuşlardır. Çok aşamalı DİA modeli, MIT-BIH Aritmi Veri Tabanı kalp atımlarını ANSI / AAMI standartları ile tanımlanan 5 ana gruba ayırmıştır. Tüm EKG'ler, medyan filtreleri ile filtrelenerek, 501 veri noktası uzunluğunda bir pencere kullanılarak parçalara ayrılmıştır. Önerilen DİA tabanlı çok aşamalı aritmi sınıflandırması, %95.05'lik yüksek doğruluk oranına sahip beş tip kalp atımını ayırt etmiştir.

Al Rahhal ve diğerkleri (2016) EKG sinyallerinin aktif sınıflandırması için derin öğrenmeye dayalı yeni bir yaklaşım önerdiler. Ham EKG verisinden, kısıtlama ile istiflenmiş yoğunlaştırıcı oto kodlayıcıları (YOK) kullanarak denetimsiz bir şekilde uygun bir öznitelik temsilini incelediler. Derin sinir ağını (DSA) oluşturan gizli tabakaların üstünde bir softmax regresyon tabakası eklediler. İyi bilinen MIT-BIH aritmi veri tabanı ve INCART ve SVDB adı verilen diğerk iki veri tabanında da yöntem kullanılmıştır ve genel olarak %90'ın üzerinde %99'a ulaşan başarı elde etmiştir

Wu ve diğerkleri (2016) EKG aritmileri öğrenme öznitelikleri için DİA, YOK'a dayalı yeni bir yaklaşım önermiştir. EKG verilerinin özniteliklerinin çıkarılması için, Gaussian-Bernoulli kısıtlı boltzmann makinesi ve Bernoulli-Bernoulli kısıtlı boltzmann makinesi dâhil olmak üzere iki tip kısıtlı boltzmann makinesi kullanılmıştır. Ağ performansını arttırmak için, denetimli sınıflandırma yapmak üzere ortaya çıkan gizli temsil katmanının üstüne bir softmax regresyon tabakası ekleyerek geri yayılımı kullanan bir ince ayar işlemi gerçekleştirilmiştir. Deney sonuçları, EKG aritmelerinin sınıflandırılmasında geleneksel el yapımı yöntemlerden daha az öznitelikli öğrenme süresiyle ve %99.5 doğruluk ile başarılı bir performans gösterdiğini göstermektedir.

Altan ve diğeri (2016) otomatik aritmi sınıflandırması için çok aşamalı bir derin öğrenme sınıflandırma modeli oluşturdu. Önerilen model, bir DİA sınıflandırıcı kullanarak EKG dalga şekilleri ve İkinci Sıra Farkı Çizelgesi özneliklerini kullanan çok aşamalı bir sınıflandırma sistemini içermektedir. Önerilen DİA tabanlı çok aşamalı aritmi sınıflandırma modeli, yüksek doğruluk oranı %96,10 ile beş tip kalp atımını ayırt etmiştir.

Taji ve diğeri (2017) EKG sinyallerinde gürültülü ve temiz sinyal ölçümleri arasında ayırım yapabilen DİA dayanan bir algoritma önerdi. Algoritma, ilk iki Kısıtlı Boltzmann Makinesi (Restricted Boltzmann Machine, RBM)'nin öznelikleri ayıklamak ve verileri sınıflandırmak için üçüncü RBM katmanına uygulamak için eğitildiği üç katmanlı RBM temel alınarak tasarlanmıştır. MIT-BIH Arrhythmia veri tabanını kullanarak elde edilen sonuçlar, algoritmanın temiz bir sinyalden gürültülü bir EKG sinyalini başarılı bir şekilde tanıdığını, kirlilik düzeyine bağlı olarak %75 ile %99.5 arasında bir sınıflandırma doğruluğu olduğunu kanıtlamıştır.

Jiang ve diğeri (2017) modifiye edilmiş yığınlanmış yoğunlaştırıcı otokoderler ve nöral ağlara dayalı tam bir kalp atışı sınıflandırma sistemi oluşturmuşlardır. Ön işleme bölümünde, orijinal EKG sinyali filtrelenir ve her kalp atışı olarak bölümlere ayrılır. Öznelikler, modifiye edilmiş yığınlanmış yoğunlaştırıcı otomatik kodlayıcılar kullanılarak orijinal kalp atışı sinyalinden çıkarılır ve %97.99'lük bir başarı elde edilir.

Assodiky ve diğeri (2017) aritmi verilerini sınıflandırmak için Derin Öğrenme'yi kullanmıştır ve öznelik seçim yöntemi olarak Parçacık Sürü Optimizasyonu (Particle Swarm Optimization, PSO) algoritmasını kullanarak %76.51'lik bir başarıya ulaşmıştır. Öznelik seçimi yöntemi olarak Genetik Algoritma (Genetics Algorithm, GA) algoritması kullanılarak %74,44'lük başarıya ulaşılmıştır.

Li ve Li (2018) EKG'nin verileri yüksek boyutlu bir manifold üzerinde gösterdiği için, bu tür veri manifoldlarının detaylarında detayı yakalamak amacıyla yerel derin alan olarak adlandırılan yeni bir yöntem önermektedir. Bu yöntem, yerel manifold çizelgeleri içinde farklı derin modelleri öğrenir. Yerel bölgeselleştirme, modellerin yerel varyasyonların özelliğine odaklanmasına yardımcı olabilirken, derin mimari, gizli sınıf bilgilerini yerel dağıtımlarda çözebilir. Önerilen yöntemi, MIT-BIH Aritmi veri tabanı kullanılarak incelenmiştir ve %98 seviyelerinde başarıya ulaşmıştır.

Liu ve diğeri (2018) çocuklarda VEK'leri otomatik olarak tespit edebilen modeller geliştirmek için derin öğrenme uyguladılar. Google tarafından geliştirilen ayarlı Inception

V3 modeli ve 1D KSA modeli ile çocukların VEK tespitinde %88'e ulaşan ümit verici bir performans sağladılar.

Xia ve diğerleri (2018) YOK otomatik giyilebilir bir EKG sınıflandırma ve izleme sistemi geliştirdi. EKG öznitelik gösterimi, YOK tarafından sınırlı bir kısıtlama ile öğrenilir. Daha sonra, softmax regresyonu EKG atımlarını sınıflandırmak için kullanılır. İnce ayar aşamasında, performansı artırmak için aktif bir öğrenme eklenir. Aktif öğrenme aşamasında, en bilgilendirici örnekleri seçmek için güven ölçümlerini ilişkilendirmek için DSA'larına sonradan gelen olasılıklara dayanan yöntemi kullanırız. İyi bilinen MIT-BIH aritmi veri tabanı üzerinde önerilen yöntem doğrulanmıştır ve %99 seviyesinde başarılar elde edilmiştir. Biyomedikal sinyaller doğal olarak sıralı verileri temsil ettiğinden, tekrarlayan sinir ağları (TSA) verileri analiz etmek için uygun bir derin öğrenme mimarisidir ve umut verici sonuçlar üretmesi beklenir. Beyin şifre çözme ve anomali sınıflandırmasında çalışmaların bir kısmını sunmak için Petrosian ve diğerleri (2000) nöbetler için ham EEG sinyallerine ve karşılık gelen dalgacık ayrışmış özniteliklerine perceptron TSA'leri uyguladı. Ek olarak, Davidson ve diğerleri (2007), sapmaları tespit etmek için EEG log-power spektrumları üzerinde UKSBB TSA'leri kullanmışlardır. konvolüsyonlu oto-kodlayıcılar (KOK), birkaç beyin kod çözme çalışmasında uygulanmıştır. Wang ve diğerleri (2013), parmak esnekliği gerçekleştirdiler ve ham ECoG sinyallerini kullanarak sınıflandırmaları genişletti. Ek olarak Stober ve diğerleri (2015) katılımcıların ham EEG sinyalleri ile dinledikleri müzikal ritimleri sınıflandırdılar.

1.5.Tezin Motivasyonu ve Konusu

Aritmiye bağlı ölüm sayısındaki artış aritmileri tanımlamak için geliştirilecek otomatik olarak tespit sistemlerin geliştirilmesini gerektirdi. Tespit sürecini hızlandırmak için otomatik tespit sistemlerinin geliştirilmesi ve kullanılması gerekmektedir. Geliştirilecek otomatik tespit sistemleri, hekimlerin aritmeleri tanımlamasında yardımcı olacaktır ve teşhiste olabilecek muhtemel hataların önüne geçilebilecektir. Aritminin saptanması örüntü tanıma problemidir ve EKG'den elde edilen veriler aritminin saptanması için hayati bir öneme sahiptir. Hastaya yerleştirilen elektrotlar kullanılarak kalbin elektriksel aktivitesini ölçmek ve kaydetmek mümkündür. Hastaya 10 elektrotun tam yerleşimi (her bacak ve kol için bir elektrot ve göğsün üzerine yerleştirilmiş altı tane olmak üzere) 12 kanallı EKG kaydı için gereklidir.

Araştırmanın amacı, dokuz sınıflı aritmi sınıflandırmasını yapmak için hızlı ve doğru bir yöntem bulmaktır. Bu tez çalışmasında genellikle daha nadir kullanılan St. Petersburg Kardiyoloji Tekniği Enstitüsü'nün 12 kanallı aritmi veri tabanı eğitim ve test için kullanılmıştır. Yapılan çalışmalar genelde bir kanallı ve MIT-BIH aritmi veri tabanını kullanmaktadır. Tüm veri harmanlanarak eğitim ve test olarak iki kümeye ayrılmıştır. Kümelerde eşit sayıda aritmi içeren ve içermeyen veri bulunmaktadır. Eğitim veri setine on kat çapraz doğrulama uygulandı. Öznitelik hesaplaması için sisteme gönderilmeden önce veriler sıkıştırılmış ve önceden işlenmiştir. Sıkıştırılma işlemi dalgacık tabanlı sıkıştırma yöntemiyle yapılmıştır. Benzer çalışmalarda sıkıştırılmış verilerle performans analizi yapan bir çalışmaya rastlanılmamıştır. Sıkıştırma sonucunda anlamlı veride bir kayıp olmamaktadır ve eğitim süresi kısalmaktadır. Ayrıca dalgacık yöntemiyle gürültü yok edilmiştir. Bunun dışında önışleme aşamasında trend eliminasyonu, taban düzeltilmesi ve normalleştirme yapılmıştır. Bu şekilde bir önışleme tabii tutulan verilerle çalışan benzer bir çalışmaya rastlanılmamıştır. Sınıflandırmada öznitelik olarak dalgacık katsayıları, morfolojik öznitelikler ve Hjorth parametreleri incelenmiş ve bu özniteliklerin birbirine göre avantajları ve değişik sınıflandırıcılar kullanılarak performansları karşılaştırılmıştır. Bu özniteliklerin birbiriyle karşılaştırıldığı bir çalışma bulunamamıştır. Ayrıca dalgacık katsayılarını hesaplarken iki küçük pencere kullanımı tercih edildi. Bu kullanım, öznitelik çıkarma için yalnızca bir pencere kullanma eğiliminde olan çoğu araştırmadan farklıdır. Benzer çalışmalarda Hjorth değişkenlerinin sadece birisi öznitelik olarak kullanılmıştır. Ancak bu çalışmada Hjorth değişkenlerinin hepsi öznitelik olarak kullanılmıştır. Ayrıca yapılan bu çalışmada benzer çalışmalara göre geniş bir veri tabanında çalışma yapıldı. Böylece sonuçlar daha gerçekçi olmuştur. Morfolojik öznitelikler olarak diğer çalışmalardan farklı bir set oluşturduk ve sınıflandırmaları yaptık. . Özniteliklere karar verildikten sonra, araştırmalarımızda kullanılacak daha iyi bir sınıflandırıcının olup olmadığını belirlemek için temel sınıflandırma yöntemlerinin yanı sıra derin öğrenme algoritmalarının performansı test edildi. Yine benzer çalışmalarda bu kadar geniş kapsamlı bir karşılaştırmaya rastlanılmamıştır. Özellikle derin öğrenme aşamasında KSA dışında nadir kullanılan, daha yeni ve hesaplama yükünü azaltan İSA algoritması da kullanılmıştır. KSA kullanımı için biri diğerinden daha derin iki ağ incelendi. Derin ağlarda daha gelişmiş öznitelikler ile daha yüksek başarıya ulaşıldı. Özniteliklerin incelenmesinde en hızlı özellik hesaplaması morfolojik öznitelikler olarak tespit edildi ve bu öznitelikler kullanarak gerçek zamanlı aritmi tespiti için simulink modeli geliştirilmiştir. Bu modelin karar verme kısmında daha

derin olarak oluşturulmuş KSA modelinden elde ettiğimiz karar verme süreci kullanıldı. Gerçek zamanlı aritmi analizinde oluşturulan benzer bir modele rastlanmamıştır. Ayrıca benzer çalışmalarda analizler ile ilgili bir hız testi verisine rastlanılmamıştır. Ancak yöntemin diğer yöntemlere göre daha hızlı olduğu düşünülmektedir.

Sinyali, bir öznitelik kümesi kullanmadan girdi olarak kullanarak, hesaplama yükünü azaltmak ve KSA'ndaki sınıflandırmaya yönelik işlemleri basitleştirmek mümkündür. KSA ile, çalışmamızda kullandığımız özniteliklere ek ayırt edici ve bilgilendirici bilgiler sağlayan önemli ve yeni öznitelikler oluşturulabilir. Öznitelik seçimi ve KSA'nın birlikte kullanımı ile daha başarılı sonuçlar elde edilebilir. Böylece, hızlı bir şekilde öğrenebilen ve yüksek doğruluk elde edebilen optimize edilmiş bir KSA tanımlanabilir.



2.YAPILAN ÇALIŞMALAR

2.1.Önişleme Yöntemleri

EKG sinyalini yüklediğimizde, bozulmalardan dolayı EKG sinyaline özgü olmayan desenler görülebilir. Veri analizi bu eğilimler tarafından engellenebilir. Sinyal üzerinde yapılan önişlemeler sinyalin daha hızlı ve doğru işlenmesini sağlayabilir.

2.1.1.Dalgacık Tabanlı Sıkıştırma

EKG sinyallerinde kullanılan sıkıştırma teknikleri, büyük veritabanlarında uzun süreli sinyallerle çalışmayı kolaylaştırdığı için giderek daha önemli hale gelmektedir. Dahası, EKG sinyallerinin kablosuz iletimini kolaylaştırırlar. Kalp hastalıkları söz konusu olduğunda, EKG verileri kırsal alanlardan hastanelere, teletıp kullanan uzman kardiyologlar tarafından incelenmek için aktarılabilir. Veriler analiz edildikten sonra, kırsal kesimde ilgili kişilere tıbbi öneriler gönderilebilir. Sinyallerin daha hızlı işlenebilmesi için sıkıştırılmış sinyaller kullanmaya karar verdik. Her sinyali sıkıştırdık ve öznitelik çıkartma için .mat dosyaları olarak kaydettik. Bu süreçte katsayılar hesaplanır ve sonra, bir eşik değeri seçilir. Bu eşikten küçük olan katsayılar göz ardı edildi. Sıkıştırılmış sinyaller, ağ üzerinden kaydedildiğinde veya iletildiğinde, orijinal sinyallerden çok daha düşük miktarda bilgisayar kaynağına ihtiyaç duyar. Ters dönüşüm uygulanırsa, orijinaline benzer bir sinyal elde edilir. Benzer bir sinyal elde etmek, orijinal sinyallerin özelliklerinin çoğunun sıkıştırılmış sinyallerde saklanabileceği anlamına gelir (Tomak ve Kayıkçıoğlu, 2018).

Sinyaller 5. seviyede ayrıştırıldı ve ana dalgacık olarak Daubechies 1 dalgacık kullanıldı. Eşik kriterler için, eşikleme yöntemi olarak, sabit eşikleme dağıtan küresel eşikleme kullanılmıştır. Küresel eşik için denge kısıtlama normu seçildi. 12 kanallı 30 dakika uzunluğunda bir sinyal için tespit edilen ortalama boyut 11.102.424 bayt (diğer şekilde 10,6 MB) olarak bulundu. Sıkıştırmadan sonra birinci kanal sinyal ortalama boyut değeri 95.121 bayt (diğer şekilde 92,9 KB) olarak bulundu. Dosya boyutunun ihtiyaç duyduğu hafıza miktarının oldukça düştüğünü söyleyebiliriz.

Dalgacık sıkıştırmalarının performans üzerine etkisini incelemek için yaptığımız analizlerde sınıflandırmaları yaparken karar ağaçları kullanıldığında bölünme ölçütü Gini

çeşitlilik indeksi seçilmiştir. Maksimum bölünme sayı değeri Karmaşık Ağaç için 100, Orta Seviye Ağaç için 20, Basit Ağaç için 4 olarak belirlendi. DVM için kutu kısıtlama seviyesi 1 olarak belirlendi. Çekirdek ölçek seçeneği Doğrusal, Kuadratik ve Kübik DVM için otomatik, Hassas Gauss DVM için 1.6 olarak, Orta Seviye Gauss DVM için 6.6 olarak, Yüzeysel Gauss DVM için 26 olarak belirlendi. Kernel fonksiyonu Doğrusal DVM için doğrusal, Kuadratik DVM için kuadratik, Kübik DVM için kübik, Hassas Gauss, Orta Seviye Gauss, Yüzeysel Gauss DVM için gauss olarak belirlendi. K-EYK sınıflandırması için, mesafenin önemi eşit olarak seçildi. Hassas, Orta Seviye, Yüzeysel, Ağırlıklı K-EYK için metrik mesafesi yöntemi Öklid olarak, Kosinüs K-EYK içinse kosinüs olarak, Kübik K-EYK içinse minkowski olarak belirlendi. Komşu sayısı Hassas K-EYK’de 1 olarak, Orta Seviye, Kosinüs, Kübik, Ağırlıklı K-EYK içinse 10 olarak, Yüzeysel K-EYK içinse 100 olarak seçildi. Geliştirilmiş Karar Ağaçlar için topluluk yöntemi AdaBoost olarak, öğrenme şekli karar ağacı olarak belirlendi. Maksimum bölünme miktarı 20 olarak, öğrenme oran değeri ise 0.1 olarak, öğrenen miktarı 30 olarak seçildi. Torbalama Karar Ağaçlar içinse topluluk yöntemi Bag, öğrenen miktarı ise 30 olarak ve öğrenme ekli karar ağacı olarak seçildi. Subspace Discriminant için grup metodu altuzay, öğrenme tipi diskriminant, öğrenen sayısı 30, altuzay boyutu 22 seçilmiştir. Altuzay Ayırımı içinse topluluk yöntemi altuzay, öğrenme şekli K-EYK, öğrenen miktarı 30 olarak ve altuzay büyüklüğü 22 olarak seçildi. RUSGeliştirilmiş Ağaçlar için topluluk yöntemi RUSBoost, öğrenme şekli karar ağacı, öğrenme oran değeri 0.1 olarak, öğrenen miktarı 30 olarak ve maksimum bölünme miktarı 20 olarak seçildi. Diskriminant Analiz düzenleme seviyesinde çapraz kovaryans kullanıldı.

Korunan enerji seviyesi % 99 seviyesindedir ve sıfır miktarı %97 seviyesinde olduğu görülmektedir, buna göre veri miktarı oldukça azaltılabilir. Bu süreçte büyük veri tabanını kullanarak çalışmanın sonuçların gerçekçi olması hedeflendi. EKG sinyallerindeki dalgacık yöntemi kullanarak sıkıştırmanın temel sınıflandırma yöntemlerindeki performansına bakınca, sıkıştırılmış veri kullanılarak yapılan sınıflandırmanın sonuçları, sıkıştırma olmadan yapılan sınıflandırmanın sonuçlarıyla karşılaştırıldı ve sonuçların oldukça yakın olduğu görüldü, sonuç olarak sıkıştırma süreci sınıflandırmaya olumsuz bir etki göstermemektedir. Veri aktarımında hız değerini önemli ise, veri boyutundaki azalma ve verinin en az kayıpla iletilmesi için sıkıştırma kullanılabilir. Bu süreçte dalgacık sıkıştırma yöntemini tercih ettik.

2.1.2. Dalgacık Yöntemiyle Gürültüden Kurtulma


Gürültüden Kurtulma süreci üç adım olarak ifade edebiliriz. İlk adımda ayrıştırma yapılır. Bir dalgacık ve bir seviye seçildikten sonra, belirlenen Seviyedeki sinyal için dalgacık ayrışması yapılır. Sonraki adımda her seviyede eşikler belirlenir, eşik değerleri ayrıntı katsayılarına uygulanır. Son adımda ise orijinal sinyalin yaklaşık katsayıları ve tüm seviyeler için düzenlenmiş detay katsayıları kullanılarak dalgacığın yeniden yapılandırılması tamamlanır. Dalgacık yönteminin kullanıldığı gürültüden kurtulma sürecinde ana dalgacık seçimi Daubechies 6'dır ve sinyalimizin beşinci seviye ayrıştırılması ile katsayılar bulunmuştur. Sabit değerde eşik eşik belirleme yöntemi olarak kullanılmıştır. Gürültü yapısı olarak ölçeklendirilmemiş beyaz gürültü belirlendi. Gürültüden Kurtulma sürecinden sonra, sentezlenmiş sinyal güncellendi. Bu işlev MATLAB dalgacık araç kutusunda bulunur.

2.1.3. Trend Eliminasyonu, Başlangıç Düzeltmesi ve Normalleştirme

Bu aşamadaki ön işleme aşamaları trend eliminasyonu, başlangıç düzeltmesi ve normalleştirme şeklindedir. MATLAB'da mevcut olan fonksiyon detrend kullanılarak doğrusal eğilim ortadan kaldırıldı. Doğrusal olmayan eğilim EKG sinyaline düşük dereceli bir polinom eklenerek ve çıkarılarak giderildi. Denklem 2.1, sinyalin ortalamasının, ham sinyalin her bir değerinden çıkarıldığı taban düzeltmesi içindir. Denklem 2.2, her bir değer sinyalinin, maksimum değerinin mutlak değeriyle bölüneceği normalizasyon içindir. Ön işlem adımları yani gürültünün yok edilmesi, trend eliminasyonu, taban düzeltmesi ve normalleştirme Şekil 2.1'de verilmiştir.

$$ECG\ Signal_{base\ line\ correction} = ECG\ Signal - mean(ECG\ Signal) \quad (2.1)$$

$$ECG\ Signal_{normalized} = \frac{ECG\ Signal}{|ECG\ Signal_{max}|} \quad (2.2)$$



Şekil 2.1. Ön işlem adımları

2.2.Öznitelik Çıkarma Yöntemleri

Sınıflandırmada öznitelik olarak dalgacık katsayıları, morfolojik öznitelikler ve Hjorth parametreleri incelenmiş ve bu özniteliklerin birbirine göre avantajları ve değişik sınıflandırıcılar kullanılarak performansları karşılaştırılmıştır.

2.2.1.Dalgacık Yöntemi Kullanılarak Aritmi Tespiti

Dalgacık yöntemi öznitelik çıkarma aşamasında oldukça kullanışlı bir yöntemdir. Fourier dönüşümü kullanarak sinyalin içerdiği tüm frekanslar bulunabilir. Yüksek frekans çözünürlüğü mevcuttur. Fakat bulunan frekansların hangi zamana ait olduğuna dair bir bilgi elde edilemez. Sonuç olarak EKG gibi durağan olmayan sinyallerde Fourier analizi kullanımı yeterli olmamaktadır. Bu sinyallerde oluşan kısa süreli darbelerin ve kompleks

dalgaların ne zaman meydana geldiğini bilmemiz önem taşımaktadır. Shannon dönüşümünde yüksek zaman çözünürlüğü vardır ancak, frekans çözünürlüğü bulunmamaktadır. Kısa zamanlı Fourier dönüşümü için bir zaman penceresi içinde Fourier dönüşümü uygulanmaktadır. Bu şekilde pencere içindeki frekans bileşenlerini belirlememiz mümkün olabilmektedir. Ancak frekansın kesin olarak görüldüğü zaman bilinmemektedir. Bu eksiklikten dolayı DD'üne ihtiyaç duyulmaktadır.

DD, sinyal işlemede kullanılan güçlü bir teknik olarak karşımıza çıkmaktadır. Bu dönüşüm yardımıyla sinyali frekans ve zaman alanında incelememiz mümkündür. Sahip olduğumuz sinyali DD'nden elde edilen katsayılar ile ifade edebileceğimiz için, bu sinyalleri sınıflandırmada yine bu katsayıları kullanmamız mümkündür.

Dalgacık fonksiyonu, Denklem 2.3'de görüldüğü gibi $t = 0$ 'a göre ortalananmış, normalize edilmiş ve sıfır ortalamalı bir fonksiyondur (Mallat, 2008).

$$\int_{-\infty}^{+\infty} \Psi(t) dt = 0 \quad (2.3)$$

$\Psi(t)$ = Dalgacık fonksiyonu.

DD'ünü konvolüsyon çarpımı olarak yeniden yazabiliriz (Mallat, 2008). Bu süreç Denklem 2.4 ve 2.5'de verilmiştir.

$$W f(u, s) = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \Psi^* \left(\frac{t-u}{s} \right) dt = f \star \bar{\Psi}_s(u) \quad (2.4)$$

$$\bar{\Psi}_s(t) = \frac{1}{\sqrt{s}} \Psi^* \left(\frac{-t}{s} \right) \quad (2.5)$$

DD'ünde ana dalgacık ve sinyalimiz birleştirilir. Bunun sonucunda oluşturulan veri ölçek katsayısıyla ölçek zaman formatında ifade edilir. Alçak frekans verisini uzun zaman aralığı kullanarak, yüksek frekans verisini kısa zaman aralığı kullanarak belirleriz.

ADD orijinal sinyali analiz etmek için yeterlidir ve hesaplamada ihtiyaç duyulan süreyi belirgin bir seviyede azaltır. ADD'nde sinyal filtreler kullanılarak iki ana bileşen olarak ayrılır. Alçak geçiren filtrenin çıkışından alınan düşük frekans içeren bileşenler bu iki ana bileşenin birisi, yüksek geçiren filtrenin çıkışından alınan yüksek frekans içeren bileşenler diğeridir.

Filtreleme sonucunda elde edilen iki sinyalden ilki yaklaşım (Approximation) ve diğeri detay (Detail) olarak isimlendirilmiştir. Yaklaşım ile sinyalin tanımı ifade edilir yani asıl sinyal temsil edilir. Detaylar ile sinyalin özelliğini veya ayrıntısı ifade edilir. ADD, yüksek frekanslar için çok iyi frekans çözünürlüğüne sahiptir, ayrıca alçak frekanslar için de başarılı zaman çözünürlüğüne sahiptir. Sinyal, birinci seviyedeki yüksek ve düşük frekans bileşenlerine ayrıştırılır. Enerjiyi daha fazla içeren birinci düşük frekans alt bantı, bir daha yüksek ve düşük frekans alt bantlarına ayrıştırılır. Bu, gerekli seviyeye ulaşıncaya kadar tekrarlanır. Bu süreç Denklem 2.6 ve 2.7’de verilmiştir.

$$y_{high}[k] = \sum_n x[n].g[2k - n] \quad (2.6)$$

$$y_{low}[k] = \sum_n x[n].h[2k - n] \quad (2.7)$$

Denklemden verilen $h[N - 1 - n] = (-1)^n g(n)$ ve N değeri $x[n]$ ’in mevcut örnekleme sayıdır.

Sinyal ADD’nden geçirildikten sonraki durumda bir kayıp söz konusu değildir. Ana dalgacık ve sinyal çarpılmış ve bileşenlerine ayrıştırılmıştır. Şekildeki cA3 yaklaşım bileşeni, bir temel bileşendir ve düşük frekanslı ve yüksek ağırlıklı bir bileşendir. Şekildeki cD1, cD2 ve cD3 ise detaylardır ve yüksek frekanslı, düşük ağırlıklı bileşenlerdir. Dikey dalgacık taban fonksiyonumuz Denklem 2.8’de verilmiştir.

$$\Phi_{(s,l)}(x) = 2^{\frac{-s}{2}} \Phi(2^{-s} x - l) \quad (2.8)$$

$\Phi_{(s,l)}(x)$ = Dikey dalgacık taban fonksiyonu, l = Konum indeksi,
 s = ölçek indeksi

Ayrık dalgacık ailesini oluşturmada ihtiyaç duyulan ana fonksiyonu genişletmek ve ölçeklemek için kullanılan değişkenler l ve s ‘tir l konum indeksidir ve konumu verir. s ölçek indeksidir ve dalgacığın genişliğini verir (Mallat, 2008).

Φ , analizi yapan dalgacıktan farklı çözünürlüklerde genişlemesi için ölçeklendirme Denklemi 2.9’den yararlanır.

$$W(x) = \sum_{k=-1}^{N-2} (-1)^k c_{k+1} \Phi(2x + k) \quad (2.9)$$

Denklemdaki $W(x)$ ölçekleme fonksiyonudur, Dalgacık katsayıları c_k Denklem 2.10 ve 2.11'de verilen iki koşulu sağlamalıdır.

$$\sum_{k=0}^{N-1} c_k = 2 \quad (2.10)$$

$$\sum_{k=0}^{N-1} c_k c_l = 2\delta_{l,0} \quad (2.11)$$

l = Konum indeksi ve δ = delta fonksiyonu.

Haar dalgacığı en basit yapıya sahip dalgacık fonksiyonudur. Kare şeklindeki fonksiyonların yeniden boyutlandırılmış bir bileşkesidir ve birlikte dalgacık ailesini oluştururlar. Haar dalgacığı, tüm dikey dalgacık yapıları arasındaki en küçük destekli yapıya sahip dalgacıktır. Pürüzsüz fonksiyonlarından dolayı benzetme için uygun değildir ve yalnızca sıfırlanan momente sahiptir (Mallat, 2008).

Daubechies dalgacık fonksiyonunda herhangi sayıdaki sıfırlanan moment, en küçük boyuttaki desteğe sahiptir (Mallat, 2008). Kompakt destekli dalgacıklar sonlu darbe-tepki eşlenik ayna filtreleri ile hesaplanır.

Dalgacık katsayılarını kullandığımız sistem giriş olarak 30 dakika süren 75 açıklamalı kayıt içeren St. Petersburg Kardiyoloji Tekniğı Enstitüsü'nün 12 kanallı aritmi veri tabanından toplanan EKG sinyallerini kullanır. Dalgacık katsayıları hesaplanırken iki küçük pencere kullanıldı. Bunun için her bir kayıta için, R tepe noktasının (maksimum değer) her iki tarafından 60 örnek alındı. Sonrasında öznitelik sayısı önemli ölçüde azaltıldı. Bu azaltma, sınıflandırma üzerinde en önemli etkiye sahip olan katsayıların belirlenmesi ve TBA kullanımıyla elde edildi. Bunun başarılması için önce, ilk üç katsayıları kullanarak sınıflandırma performansını kontrol ettik. Daha sonra, sınıflandırma üzerindeki etkisini gözlemlemek için dördüncü katsayı eklenmiştir. Bundan sonra, etkisini gözlemlemek için ilk katsayıyı kaldırdık. Sonra beşinci katsayı eklendi; sonra, ikincisini çıkardık. Bu teknik tekrar tekrar yapıldı. Ayrıca öznitelik setine standart sapma ve varyans ekledik. Öznitelik vektörleri oluşturulduktan sonra, özniteliklerin sayısı TBA ile daha da azaltıldı. Sinyal ile ilgili bilginin genelini koruduğumuz değişkenleri elde etmek için TBA algoritmasının

kullanımı tercih edildi. Bunu asıl bileşenlere, diğer deyişle birbiri ile ilgisi olmayan bir değişken topluluğuna dönüştürüp, varyasyonların geneli ilk değişkenlerde saklanır (Jolliffe, 2011).

TBA için temel adımlar

1. Verimizi hazırlarız. Sinyalimizin ortalamasını hesaplarız.
2. Ortalama değeri orijinal sinyalin değerlerinden çıkarırız. Sonuçta ortalaması sıfır seviyesinde olan veri kümemiz oluşturulur.
3. Kovaryans/korelasyon matrislerini hesaplarız.
4. Özdeğerlerini ve de özvektörlerini hesaplarız.
5. Özdeğerleri ve onlara karşılık gelen özvektörleri büyük değerden küçük değere doğru düzenleriz.
6. Ana bileşenleri seçeriz. Sonra yeni veri kümemizi oluştururuz.

Bu analiz, çok değişkenli ve de gerçek özvektör tabanlı analiz modelleri arasında en basitidir. Genellikle, çalışmanın verimize ait iç yapıyı ve verimizdeki varyansı olabilecek en iyi açıkladığı düşünülür. Çok değişkene sahip veri kümemizin, yüksek boyuta sahip veri alanındaki koordinat kümesi şeklinde görselleştirildiğini farz edelim. Bu durumda TBA, kullanıcıya bilgilendirici bir bakış açısından bakıldığı durumda, nesnenin alt boyutlu bir resimini sunar. TBA faktör analiziyle çok yakından ilişkilidir. Faktör analizi özgün olarak, matrisin özvektörlerini çözümler ve temelde yatan yapıyla ilişkili alana özgü olan varsayımları içerir. TBA, kanonik korelasyon analiziyle de ilgilidir. Kanonik Korelasyon Analizi, iki farklı veri kümesinin arasındaki çapraz kovaryansı olabilecek en iyi şekilde tanımlayan koordinat sistemini tanımlarken, TBA tek veri kümesinde hesaplanan varyansı optimum olacak şekilde tanımlayan yeni ortogonal koordinat sistemini tanımlar (Hsu vd., 2012). Son olarak değişik sınıflandırma yöntemleri karşılaştırıldı. Sonuçlar bulgular kısmında dayalı olarak verilmiştir. Sınıflandırıcıyı belirlemek için sınıflandırma yöntemleri ve derin öğrenme algoritmaları kullanıldı.

2.2.2. Hjorth Tanımlayıcılar Kullanarak Aritmi Tespiti

Çalışmamızın bu kısmında temel öznitelikler olarak Hjorth tanımlayıcıları kullanarak EKG sinyallerindeki aritmilerinin varlığı tespit ettik. EKG sinyalinde aritmi sınıflandırılması aşamasında öznitelik olarak kullanılmakta olan Hjorth tanımlayıcılar hareketlilik (mobility), aktivite (activity), karmaşıklık (complexity veya form-factor) olarak isimlendirilmektedir.

Hareketlilik değışkeni güç spektruma ait standart sapmanın oranı ifade etmektedir. Bu değışken sinyale ait birinci türevin varyans değerini, sinyalinin varyans değerine bölümünü ile bulunur. Aktivite ise sadece enerjiyi temsil eden sinyalin varyansdır. Karmaşıklık frekanstaki değışimi temsil eder. Bu değışken sinyal ile saf sinüs dalgası arasındaki benzerliğı karşılaştırmaktadır. Sinyalin saf sinüs dalgasına benzer bulunursa değeri 1 değerine yaklaşır. $x(n)$ sinyalimiz $n = 0, 1, 2, \dots, N - 1$ olmak üzere ve $x(n)'$ sinyalden türetilen ilk sıra değışkendir ve Denklem 2.12'de verilmiştir (Rizal ve Hadiyoso, 2015).

$$x(n)' = x(n) - x(n - 1), \quad n = 1, 2, \dots, N \quad (2.12)$$

Ayrıca Denklem 2.13'de verilen $x(n)''$, $x(n)'$ den ikinci sıra değışkeni olarak tanımlanır.

$$x(n)'' = x(n)' - x(n - 1)' \quad (2.13)$$

Denklem 2.14'de verilen σ_x , $x(n)$ den bir sapma standardı anlamına gelirse, $\sigma_{x'}$, $x(n)'$ nin sapma standardı olarak tanımlanacaktır. Böylece $\sigma_{x''}$, $x(n)''$ nin sapma standardıdır. $x(n)$ in sapma standardı Denklem 2.15'de verilmiştir.

$$\sigma_x = \sqrt{\frac{\sum_{n=0}^{N-1} (x(n) - \bar{x})^2}{N}} \quad (2.14)$$

$$\bar{x} = \sum_{n=0}^{N-1} x(n) \quad (2.15)$$

Aktivite, Denklem 2.16'da ifade edildiğı gibi sinyal varyasyonu olarak tanımlanır. Hareketlilik Denklem 2.17'de tanımlanırken, karmaşıklık Denklem 2.18'de açıklanmıştır.

$$Aktivite = \sigma_x^2 \quad (2.16)$$

$$Hareketlilik = \frac{\sigma_{x'}}{\sigma_x} \quad (2.17)$$

$$Karmaşıklık = \frac{M_{x'}}{M_x} = \frac{\sigma_{x''}/\sigma_{x'}}{\sigma_x'/\sigma_x} \quad (2.18)$$

Hjorth değişkenlerini kullanarak yaptığımız analizde bu değişkenlere ek olarak yine kolay hesaplanan korelasyon katsayısını ve Akaike Bilgi Ölçütünü (Akaike Information Criterion) ilave ettik. Sinyal gücünün aktiviteye oranı ve standart sapma, sınıflandırmada kullanılan diğer iki özneliktir. MATLAB kullanılarak bir şablon olarak aynı boyutta bir yapay EKG sinyali oluşturuldu ve bu yapay EKG sinyali ile sinyalin korelasyonu, sınıflandırmada kullanılan için başka bir öznelik olarak kullanıldı. Korelasyon sinyaller arasındaki ilişkiyi temsil eder, bu ilişkinin yönünü ve gücünü bildirir.

Akaike Bilgi Ölçütü (AIC), verileri sınıflandırmada kullanılabilecek başka bir yöntemdir. Kardys ve diğerleri (2003), bu özelliği ölümcül ve ölümcül olmayan kalp olayları için bölgesel QRS-T açısının prognostik önemini değerlendirmek için kullanmıştır. Akaike'nin bilgi ölçütünün hesaplanması, açının klasik kardiyovasküler ve EKG belirleyicileri tarafından tüm ölümcül uç noktaların tahminine önemli ölçüde katkıda bulunduğunu göstermiştir. Model setinden içinden bir model seçme yöntemidir. Veri modellerine ait bir set varsa, AIC bu set içindeki her modelin kalitesini, diğer modellerle göreceli olarak bilebiliyor. Seçilen model, model ile gerçek arasındaki Kullback-Leibler mesafesini en aza indiren modeldir. Bilgi teorisine dayanır, gerçeğe uygun ancak birkaç parametreye sahip model arayışında olan kriter için sezgisel bir yoldur (Burnham ve Anderson, 2003). Olabilirlik (likelihood), verilen modelin olasılığıdır ve K , modeldeki serbest parametrelerin sayısıdır. Denklem 2.19'daki gibi tanımlanır.

$$AIC = -2(\ln(\text{likelihood})) + 2K \quad (2.19)$$

Öznelikleri belirledikten sonra sınıflandırma aşamasına geçtik. Sınıflandırma türleri arasında karar ağaçları, DVM, diskriminant analizi, K-EYK, topluluk sınıflandırması yer alır. Denetimli makine öğrenimi, bilinen girdi veri seti ve verilere bilinen yanıtlar sağlayarak gerçekleştirilebilir. Veriler, yeni verilere yanıt için tahminler üreten modeli eğitmek için kullanılır. Modeli yeni verilerle kullanmak için, model çalışma alanına aktarılabilir veya eğitilmiş modeli yeniden oluşturmak için MATLAB kodu üretilebilir. Kullanılan veriler MIT aritmi veri tabanından alınmıştır (Goldberger vd., 2000). Bu veri tabanı, aritmi değerlendirilmesinde kullanılan standart test materyalinin ilk setlerinden oldu ve bu amaçla kullanıldı ve bu veri tabanı ile kardiyak dinamiğe yönelik temel araştırmalar yapılmıştır. MIT-BIH Aritmi Veri Tabanı, 1975-1979 yılları arasında BIH Aritmi Laboratuvarı

tarafından incelenen 47 denekten iki kanallı EKG kayıtlarının 48 adet yarım saatlik bölümünü içermektedir. Yirmi üç kayıt, Boston'daki Beth Israel Hastanesi'nde yatan hastalardan (yaklaşık% 60) ve ayakta hastalardan (yaklaşık % 40) toplanan EKG kayıtlarından rastgele seçildi; geriye kalan 25 kayıt, daha az yaygın fakat klinik olarak anlamlı aritmileri içerecek şekilde aynı setten seçildi. Hastalar 32-89 yaşlarında 25 kişilik erkek gurubu ve 23-89 yaşları arasında 22 kadın gurubu şeklindedir. Kayıtlar, her kanal için saniyede 360 örnekte 10 mV aralığındaki 11 bit çözünürlükte sayısallaştırıldı. İki ya da daha fazla kardiyolog, her kaydı bağımsız olarak çözümlendi. Veri tabanında yer alan her atım için bilgisayar tarafından okunabilir referans notları (tümü yaklaşık 110.000 ek açıklama) elde edildi. Tıbbi Cihazların Geliştirilmesi Derneği (Association for the Advancement of Medical Instrumentation, AAMI) tarafından kullanılan standartlara göre isimlendirilmişlerdir. 15 atım tipi tanımlanmıştır. Bunlar Normal atım, sağ dal bloğu(RBBB), sol dal bloğu(LBBB), erken kulakçık atımı(AP), anormal erken kulakçık atımı(aAP), normal ve karıncık atım füzyonu(fVN), erken ektopik atımı, ventriküler erken karıncık atım(VEK), düğüm kaçak atım(NE), ventriküler kaçak atım (VE), yapay vuru, normal ve yapay vuru füzyonu(fPN), ventriküler flutter dalga(junctional) erken atım(NP) ve sınıflandırılmayan atımlar(Q). şeklindedir.

2.2.3. Morfolojik Öznitelikler Kullanılarak EKG Sinyalinde Aritmi Tespiti

Morfolojik öznitelikler EKG sinyalinde kullanılan en yaygın öznitelik tipidir. Bunlar arasında QRS kompleksi kalp atımını tespit etmek için önemli bir özniteliktir. QRS kompleksi üç referans noktadan oluşmaktadır, ancak bunlardan biri olan R noktası kalp atımının tespit edilmesinde önemli bir özniteliktir. Bu nedenle bugüne kadar, R noktası bulunması ile ilgili çalışma yayınlanmıştır. Bu alanda en bilinen algoritmalarından olan Pan Tompkins Algoritması EKG sinyallerindeki QRS komplekslerini saptamak için geliştirilmiş gerçek zamanlı bir algoritmadır (Pan ve Tompkins, 1985). Eğim, genlik ve genişlik ile ilgili dijital analizlere dayanarak QRS komplekslerini güvenilir şekilde tespit eder. Özel bir bant geçiren filtre yardımıyla EKG sinyallerinde bulunan çeşitli parazit türlerinin neden olduğu yanlış tespitleri azaltır. Bu filtreleme, düşük eşiklerin kullanılmasına izin verir, böylece algılama hassasiyetini artırır. Algoritma, QRS morfolojisi ve kalp hızı gibi EKG değişikliklerine uyum sağlamak için eşikleri ve parametreleri otomatik olarak ayarlar. Standart 24 saatlik MIT / BIH aritmi veri tabanı için, bu algoritma QRS komplekslerinin

yüzde 99.3'ünü doğru olarak tespit eder. Doğrusal işlemler bir bant geçiren filtre, bir türev ve hareketli bir pencere birleştirici içerir. Kullandığımız doğrusal olmayan dönüşüm, sinyal genliğinin karesinin alınmasıdır. Adaptif eşikler ve T dalgası ayırma teknikleri, karar kural algoritmasının bir parçasıdır. R dalgasının eğimi, birçok QRS dedektöründe QRS kompleksinin yerini belirlemek için kullanılan popüler bir sinyal özelliğidir. Bununla birlikte, doğası gereği, bir türev, istenmeyen yüksek frekanslı gürültü bileşenlerini artırır. Ayrıca, büyük genlikleri olan ve uzun süren birçok anormal QRS kompleksi, nispeten düşük R dalga eğimlerinden dolayı salt türev bir yaklaşımında gözden kaçırılır. Böylece, QRS algılamada R dalgası eğimi tek başına yetersizdir. Güvenilir performans elde etmek için, sinyalden genlik, genişlik ve QRS enerjisi gibi diğer parametreleride çıkarmalıyız. Öncelikle, gürültüyü azaltmak için sinyal, peşpeşe yüksek geçiren ve alçak geçiren filtrelerden oluşan bir bant geçiren filtreden geçer. Filtrelemeden sonraki süreç, türev işlemidir. Peşinden kare alma ve hareketli pencere birleştirme işlemi gelir. QRS'nin eğimi hakkında bilgi türev aşamasında elde edilir. Kare alma işlemi, türevin frekans tepki eğrisinin eğimini yoğunlaştırır ve T dalgalarının neden olduğu yanlış pozitiflikleri sınırlamaya yardımcı olur. Hareketli pencere birleştiricisi, QRS kompleksinin eğimi ve genişliği hakkında bilgi içeren bir sinyal üretir.

Kullanabileceğimiz diğer bir yöntem tepe noktasının birinci türevinin aşağı yönlü gidişli ve tepe maksimum noktasında sıfır geçişi yaptığı gerçeğini kullanmaktır. Ayrıca matlab programında sinyal işleme araç kutusunda findpeaks komutunu kullanılabilir. Bu yöntemler ve diğerlerinin hepsinin bazı avantajları ve dezavantajları olacaktır. Sinyalde R noktasından sonra EKG sinyalimizin diğer önemli noktalarını, yani P, Q, S, T, U noktalarını bularak sinyali daha iyi tanımlayabiliriz. Bu noktaların varlığı ya da yokluğu, bulunduğu yer, özellikle QRS kompleksinin yapısı bize aritminin varlığı ve cinsi hakkında önemli bilgiler vermektedir.

EKG sinyallerindeki önemli noktaları tespit ederek aritmi tespiti için gerekli öznitelikler oluşturabiliriz. Bu aşamada aritmi tespitinde EKG sinyallerinden elde ettiğimiz morfolojik öznitelikleri kullanarak sınıflandırma aşamasında kullandık. Kullandığımız öznitelikler P-P aralığı, ortalama, standart sapma, çarpıklık, Q ile S arasındaki mesafe, Q ile R arasındaki eğim, R ile S arasındaki eğim, Q'dan S'ye varyans değeri şeklindedir. Bu sekiz öznitelik kullanılarak değişik sınıflandırma yöntemleri karşılaştırılmış ve bu özniteliklerle kullanılacak en uygun sınıflandırma yöntemi belirlenmiştir. Bu süreçte St. Petersburg Kardiyoloji Tekniği Enstitüsü'nün 12 kanallı aritmi veri tabanında analizler yapılmıştır.

Sinyal dördüncü seviye butterworth yüksek geçiren filtreden geçirilmiştir. Ayrıca dördüncü seviye butterworth alçak geçiren filtreden geçirilmiştir. Veriler için öznitelik çıkarımı yapıldıktan sonra veri test ve eğitim için rastgele iki eşit parçaya ayrılmıştır.

2.3.Sınıflandırma Yöntemleri

Veri bilimi, önemli bilgiye ulaşmak hedefiyle veriler üzerinde işlem yapmak ve de verileri analiz etmekte kullanılan bir disiplin olarak ifade edilebilir. Veri algılama, veriyi toplama, işleme, saklama, öznitelik çıkarımı, bilgi keşfi ve de veri madenciliği ile birlikte tüm sürecin desteklediği anlamındaki bütüncül yaklaşımdır. Veri madenciliği, bilinmeyen kalıplar bulmak amacıyla geniş veritabanlarının arasında geçiş yapabilme sürecini ifade eden bir terimdir. Veri madenciliğindeki hedeflerden birisi, belli olaylarda tahminler yapabilme becerisidir. Veri madenciliğindeki tekniklerin çoğunluğu endüktif öğrenme temellidir. Endüktif yaklaşımdaki varsayım, eğitilmiş bir modelin gelecekte bilinmeyen örnekler üzerine uygulanabilmesidir. Model, yeterli miktarda eğitim örneklerinden genelleme ile açık veya kapalı olarak oluşturulmaktadır (URL-1, 2017). Sınıflandırma, sınıfını bildiğimiz gözlemler ile oluşturulmuş eğitim setinden, yeni gözleme ait sınıfın bulunması sorunudur. Sınıflandırma yapabilmek için öznitelikler belirlenmelidir. Özniteliklerin seçiminin uygun olması sınıflandırmadaki sürecin daha kolay olmasını sağlar.

Temel sınıflandırma işlemleri MATLAB Classification Learner Yazılımı ve MATLAB fonksiyonları kullanılarak yapılmıştır. Bu tezde kullanılan temel sınıflandırma yöntemleri Support Vector Machines (Destek Vektör Makineleri): Linear SVM (Doğrusal DVM), Quadratic SVM (Kuatratik DVM), Cubic SVM (Kübik DVM), Fine Gaussian SVM (Hassas Gauss SVM), Medium Gaussian SVM (Orta Seviye Gauss DVM), Coarse Gaussian SVM (Yüzeysel Gauss DVM); Nearest Neighbors (En Yakın Komşular): Fine KNN (Hassas K-EYK), Medium KNN (Orta Seviye K-EYK), Coarse KNN (Yüzeysel K-EYK), Cosine KNN (Kosinüs K-EYK), Cubic KNN (Kübik K-EYK), Weighted KNN (Ağırlıklı K-EYK); Decision Trees (Karar Ağaçları): Simple Tree (Basit Karar ağacı), Medium Tree (Orta Seviye Karar ağacı), Complex Tree (Kompleks Karar ağacı); Discriminant Analysis (Diskriminant Analiz): Linear Discriminant (Doğrusal Diskriminant), Quadratic Discriminant (Kuatratik Diskriminant); Logistic Regression (Lojistik Regresyon) ; Ensemble Classifiers (Topluluk Sınıflandırıcıları): Boosted Trees (Geliştirilmiş Karar Ağaçlar), Bagged Trees (Torbalama Karar Ağaçlar), Subspace Discriminant (Altuzay

Ayırımı), Subspace KNN (Altuzay K-EYK), RUSBoosted Trees (RUSGeliştirilmiş Ağaçlar) şeklindedir.

Bu tezde kullanılan derin öğrenme yöntemleri Konvolüsyonel Sinir Ağı (Convolutional Neural Networks) ve İğnecikli Sinir Ağları (Spiking Neural Networks) şeklindedir.

2.3.1. Destek Vektör Makinesi

DVM, sınıflandırma problemlerinin çözümü için başarıyla uygulanmakta olan bir tekniktir ve yüksek genelleme performansına sahip etkin bir makine öğrenimi algoritmasıdır (Ayhan ve Erdoğan, 2014). Cortes ve Vapnik tarafından 1995’de örüntü tanıma ayrıca sınıflandırma için geliştirilmiştir. Temelleri Vapnik-Chervonenkis teorisinden gelmektedir. DVM, ilk zamanlarda iki gruplu sınıflandırma problemleri için geliştirilmiş bir öğrenme makinesidir. İlerleyen zamanlarda çok sınıflı ve de doğrusal olmayan durumlar için de kullanılmaya başlandı. Girdi vektörleri, doğrusal olmayan şekilde çok boyutlu bir öznitelik alanına eşlenir (Cristianini ve Shawe-Taylor, 2000). Bu öznitelik alanında doğrusal bir karar yüzeyi oluşturulur. Karar yüzeyinin özel öznitelikleri, öğrenme makinesinin yüksek genelleme kabiliyetini sağlar. Destek-vektör ağının arkasındaki fikir, eğitim verilerinin hatasız bir şekilde ayrılacağı kısıtlı durumda uygulanmıştır. DVM, genel olarak aykırı noktalara dayanıklıdır. DVM, verileri ayırtmak için en uygun hiperdüzlemi bulur. Bu hiperdüzlem sınıflar arasındaki en geniş ayrımı içerir (Cortes ve Vapnik, 1995).

2.3.1.1. Doğrusal DVM

Doğrusal DVM için verilerin doğrusal olarak ayrılabilir olması için gerekli koşullar aşağıda verilmiştir. Denklem 2.20’de verilen tanımlı eğitim örnekleri kümemizde x_i m örnekten oluşan veri tabanımızdır ve y_i ise etiket değerimizdir (Cortes ve Vapnik, 1995).

$$(y_1, x_1), \dots, (y_m, x_m), \quad y_i \in \{-1, 1\} \quad (2.20)$$

Denklem 2.21 ve 2.22’de verilen eşitsizlikleri sağlayacak bir vektör w ve bir skaler b varsa, sistemi doğrusal olarak ayrabileceğimizi söyleyebiliriz. Burada w ağırlık vektörü, b ise eğilim değerini ifade eder.

$$w \cdot x_i + b \geq 1 \text{ eğer } y_i = 1 \quad (2.21)$$

$$w \cdot x_i + b \leq -1 \text{ eğer } y_i = -1 \quad (2.22)$$

Destek vektörleri, ayıran hiperdüzlem e en yakın olan veri noktalarıdır. En uygun hiperdüzlem, eğitim verilerini maksimum mesafe ile ayıran benzersiz bir ayırıcıdır ve w normaline ayrıca $\frac{|b|}{\|w\|}$ orijinle dik uzaklığına sahiptir ve Denklem 2.23’de verilmiştir.

$$w_0 \cdot x + b_0 = 0 \quad (2.23)$$

İki farklı sınıfın eğitim vektörlerinin izdüşümü arasındaki mesafenin maksimumu olduğu yönü belirler. Sonuç olarak hiperdüzleme en yakın örneklerle ait hiperdüzleme ters uzaklığı ise sahip olunan ağırlık vektörüne ait norma eşittir. Doğrusal DVM sınıflandırmasında tahmin edebilme hızı orta düzeydedir. Hafıza kullanımı ortalama bir seviyededir. Yorumlanabilirliği kolaydır. Model esnekliği azdır. Kutu sınırlama düzeyini belirleyerek, Lagrange çarpanları değerini sınırlı bölgede tutabiliriz. Arttırılması durumunda eğitim süresi artabilir, fakat bu durumda destek vektörlerinin sayısı azalır. DVM’de, iki sınıfı ayıran doğrusal hiper düzlemin tespiti kolaydır. Diğer durumlarda ise yani doğrusal olmayan DVM, veri setinin herhangi bir doğrusal fonksiyon ile tam olarak veya belirli hatayla ayrılabilmesi halinde kullandığımız algoritmalarıdır.

Bu durumlarda DVM, çekirdek (kernel) tekniğini kullanır. Bunlar, küçük hacimli girdi alanını alarak yüksek boyutlu boşluğa çeviren işlevlerdir ve doğrusal olmayan ayırma problemi için genellikle yararlıdır. Değişik veri setlerinde yapılan sınıflandırma sürecinde çekirdek fonksiyonunun seçimi ve de parametre en uygun hale getirilmesi önemlidir. Çekirdek fonksiyonları ile girdilere ait iç çarpımlar hesaplanmaktadır. Lagrange çarpanları ağırlıkları ifade etmektedir. P boyutuna sahip x girdi vektörünün yine P boyutuna sahip Φ öznitelik vektörüne dönüşmesi için en uygun ayırma düzlemi öznitelik uzayında tanımlanmalıdır. Bunun için ise doğrusal olmayan bir haritalama yaklaşımına başvurulur. Bu haritalama yaklaşımında x orijinal giriş uzayı, Hilbert uzayı şeklinde F yüksek boyutlu bir öznitelik uzayına dönüştürülür ve ayırım gerçekleştirilir. İki boyutlu olan giriş vektörü

(x_1, x_2) ve de üç boyutlu olan öznitelik uzayı (z_1, z_2, z_3) olacak şekilde, fonksiyonlara ait öznitelik uzayı Denklem 2.24 ile gösterilir.

$$\emptyset: R^2 \rightarrow R^3 \quad (x_1, x_2) \rightarrow (z_1, z_2, z_3) = (x_1^2, \sqrt{2}x_1x_2, x_2^2) \quad (2.24)$$

Doğrusal olmayan DVM'de sınıflandırıcı karar verme fonksiyonu Denklem 2.25 ile gösterilir.

$$f(x) = \text{sign}((w', x_1) + b') = \text{sign}(\sum_{i=1}^n y_i \alpha_i (\emptyset(x_i) \emptyset(x_j))) \quad (2.25)$$

2.3.1.2. Kuadratik DVM

Kuadratik DVM sınıflandırma yönteminde tahmin edebilme hızı yavaştır (Cristianini ve Shawe-Taylor, 2000).. Fazla hafıza kullanımı ve zor yorumlanabilirlik seviyesi diğer dezavantajlarıdır. Model esnekliği ise orta seviyelerdedir. Kutu sınırlama düzeyi olarak 1 seçildi. Otomatik çekirdek ölçek modunda ayarlanmıştır. Çoklu sınıflandırma yöntemi birebir olarak seçilmiştir. Kuadratik çekirdek fonksiyonuna sahiptir.

2.3.1.3. Kübik DVM

Kübik DVM sınıflandırma yönteminde tahmin edebilme hızı yavaştır (Cristianini ve Shawe-Taylor, 2000). Fazla hafıza kullanımı ve zor yorumlanabilirlik seviyesi diğer dezavantajlarıdır. Model esnekliği ise orta seviyelerdedir. Kutu sınırlama düzeyi olarak 1 seçildi. Otomatik çekirdek ölçek modunda ayarlanmıştır. Çoklu sınıflandırma yöntemi birebir olarak seçilmiştir. Kübik çekirdek fonksiyonuna sahiptir.

2.3.1.4. Hassas Gauss DVM

Hassas Gauss DVM sınıflandırma yönteminde tahmin edebilme hızı yavaştır (Cristianini ve Shawe-Taylor, 2000). Fazla hafıza kullanımı ve zor yorumlanabilirlik seviyesi diğer dezavantajlarıdır. Model esnekliği ise yüksek seviyelerdedir. Çekirdek ölçeği olarak $\sqrt{P}/4$ belirlendi ve sınıflar arası ince detaylı ayırım yapar. P ise tahmin edicilerin

miktardır. Kutu sınırlama düzeyi 1 olarak seçildi. Çoklu sınıflandırma yöntemi birebir olarak seçilmiştir. Gauss çekirdek fonksiyonuna sahiptir.

2.3.1.5. Orta Seviye Gauss DVM

Orta Seviye Gauss DVM sınıflandırma yönteminde tahmin edebilme hızı yavaştır (Cristianini ve Shawe-Taylor, 2000).. Fazla hafıza kullanımı ve zor yorumlanabilirlik seviyesi diğer dezavantajlarıdır. Model esnekliği ise orta seviyelerdedir. Çekirdek ölçeği olarak \sqrt{P} belirlendi ve sınıflar arası orta seviye ayırım yapar. Kutu sınırlama düzeyi 1 olarak seçildi. Çoklu sınıflandırma yöntemi birebir olarak seçilmiştir. Gauss çekirdek fonksiyonuna sahiptir.

2.3.1.6. Yüzeysel Gauss DVM

Yüzeysel Gauss DVM sınıflandırma yönteminde tahmin edebilme hızı yavaştır (Cristianini ve Shawe-Taylor, 2000).. Fazla hafıza kullanımı ve zor yorumlanabilirlik seviyesi diğer dezavantajlarıdır. Model esnekliği ise düşük seviyelerdedir. Çekirdek ölçeği olarak $\sqrt{P} * 4$ belirlendi ve sınıflar arası yüzeysel seviye ayırım yapar. Kutu sınırlama düzeyi 1 olarak seçildi. Çoklu sınıflandırma yöntemi birebir olarak seçilmiştir. Gauss çekirdek fonksiyonuna sahiptir.

2.3.2. K-En Yakın Komşu Sınıflandırması

K-EYK sınıflandırmasını kullanmamızın en önemli nedenlerinden biri, mesafeye dayalı sınıflandırma sürecinin basit ve etkili bir yöntem olmasındandır (Cover ve Hart, 1967). K-EYK algoritması, olabilecek en küçük mesafeye sahip noktaları bulur ve bu noktalara ait olan sınıf bilgilerini kullanıp yeni noktaya ait sınıfı tanımlayabilen bir yöntemdir. Noktalara olan uzakları bulabilmek için değişik yöntemler mevcuttur. Mesafe ölçüm yöntemi olarak genellikle Öklid uzaklığı seçilmektedir. İki noktamız x_i ve y_i arasında bulunan öklid uzaklığı Denklem 2.26 ile bulunabilir.

$$\text{ÖU} = \sqrt{\sum (x_i - y_i)^2} \quad (2.26)$$

ÖU = Öklid uzaklığı, $x_i = x$ konum değeri, $y_i = y$ konum değeri.

Eğer $m \times n$ 'e boyutunda veri matrisi X verildiğinde, burada $m \times n$ satır vektörleri $x_1, x_2, \dots, x_{m \times n}$ olarak değerlendirilir ve Eğer $n \times m$ 'e boyutunda veri matrisi Y verildiğinde burada $n \times m$ satır vektörleri $y_1, y_2, \dots, y_{n \times m}$ olarak değerlendirilir ise vektör x_i ve y_i arasındaki çeşitli mesafeler aşağıda tanımlanmaktadır.

K-EYK sınıflandırma sürecinde, kaba veya hassas sınıflandırıcıyı belirten komşu miktarını belirtmeliyiz. Bu algoritma başarılı sonuçlar vermesi, basit ve hızlı olması, gürültü içeren verilere karşı dayanıklılığı ile bilinmektedir. Bu nedenle pek çok alanda yaygın olarak kullanılmaktadır. Ağırlıklandırma fonksiyonu seçiminde ters, kare ters veya eşit mesafe seçimi yapılabilir. Ters ağırlıklandırma fonksiyonu seçiminde ağırlık değeri $1 / \text{mesafe}$ şeklindedir. Kare ters ağırlıklandırma fonksiyonu seçiminde ağırlık değeri $1 / \text{mesafe}^2$ şeklindedir. Eşit ağırlıklandırma fonksiyonu seçiminde ağırlıksızdır. Her koordinat mesafesine ait ölçeklendirme karar vereceğimiz başka bir özneliktir. Genelde verilerde standartlaştırma tercih edildi.

2.3.2.1. Hassas K-EYK

Hassas K-EYK sınıflandırması algoritmasında tahmin edebilme hızı orta düzeydedir (Stork ve Yom-Tov, 2004). Bellek kullanımında orta seviyededir. Yorumlama yeteneği açısından zordur. Sınıflar arasında detaylı şekilde ayrımlar tanımlanır. Hassas K-EYK sınıflandırma yönteminde için komşuların miktarını düşük bir değer olarak belirledik. Çok miktarda komşunun var olması ve kullanılması zaman alıcıdır ve model esnekliğini azaltmaktadır.

2.3.2.2. Orta Seviye K-EYK

Orta Seviye K-EYK sınıflandırması algoritmasında hassas K-EYK algoritmasına göre az ayırım yapabilen K-EYK sınıflandırma algoritmasıdır (Stork ve Yom-Tov, 2004). Bu sınıflandırma algoritmasında model esnekliği azalmış ve de hesaplama zorlaşmıştır. Fakat karar vermekte daha fazla komşudan yararlanması modelin kararlılığını geliştirmiştir. Tahmin edebilme hızı ve de bellek kullanım seviyesi orta düzeydedir. Yorumlanabilirlik açısından zor yorumlanabilir. Sınıfları ayıran orta seviyede ayrımlar tanımlanır.

2.3.2.3. Yüzeysel K-EYK

Yüzeysel K-EYK sınıflandırması algoritmasında komşuların sayısı daha da artmıştır. Model esnekliği azalmış ve de hesaplama çok zorlaşmıştır (Stork ve Yom-Tov, 2004). Fakat karar vermekte çok komşudan yararlanması modelin kararlılığını geliştirmiş ve de sınıflar arasında yüzeysel ayrımlar belirlenmiştir. Tahmin edebilme hızı ve de bellek kullanım seviyesi orta düzeydedir. Yorumlanabilirlik açısından zor yorumlanabilir.

2.3.2.4. Kosinüs K-EYK

Kosinüs K-EYK sınıflandırması algoritmasında komşuların sayısı yaklaşık orta derece K-EYK sınıflandırması algoritmasındaki seviyede seçeriz (Stork ve Yom-Tov, 2004). Tahmin edebilme hızı ve de bellek kullanım seviyesi orta düzeydedir. Yorumlanabilirlik açısından zor yorumlanabilir. Kosinüs uzaklık metrik sistemi kullanarak sınıfları ayıran orta seviyede ayrımlar tanımlanır.

2.3.2.5. Kübik K-EYK

Kübik K-EYK sınıflandırması algoritmasında komşuların sayısı yaklaşık orta derece K-EYK sınıflandırması algoritmasındaki seviyede seçeriz (Stork ve Yom-Tov, 2004). Modelin kararlılığı artmıştır. Tahmin edebilme hızı düşük düzeydedir. Bellek kullanım seviyesi orta düzeydedir. Yorumlanabilirlik açısından zor yorumlanabilir. Kübik mesafe hesaplama yöntemi kullanarak sınıfları ayıran orta seviyede ayrımlar tanımlanır.

2.3.2.6. Ağırlıklı K-EYK

Ağırlıklı K-EYK sınıflandırması sınıflandırması algoritmasında komşuların sayısı yaklaşık orta derece K-EYK sınıflandırması algoritmasındaki seviyede seçeriz (Stork ve Yom-Tov, 2004). Tahmin edebilme hızı ve de bellek kullanım seviyesi orta düzeydedir. Yorumlanabilirlik açısından zor yorumlanabilir. Ağırlıklı mesafe hesaplama yöntemi kullanarak sınıfları ayıran orta seviyede ayrımlar tanımlanır.

2.3.3.Karar Ağaçları

Karar ağaçları sınıflandırmanın hızlı yapılabilmesi için en uygun seçeneklerdendir. Karar ağacında öğrenme sürecinde, ögenin hakkındaki gözlemler ile ögenin sınıfı ile ilgili sonuca gitmekte bir karar ağacı kullanılır (Breiman, 2017). Karar ağacı yapısındaki yapraklar sınıfları ifade eder. Dallar ise sınıf etiketlerine giden özelliklerin birleşkesidir. Karar ağaç yapısı, köklü ağacı bir araya getiren düğümlerden oluşur. Giden kenarları varolan düğüme test düğümü veya iç düğüm denir. Diğer düğümler ise yapraklar olarak ifade edilir veya karar düğümleri veya uç düğümler olarak da bilinmektedir. Karar ağacın yapısında, her iç düğüm örnek alanını, iki ya da daha fazla bölgeye böler. Her yapraksa uygun hedefe ait değeri ifade eden sınıflara ayrılır. Kök düğümünden sonraki her düğümden karar verilmesi gerekir. Bu süreç yapraklara kadar devam ettirilir (Rokach ve Maimon, 1967).

Karar ağaçlarında yorumlanma yapmak kolaydır. Bellek kullanım seviyesi düşüktür. Ancak muhtemel düşük öngörme doğruluk seviyesi en belirgin dezavantajdır. Bölünme kistası seçiminde genelde Gini çeşitlilik endeksi tercih edilmiştir. Gini çeşitlilik endeksi, hedef özellik değerinin olasılık dağılımı arasındaki farkı ölçen ve de saf olmama temelli bir ölçüt olarak ifade edilir. Gini katsayısı en uygun şekilde, göreceli ortalama fark olarak sırasız büyüklükteki verilerden kolayca hesaplanır (Coppersmith vd., 1999).

2.3.3.1.Basit Karar Ağacı

Basit karar ağaç yapısına ait model esnekliği düşük seviyededir (Breiman, 2017). Az yaprak bulundurur. Basit karar ağacında maksimum bölünme sayı değeri ile ağacın derinliği kontrol edebilir. Büyük değer alınırsa işlemcideki yük ve sonuç olarak hesaplama süresi artacaktır. Böylece model karmaşık bir yapıya bürünecektir. Eğer küçük bir değeri seçerse sık bir ağacımız olur ve hızlı karar verebilir. Fakat modelin doğruluk yüzdesi azalacaktır. Basit karar ağaçlarında büyük değer seçemeyiz. Büyük değerler daha karmaşık ağaç yapıları için kullanılır.

2.3.3.2.Orta Seviye Karar Ağacı

Orta seviye karar ağaç yapısına ait model esnekliği ortalama seviyededir (Breiman, 2017). Orta seviye yaprakları vardır. Orta seviye karar ağaç yapımızda maksimum bölünme değeri için küçük değerler kullanmayız. Ancak çok büyük değerlerde kullanmayız.

2.3.3.3. Kompleks Karar Ağacı

Kompleks karar ağaç yapısına ait model esnekliği yüksek seviyededir (Breiman, 2017). Çok sayıda yaprakları vardır. Kompleks karar ağaç yapımızda maksimum bölünme değeri büyük değer olarak belirlenmelidir.

2.3.4.Diskriminant Analiz

Diskriminant analizi doğrusal diskriminant analiz ve kuadratik diskriminant analiz olarak iki ayrı sınıfta inceleyebiliriz.

2.3.4.1. Doğrusal Diskriminant Analiz

Doğrusal diskriminant analizi, mucidi R. A. Fisher için isimlendirilen Fisher diskriminantı olarak da bilinir (Fisher, 1936). Doğrusal Diskriminant analizinde önceden iki ya da daha fazla sınıf bilinmektedir ve yeni gözlemler ve ölçülen özelliklere bağlı olarak bilinen sınıflara ayrılmaktadır. Her sınıf, çok değişkenli normal dağılım kullanarak veri üretir. Başka bir deyişle, model verinin Gaussian karışım dağılımına sahip olduğunu varsayar. Doğrusal diskriminant analizi için, model her bir sınıf için aynı kovaryans matrisine sahiptir, ortalamalar değişir. Doğrusal diskriminant analizi için, her bir sınıfın örnek ortalamasını hesaplar. Daha sonra, her bir sınıfın örnek ortalamasını o sınıfın gözlemlerinden çıkartarak ve sonucun ampirik kovaryans matrisini alarak örnek kovaryansı hesaplar.

2.3.4.2. Kuadratik Diskriminant Analiz

Kuadratik diskriminant analizi için, her bir sınıfın ortalaması ve kovaryansı değişir (Stork ve Yom-Tov, 2004). Kuadratik diskriminant analizi için, her bir sınıfın örnek ortalamasını hesaplar. Daha sonra, her bir sınıfın örnek ortalamasını o sınıfın gözlemlerinden çıkartarak ve her bir sınıfın ampirik kovaryans matrisini alarak örnek kovaryansları hesaplar.

2.3.5. Lojistik Regresyon

Lojistik regresyon, amacın bir şeyin olasılığının diğer değişkenlerin bir fonksiyonu olarak modellemek olan özel bir regresyon türüdür (Menard, 2002). Lojistik regresyon, bağımlı değişkenin kategorik olduğu bir regresyon modelidir. Burada x_1, x_2, \dots, x_N gözlemlerin sayısıdır ve x_i , i 'nci gözlem için d prediktörlerinin değerlerini içeren bir sütun vektörüdür. x_i için yanıt değişkeni Z_i 'dir. Z_i , n deneme sayısı ve μ deneme i için başarı olasılığı ile bir Binom rasgele değişkeni temsil eder. Normalleştirilmiş yanıt değişkeni (gözlem i için n denemelerde başarı oranı) Denklem 2.27'de verilmiştir.

$$Y_i = \frac{Z_i}{n} \quad (2.27)$$

2.3.6. Topluluk Sınıflandırıcıları

Bu yöntem ile çok sayıdaki zayıf öğrenici bir araya gelir ve bu süreçte güçlü bir öğrenici oluşturulur. Denetimli öğrenme yöntemleri, genellikle bir veri matrisi ile başlar. veri matrisi X 'in her satırı bir gözlemi temsil eder. Her X sütunu ise bir değişkeni veya belirleyiciyi temsil eder. Bir topluluğun boyutunu seçmek dengeleme hızını ve doğruluğunu içerir. Daha büyük topluluklar eğitim ve tahminler üretmek için daha uzun sürer. Bazı topluluk algoritmaları çok büyük olduğunda yanlış yapma eğilimi olabilir. Uygun bir boyut ayarlamak için, bir grupta birkaç düzine ile birkaç yüz üyeye başlamayı, topluluğu eğitmeyi ve daha sonra topluluk kalitesi kontrol edilmelidir. Düzenleme, bir topluluk için daha az zayıf öğreniciyi öngörücü performansı azaltmayacak şekilde seçme sürecidir ve Denklem 2.28'de verilmiştir. Düzenli hale getirme yöntemi, en aza indirgeyen, en uygun öğrenci ağırlıkları α_t setini bulur.

$$\sum_{n=1}^N w_n g\left(\left(\sum_{t=1}^T \alpha_t h_t(x_n)\right) y_n\right) + \lambda \sum_{t=1}^T |\alpha_t| \quad (2.28)$$

Burada $\lambda \geq 0$, lasso parametresi olarak adlandırdığınız bir parametredir. Ayrıca h_t ise x_n belirleyiciler, y_n sınıfları, w_n ağırlıkları ve N gözlemleri eğitilmiş topluluk içinde zayıf bir öğrenendir. $g(f, y) = (f - y)^2$ karesi alınmış hatadır.

Topluluk, eğitim için kullanılan aynı (x_n, y_n, w_n) verilerde düzenlenmiştir. Topluluk yeniden ikame hatası Denklem 2.29'de verildi. Hata, ortalama kare hatası (Mean Squared Error, MSE.) yöntemiyle ölçülür.

$$\sum_{n=1}^N w_n g\left(\left(\sum_{t=1}^T \alpha_t h_t(x_n)\right) y_n\right) \quad (2.29)$$

Eğer $\lambda = 0$ kullanırsanız, düzenlenme, MSE'sini en aza indirerek zayıf öğrenici ağırlıklarını bulur. Yeniden ikame hatası genellikle gerçek genelleme hatasından daha küçüktür. Yeniden yerleştirme hatasını daha da küçük yapmak, onu iyileştirmek yerine topluluk doğruluğunu daha da kötüleştirebilir. Diğer yandan, λ pozitif değerleri α_t katsayılarının büyüklüğünü 0'a itmektedir. Bu genellikle genelleme hatasını artırır. Tabii ki, eğer çok büyük seçerseniz, tüm optimal katsayılar 0'dır ve topluluğun hiçbir doğruluğu yoktur. Normalde, düzenlenmiş toplulukların doğruluğunun, düzenleyici olmayan bütün topluluklar ile daha iyi veya karşılaştırılabilir olduğu λ için en uygun aralık bulunabilir. Lasso düzenliliğinin güzel bir özelliği, optimize edilmiş katsayıları kesin olarak 0'a sürdürebilmesidir. Öğrenicinin ağırlığı α_t 0 ise, bu öğrenici düzenlenmiş topluluktan hariç tutulabilir. Sonunda, gelişmiş doğruluk ve daha az öğrenici ile bir topluluk elde ederiz.

2.3.6.1. Geliştirilmiş Karar Ağaçları

Geliştirilmiş Karar Ağaçlar sınıflandırma yönteminde, topluluk yöntemi AdaBoost'dır. Uygulanabilirlik, az hafıza kullanımı, yüksek tahmin hızı tercih edilme sebepleridir. Ancak, etkili tahminler için, Geliştirilmiş Karar Ağaçları, Torbalama karar ağaçlarından daha fazla topluluk üyelerine ihtiyaç duyabilir (Freund ve Schapire, 1997).

Öğrenme şekli karar ağacıdır. Karar ağacı, hızlı sınıflandırmada kullanılabilecek en iyi seçeneklerdendir ve yorumlanması kolaydır. Maksimum bölünme sayısı ile ağacın derinliğini kontrol ederiz. Model esnekliği ise, öğrenen miktarıyla artar. Fakat öğrenen sayısını artırırsak modelin sınıflandırmada kullanacağı zamanda artacaktır. Öğrenen sayısı

değiştirilerek performansta bir artış ve sınıflandırma aşamasındaki ihtiyaç duyulan süredeki değişime bakıp uygun öğrenme değerini belirleriz. Düşük öğrenme oranı ile daha da az öğrenen miktarına ihtiyaç duyulur. Küçük miktar seçilerek iyi bir sınıflandırma yapılması mümkündür fakat sınıflandırmada ihtiyaç duyulan zaman ve de öğrenen sayısı artacaktır.

2.3.6.2.Torbalama Karar Ağaçları

Torbalama karar ağaçlarında topluluk yöntemi torbalama seçildi. Torbalama çoğunlukla derin ağaçlar oluşturmaktadır. Bu yapı zaman alıcıdır ve de yoğun bellek kullanımına ihtiyaç duyar. Sonuçta tahminler daha yavaş yapılabilir. Bu yöntemde çapraz doğrulama olmadan genelleme hatasını tahmin edebiliriz (Breiman, 1996).

2.3.6.3.Altuzay Ayırımı

Altuzay ayırımı sınıflandırma yönteminde topluluk yöntemi altuzaydır. Öğrenme şekli diskriminant analizidir. Artan öğrenen sayısı sınıflandırmada artan performansa neden olabilir fakat sınıflandırma için ihtiyaç duyulan süre artıracaktır. Altuzay boyutu rastlantısal her bir öğrenene dâhil edeceğimiz öngörücü miktarını belirtir (URL-1, 2017).

2.3.6.4. Altuzay K-EYK

Altuzay K-EYK sınıflandırma yönteminde topluluk yöntemi altuzaydır. Öğrenme şekli K-EYK algoritmasıdır (URL-1, 2017).

2.3.6.5. RUSGeliştirilmiş Ağaçlar

RUSGeliştirilmiş ağaç sınıflandırma yönteminde topluluk yöntemi RUSBoost'dur. RUSBoost, SMOTEBoost algoritmasıyla ilişkilidir. SMOTEBoost, zeki aşırı örnekleme yöntemi kullanımıyla AdaBoost'u geliştirdi. RUSBoost hızlı model eğitimi süresi ve de olumlu performansı ile basit bir algoritma olarak görünebilir. Eğitim verilerinin gürültüsü olsa bile iyi sınıflandırma tahminleri yapabilir. Öğrenme şekli karar ağacıdır. Boost algoritmaları genellikle çok sık ağaçlar kullanır. Bu yapı nispeten az zaman veya hafıza kullanır (Schapire ve Singer, 1999).

2.3.7. Derin Öğrenme

Sağlık hizmetlerinde geçen yıllarda bilgisayar kullanımının artması ve yapılan testlerin bilgisayar ortamında saklanmasıyla çok miktarda tıbbi veri birikmiştir. Bu veriler oldukça geniş içeriklidir ve çok sayıda kişiyi kapsamaktadır. Bu sayede derin öğrenme için ihtiyaç olan büyük miktarda veri daha rahat bir şekilde elde edilebilmektedir. Çok sayıda biyomedikal veri biriktikçe, büyük verileri analiz etmek için çeşitli makine algoritmaları kullanımı artık yaygın olarak kullanılmaktadır. Derin öğrenmenin diğer ihtiyacı olan yüksek işlemci gücüne CPU ve GPU birlikte kullanımı veya Google ve Amazon'un sağladığı gibi bulut hizmetleri ile ulaşabilmektedir.

2.3.7.1. Derin Öğrenmenin Biyoinformatik Araştırmalarda Kullanımı

Sağlık hizmetlerinde geçen yıllarda bilgisayar kullanımının artması ve yapılan testlerin bilgisayar ortamında saklanmasıyla çok miktarda tıbbi veri birikmiştir. Bu veriler oldukça geniş içeriklidir ve çok sayıda kişiyi kapsamaktadır. Bu sayede derin öğrenme için ihtiyaç olan büyük miktarda veri daha rahat bir şekilde elde edilebilmektedir. Çok sayıda biyomedikal veri biriktikçe, büyük verileri analiz etmek için çeşitli makine algoritmaları kullanımı artık yaygın olarak kullanılmaktadır. Derin öğrenmenin diğer ihtiyacı olan yüksek işlemci gücüne CPU ve GPU birlikte kullanımı veya Google ve Amazon'un sağladığı gibi bulut hizmetleri ile ulaşabilmektedir.

Büyük verilerin elde edilmesinden, paralel ve dağıtılmış hesaplama gücünden ve gelişmiş eğitim algoritmalarından doğan derin öğrenme, birçok alanda önemli ilerlemeleri kolaylaştırdı (Min vd., 2017). Örneğin, IBM hastalara yönelik bilgileri analiz eden ve tedavi seçenekleri olan klinisyenlere yardımcı olan bir platform olan Onkoloji için Watson'u geliştirdi (Ferrucci vd., 2010). Ayrıca, Go oyununda AlphaGo ile büyük başarı elde eden Google DeepMind, son zamanlarda etkili sağlık teknolojileri geliştirmek için DeepMind Health'i başlattı (Silver vd., 2016).

Makine öğreniminin bir dalı olan derin öğrenme, son zamanlarda büyük verilere, paralel ve dağıtık hesaplama gücüne ve gelişmiş algoritmalara dayanarak ortaya çıkmıştır. Ayrıca, yapay zeka topluluğunun uzun yıllardır mücadele ettiği farklı alanlardaki büyük ilerlemelerden derin öğrenme sorumludur (LeCun vd., 2015). Leung ve diğerleri (2016),

biyoinformatik arařtırmalarında derin öğrenme uygulamalarını tartıřmıřlar, önceki ikisi ise genomik tıbbi uygulamalarla sınırlıdır ve sonucusu tıbbi görüntüleme ile ilgilidir. Derin öğrenmenin başarıları, önemli algoritmik ayrıntıların temeli üzerine kuruludur ve genellikle iki kısımda anlaşılabilir: derin öğrenme mimarilerinin inřası ve eğitimi (Min vd., 2017). Derin öğrenme mimarileri temel olarak çoklu doğrusal olmayan katmanların YSA'larıdır ve girdi veri özellikleri ve arařtırma hedeflerine göre çeřitli tipler önerilmiřtir. Derin öğrenme mimarilerini dört temel gruba ayrılabilir. Bunlar DSA'lar, KSA'lar, TSA, ortaya çıkan mimariler řeklinde. DSA'lardan bahsederken ÇKA, YOK, ve algılayıcılar, otomatik kodlayıcılar, kısıtlı Boltzmann makineleri kullanan DİA hakkında konuřuyoruz. KSA'lar özellikle görüntü tanımda başarılı olan ve konvolüsyon katmanları, doğrusal olmayan katmanlar ve havuz katmanlarından oluřan mimarilerdir. TSA'lar, giriř verilerinin sıralı bilgilerini, algılayıcılar, UKSBB (Hochreiter ve Schmidhuber, 1997), veya geçmeli tekrarlayan birimler (GTB) (Cho vd., 2014) gibi yapı blokları arasında döngüsel bağlantılar ile kullanmak üzere tasarlanmıřtır. Bunlara ek olarak, derin uzaysal-zamansal nöral aęlar (Lena vd., 2012), çok boyutlu tekrarlayan sinir aęları (ÇBTSA) (Graves ve Schmidhuber, 2009) ve KOK (Masci vd., 2011) gibi birçok başka ortaya çıkan derin öğrenme mimarileri geliřtirilmiřtir.

Derin öğrenme mimarilerinin eğitiminin amacı, her bir katmandaki aęrılık parametrelerinin optimizasyonu olup, daha basit öznitelikleri aşamalı olarak karmařık özniteliklere birleřtirir, böylece en uygun hiyerarřik iřaretler veriden öğrenilebilir. Optimizasyon sürecinin tek bir döngüsünde ilk olarak, bir eğitim veri seti verildiğinde, ileri geçiř, her katmanda çıktıyı sıralı olarak hesaplar ve fonksiyon sinyallerini aę boyunca ileriye doğru ilerletir (LeCun vd., 2015). Son çıktı katmanında, nesnel bir kayıp fonksiyonu, çıkarılan çıktılar ve verilen etiketler arasındaki hatayı ölçer. Eğitim hatasını en aza indirmek için, geriye doğru geçiř hata sinyallerini geri yaymak ve sinir aęındaki tüm aęrılıklar açısından gradyanları hesaplamak için zincir kuralını kullanır (Hecht-Nielsen, 1989). Son olarak, aęrılık parametreleri stokastik gradyanlı iniře dayanan optimizasyon algoritmaları kullanılarak güncellenmiřtir (Bottou, 1991). Toplu gradyan iniře, her bir tam veri kümesi için parametre güncellemeleri gerçekleřtirirken, SGD, her bir küçük veri örneęi kümesi için güncellemeleri gerçekleřtirerek stokastik yaklařımlar saęlar. Derin öğrenme mimarilerinin eğitiminde bir dięer temel öęe, aşırı uyumu önlemek ve böylece iyi bir genelleme performansı elde etmek için amaçlanan stratejilere atıfta bulunan bir düzenlemedir. Örneęin, bilinen bir geleneksel yaklařım olan aęrılık kaybı, hedef parametrelere bir ceza terimi

ekleyerek ağırlık parametrelerinin daha küçük mutlak değerlere yaklaştığını gösterir (Krogh ve Hertz, 1992). Günümüzde en yaygın kullanılan regülasyon yaklaşımı dropout'dur (Srivastava vd., 2014). Dropout, eğitim sırasında gizli birimleri sinir ağlarından rasgele kaldırır ve olası alt ağlar topluluğu olarak düşünülebilir (Baldi ve Sadowski, 2013). Dropout yeteneklerini geliştirmek için yeni bir aktivasyon fonksiyonu, maxout (Goodfellow vd., 2013) ve TSA'lar için rnnDrop (Moon vd., 2015) olarak adlandırılan bir dropout varyantı önerilebilir. Ayrıca, yakın zamanda önerilen toplu normalizasyon (Ioffe ve Szegedy, 2015), bir mini grup içindeki her aktivasyon için skaler özniteliklerin normalleştirilmesi yoluyla ve her bir ortalama ve varyansı parametre olarak öğrenerek yeni bir düzenleme yöntemi sağlar.

Derin öğrenme algoritmalarını gerçek anlamda uygulamak için, algoritmik ayrıntılara büyük önem verilmelidir. Neyse ki, birçok açık kaynaklı derin öğrenme kütüphanesi çevrimiçi olarak mevcuttur ve her kütüphanenin kendine özgü güçlü yanları vardır.

DSA'ların temel yapısı bir giriş katmanı, çoklu gizli katmanlar ve bir çıkış katmanından oluşur. DSA'lara giriş verisi verildikten sonra çıkış değerleri, ağırlık katmanları boyunca sıralı olarak hesaplanır. Her tabakada, aşağıdaki katmanda her bir birimin çıktı değerlerini içeren girdi vektörü, ağırlıklı toplamın üretilmesi için mevcut katmandaki her birimin ağırlık vektörü ile çarpılmaktadır. Daha sonra, sigmoid, hiperbolik teğet veya rektifiye edilmiş doğrusal birim (ReLU) (Nair ve Hinton, 2010) gibi doğrusal olmayan bir fonksiyon, katmanın çıktı değerlerini hesaplamak için ağırlıklı toplama uygulanır. Her katmandaki hesaplama, aşağıdaki katmandaki işaretleri biraz daha soyut işaretlere dönüştürür (LeCun vd., 2015). DSA'larda kullanılan katmanların türlerine ve ilgili öğrenme yöntemine dayanarak, DSA'lar ÇKA, YOK veya DİA olarak sınıflandırılabilir. ÇKA, normal sinir ağlarına benzer bir yapıya sahiptir, ancak daha fazla katman içerir. Sadece etiketlenmiş verileri kullanan tamamen denetimli bir şekilde eğitilmiştir. Eğitim yöntemi, yüksek boyutlu parametre uzayında bir optimizasyon süreci olduğundan, çok sayıda etiketli veri mevcut olduğunda ÇKA genellikle kullanılır (LeCun ve Ranzato, 2013). YOK ve DİA, AE'leri ve RBM'leri sırasıyla mimarilerin yapı taşları olarak kullanır. Bunlar ve ÇKA arasındaki temel fark, denetimsiz eğitim öncesi ve denetimli ince ayar olmak üzere eğitimin iki aşamada yürütülmesidir. Öncelikle, denetlenmemiş ön eğitimde, katmanlar sıralı olarak kümelenir ve etiketlenmemiş veriler kullanılarak bir AE veya RBM olarak katmanlı bir şekilde eğitilir. Daha sonra, denetimli ince ayarda, bir çıktı sınıflandırıcı katmanı yığılır ve etiketli verilerle yeniden test edilerek tüm sinir ağı optimize edilir. Hem YOK hem de DİA etiketlenmemiş

verilerden yararlandığından ve aşırı eşleştirmeden kaçınmaya yardımcı olabileceğinden, araştırmacılar gerçek dünyada olduğu gibi etiketli veriler yetersiz olsa bile, oldukça düzenli sonuçlar elde edebilirler (Erhan vd., 2010). DSA'lar, yüksek boyutlu verileri analiz etmede uygundur. Biyoenformatik verilerinin tipik olarak karmaşık ve yüksek boyutlu olduğu göz önüne alındığında, DSA'ların biyoinformatik araştırmaları için kullanımda büyük umutlar söz konusudur. Verilerin doğasını daha iyi anlamak için hiyerarşik temsil öğrenme yöntemleri olarak DSA'lar, daha önce bilinmeyen son derece soyut desenler ve korelasyonları keşfetme yeteneğine sahiptirler. DSA'ların temel özelliği, hiyerarşik özniteliklerin yalnızca veriden öğrenilmesidir, insan tarafından tasarlanan öznitelikler çoğunlukla ham veri formları yerine girdi olarak verilmiştir.

KSA'lar çoklu veri tiplerini, özellikle iki boyutlu görüntüleri işlemek üzere tasarlanmıştır ve doğrudan beynin görsel korteksinden esinlenmiştir. Görsel kortekste, iki temel hücre tipinin hiyerarşisi vardır: basit hücreler ve kompleks hücreler (Hubel ve Wiesel, 1968). Basit hücreler görsel uyarıların alt bölgelerindeki ilkel modellere tepki gösterir ve karmaşık hücreler bilgiyi daha karmaşık formları tanımlamak için basit hücrelerden sentezler. Görsel korteks böylesine güçlü ve doğal bir görsel işleme sistemi olduğundan, KSA'lar üç temel fikri taklit etmek için uygulanır: yerel bağlantı, lokasyona değişmezlik ve yerel geçişe karşı değişme (LeCun vd., 2015). KSA'ların temel yapısı, konvolüsyon katmanları, doğrusal olmayan tabakalar ve havuz katmanlarından oluşur. Verilerin yüksek korelasyonlu alt bölgelerini kullanmak için, yerel yamalar ve filtreler denilen ağırlık vektörleri arasındaki konvolüsyonu hesaplayarak her bir konvolüsyon katmanında, öznitelik haritaları olarak adlandırılan yerel ağırlıklı toplamlar elde edilir. Ayrıca, verilerdeki konumdan bağımsız olarak aynı kalıplar görülebildiği için, tüm veri kümesi boyunca filtreler sürekli olarak uygulanır, bu da öğrenilecek parametrelerin sayısını azaltarak eğitim verimliliğini artırır. Daha sonra doğrusal olmayan katmanlar, öznitelik haritalarının doğrusal olmayan özelliklerini artırır. Her bir havuz katmanında, öznitelik haritalarında örtüşmeyen bölgelerin maksimum veya ortalama alt örnekleme gerçekleştirilir. Bu örtüşmeyen alt örnekleme, KSA'ların biraz farklı fakat semantik olarak benzer öznitelikleri ele almasını ve böylece daha karmaşık öznitelikleri tanımlamak için yerel öznitelikleri bir araya getirmesini sağlar.

Hâlihazırda, KSA'lar mekânsal bilgileri analiz etmek için olağanüstü kapasiteleri sayesinde en başarılı derin öğrenme mimarilerden biridir. Normal ve biyomedikal görüntüleme arasındaki farklı veri özelliklerine rağmen, KSA yine de diğer alanlara kıyasla

kolay uygulamalar sağlar. Aslında, KSA'lar biyomedikal sinyal işlemede büyük potansiyele sahiptir. KSA'ların üç anahtar fikri, genomik dizi motifleri gibi küçük varyanslı anlamlı yinelenen kalıpları keşfetmek için sadece tek boyutlu bir ızgarada değil, aynı zamanda biyomedikal sinyallerde zaman frekans matrisleri ve omik verilerdeki etkileşimler gibi iki boyutlu ızgaralarda da uygulanabilir. Bu nedenle, biyoenformatik uygulamalarındaki KSA'ların popülerliği önümüzdeki yıllarda da devam edecektir.

Sıralı bilgileri kullanmak için tasarlanan TSA'lar, döngüsel bağlantı ile temel bir yapıya sahiptir. Giriş verileri sırayla işlendiğinden, tekrarlı hesaplama döngüsel bağlantının mevcut olduğu gizli birimlerde gerçekleştirilir. Bu nedenle, durum vektörleri olarak adlandırılan gizli birimlerde açıkça saklanan geçmiş bilgiler ve mevcut giriş için çıkış, bu durum vektörlerini kullanan önceki tüm girişler dikkate alınarak hesaplanır (LeCun vd., 2015). Hem geçmiş hem de gelecekteki girişlerin mevcut giriş için çıkışı etkilediği birçok durum olduğu için, çift yönlü tekrarlayan sinir ağları (bidirectional recurrent neural networks, BRNNs) yaygın olarak tasarlanmış ve kullanılmıştır. Her ne kadar TSA'lar katman sayısı bakımından DSA veya KSA'lar kadar derin gözükme de, zaman içinde açıldıklarında daha derin bir yapı olarak kabul edilebilirler. Bu nedenle, uzun bir süredir, araştırmacılar TSA'ları eğitirken ve gradyanlar arasında uzun vadeli bağımlılığı öğrenirken, ufukta görülen gradyan sorunlarına karşı mücadele etmekte zorlandılar (Bengio vd., 1994). Neyse ki, basit perceptron gizli birimlerinin, bellek hücreleri olarak işlev gören UKSBB veya GTB gibi daha karmaşık birimlerle değiştirilmesi, sorunun önlenmesine yardımcı olur. Daha yakın zamanlarda, TSA'lar doğal dil işleme (Li vd., 2015) ve dil çevirisi (Luong vd., 2015) dâhil olmak üzere birçok alanda başarıyla kullanılmıştır. TSA'lar DSA ve KSA'dan daha az araştırılmış olsa bile, sıralı bilgi için hala çok güçlü analiz yöntemleri sağlarlar. Biyomedikal sinyaller tipik olarak sıralı olduğundan, değişken uzunluklu bir giriş dizisini başka bir diziye veya sabit boyutlu tahminlere eşleştirmede TSA'ların kabiliyetleri biyoinformatik araştırmaları için ümit vericidir. Biyomedikal görüntüleme ile ilgili olarak, TSA'lar şu anda pek çok araştırmacının ilk tercihi değildir. Bununla birlikte, dinamik bilgisayarlı tomografi ve manyetik rezonans görüntülemenin yayılması TSA ve KSA'ların birleşmesine yol açacak ve uzun vadede önemlerini yükseltecektir (Erhan vd., 2010). Acil durum mimarileri, DSA'lar, KSA'lar ve TSA'ların yanı sıra derin öğrenme mimarilerini ifade eder. Bunlara örnek olarak, üç yeni mimariyi yani Derin Uzaysal Geçici Sinir Ağlar (DUGSA), ÇBTSA'lar ve KOK'lar ve bunların biyoinformatik deki uygulamalarından bahsediyoruz. DUGSA'lar, aşamalı arındırma yoluyla çok boyutlu çıktı hedeflerini

öğrenmek için tasarlanmıştır. DUGSA'ların temel yapısı çok boyutlu gizli katmanlardan oluşur. Yapının anahtar yönü, ilerleyici arındırma, yerel korelasyonları dikkate alır ve her bir katmanda girdi özelliği bileşimleri (uzaysal öznitelikler ve geçici öznitelikler) ile gerçekleştirilir. Uzaysal öznitelikler, tüm DUGSA için orijinal girdilere karşılık gelir ve her katmanda aynı şekilde kullanılır. Bununla birlikte, geçici öznitelikler, üst katmanlara ilerlemek için kademeli olarak değiştirilir. İlk katman haricinde, her bir gizli birimi mevcut tabakada hesaplamak için, sadece aşağıdaki tabakadaki aynı koordinatın bitişik gizli birimleri kullanılır, böylece yerel korelasyonlar kademeli olarak yansıtılır.

ÇBTSA'lar, sıralı olmayan çok boyutlu verileri sıralı veri grupları olarak ele alarak, TSA'ların yeteneklerini sıralı olmayan çok boyutlu verilere uygulamak için tasarlanmıştır. Örneğin, iki boyutlu veriler yatay ve dikey dizi verileri olarak kabul edilir. Tek boyutlu verilerde her iki yönde de bağlamları kullanan BRNN'lere benzer şekilde, ÇBTSA'lar çok boyutlu verilerde tüm olası yönlerde bağlamları kullanır. İki boyutlu bir veri kümesinin örneğinde, veri işlem sırasına göre değişen dört bağlam gizli katmandaki her konum için dört gizli birimin hesaplanmasında yansıtılır. Gizli birimler tek bir çıkış katmanına bağlanır ve nihai sonuçlar tüm olası bağlamlar göz önüne alınarak hesaplanır.

KOK'lar (Hadsell vd., 2009), hem AE'nin hem de KSA'ların avantajlarını kullanmak için tasarlanmıştır, böylece uzaysal bilgileri yansıtan verilerin iyi hiyerarşik temsillerini öğrenebilir ve denetimsiz eğitim tarafından iyi bir şekilde düzenlenebilir. AE'lerin eğitiminde, yeniden yapılandırma hatası, enkoder ve kod çözücü kullanılarak, girdi vektörlerinden öznitelik vektörlerini ayıklayan ve öznitelik vektörlerinden gelen verileri yeniden oluşturacak şekilde en aza indirilir. KSA'larda, konvolüsyon ve havuzlama katmanları bir kodlayıcı türü olarak kabul edilebilir. Bu nedenle, dekonvolüsyon ve çözülmeyen katmanlardan oluşan KSA kodlayıcı ve kod çözücü, bir KOK oluşturmak için entegre edilmiştir ve AE'de olduğu gibi eğitilmiştir.

Derin öğrenme hızla büyüyen bir araştırma alanıdır ve çok sayıda yeni derin öğrenme mimarisi önerilmekte, ancak biyoinformatikte geniş uygulamaları bulunmaktadır. Yeni önerilen mimariler mevcut mimarilerden farklı avantajlara sahiptir, bu yüzden çeşitli araştırma alanlarında umut verici sonuçlar üretmeleri beklenmektedir. Örneğin, DUGSA'ların progresif artırılması proteinlerin dinamik katlanma sürecine uyar ve protein yapı tahminde etkin bir şekilde kullanılabilir (Lena vd., 2012). ÇBTSA'ların yetenekleri, biyomedikal görüntülerin segmentasyonu için uygundur; çünkü segmentasyon, yerel ve küresel bağlamların yorumlanmasını gerektirir.

Derin öğrenmeye karşı bir ana eleştiri, kara kutu olarak kullanılmasıdır: olağanüstü sonuçlar üretmesine rağmen, bu sonuçların içsel olarak nasıl elde edildiğine dair çok az şey biliyoruz. Biyoenformatikte, özellikle biyomedikal alanlarda, sadece iyi sonuçlar üretmek için yeterli değildir. Birçok çalışma hastanın sağlığına bağlandığından, klinisyenlerin tıbbi tedaviler için yaptığı gibi, kara kutunun beyaz kutuya dönüştürülmesi ve mantıksal bir neden sağlamak hayati önem taşımaktadır. En çok kullanılan yaklaşımlardan biri eğitilmiş bir derin öğrenme modelinin görselleştirilmesi yoluyla yorumlanmasıdır. Görüntü girdisi açısından, KSA'ların belirli bir girişi için hiyerarşik temsilleri yeniden yapılandırmak ve görselleştirmek için bir uzlaşma ağı önerilmiştir (Zeiler ve Fergus, 2014). Ek olarak, belirli bir girdiye bağımlı olmaktan ziyade genelleştirilmiş bir sınıf temsilcisi görüntüsünü görselleştirmek için, girişte geriye doğru yayılma yoluyla girdi alanında degrade yükselme optimizasyonu (çapraz geri-dağıtma), başka bir etkili yöntem sağlamıştır (Erhan vd., 2009). Genomik dizi girdisi ile ilgili olarak, PSSM'leri eğitilmiş bir modelden çıkarmak ve karşılık gelen motifleri ısı haritaları veya dizi logoları ile görselleştirmek için çeşitli yaklaşımlar önerilmiştir. Örneğin, Lee ve Yoon (2015) DİA'nın ilk tabakasındakiler arasında en iyi sınıf ayırıcı ağırlık vektörünü seçerek motifleri çıkarmışlardır. Özellikle transkripsiyon faktörü bağlanma alanı tahmini için, Alipanahi ve diğerleri (2015), genetik varyantların KSA'lar tarafından tahmin edilen bağlanma skorları üzerindeki etkilerini göstermek için bir görselleştirme yöntemi olan bir mutasyon haritası geliştirdiler. Bir mutasyon haritası, her mutasyonun bağlanma skorunu ne kadar değiştirdiğini gösteren bir ısı haritası ve her bir tabanın yüksekliğinin tüm olası mutasyonlar arasında bağlanma puanının maksimum azalması olarak ölçeklendiği giriş dizisi logosundan oluşur. Dahası, Kelley ve diğerleri (2016), maksimum artışların yanı sıra tahmin puanlarının maksimum düşüşlerini göstermek için mutasyon haritasını bir çizgi grafiği ile tamamlamıştır. Görselleştirme yoluyla yoruma ek olarak, belirgin noktalara ve derin öğrenmenin ardındaki matematiksel mantığa açıkça odaklanmak için tasarlanan dikkat mekanizmaları üzerinde çalışılmaktadır.

Uygun derin öğrenme mimarisini seçmek, derin öğrenmenin doğru kullanılması açısından önemlidir. Sağlam ve güvenilir sonuçların elde edilmesi için, her bir derin öğrenme mimarisinin yeteneklerinin farkında olması ve girdi veri özelliklerine ve araştırma hedeflerine ek olarak yeteneklere göre seçim yapılması önemlidir. Ancak, bugüne kadar, her mimarinin avantajları sadece kabaca anlaşılmaktadır. Örneğin, DSA'lar yüksek boyutlu verilerdeki iç korelasyonların analizi için uygundur, KSA'lar mekansal bilginin analizi için uygundur ve TSA'lar ardışık bilgilerin analizi için uygundur (Goodfellow vd., 2016).

Gerçekten de, en uygun veya “en uygun” derin öğrenme mimarisini seçmek için ayrıntılı bir metodoloji, gelecekte üzerinde çalışılması gereken bir zorluk olmaya devam etmektedir. Derin bir öğrenme mimarisi seçildiğinde bile, araştırmacıların belirleyeceği çok sayıda hiperparametre (katman sayısı, gizli birimler sayısı, ağırlık başlangıç değerleri, öğrenme yinelemeleri ve hatta öğrenme oranı) vardır ve bunların hepsi sonuçları etkileyebilir. Uzun yıllar boyunca hiperparametre ayarlaması sistematik olmak yerine insan makine öğrenimi uzmanlarına bırakılmış bir konuydu. Yine de, hiperparametreleri otomatik olarak optimize etmeyi amaçlayan makine öğrenimi araştırmalarının otomasyonu sürekli artmaktadır (Bergstra vd., 2011). Ardışık model tabanlı küresel optimizasyon (Hutter vd., 2011), Gaussian işlem öncelikleriyle Bayesyen optimizasyon (Snoek vd., 2012) ve rasgele arama yaklaşımları (Bergstra ve Bengio, 2012) dâhil olmak üzere birkaç algoritma önerilmiştir. Çoklu giriş kaynaklarından gelen bilgileri kullanan çok modlu derin öğrenme (Ngiam vd., 2011), derin öğrenim araştırmasının geleceği için umut verici bir yoldur. Bilhassa, biyoinformatiğin, çeşitli türdeki verilerin doğal olarak asimile edilebildiği bir alan olduğu için, büyük ölçüde fayda sağlaması beklenmektedir (Cao vd., 2014). Örneğin, yalnızca veri verileri, görüntüler, sinyaller, ilaç yanıtları ve giriş verileri olarak mevcut olan elektronik tıbbi kayıtlar değil, X-ışını, CT, MRI ve PET formları da tek bir görüntüden elde edilebilir. Birkaç biyoinformatik çalışması çok modlu derin öğrenmeyi kullanmaya başladı. Örneğin, Suk ve Shen (2013) MRG ve PET taraması formlarında beyin-omurilik sıvısı ve beyin görüntülerini kullanarak Alzheimer hastalığı sınıflandırmasını incelediler. Soleymani ve diğerleri (2014) hem EEG sinyali hem de yüz görüntü verileriyle bir duygu algılama çalışması gerçekleştirdi.

Daha derin öğrenme modeli parametreleri ve eğitim verilerinin kullanıma sunulmasıyla, daha iyi öğrenme performansları elde edilebilir. Bununla birlikte, aynı zamanda, bu, kaçınılmaz olarak, eğitimin hızlandırılmasının gerekliliğini vurgulayarak, eğitim süresinde büyük bir artışa yol açmaktadır (Svozil vd., 1997). Derin öğrenmeyi hızlandırmaya yönelik yaklaşımlar üç gruba ayrılabilir: gelişmiş optimizasyon algoritmaları, paralel ve dağıtılmış bilgi işlem ve özel donanım. Uzun eğitim sürelerinin ana nedeni, düz SGD ile parametre optimizasyonunun çok uzun sürmesi olduğundan, bazı çalışmalar ileri düzey optimizasyon algoritmalarına odaklanmıştır (Le vd., 2011). Bu amaçla, yaygın olarak kullanılan bazı algoritmalar arasında Adagrad, Adam, toplu normalizasyon ve Hessiyonsuz optimizasyon (Martens, 2010) yer almaktadır. Paralel ve dağıtılmış hesaplama, tamamlanma süresini önemli ölçüde hızlandırabilir ve birçok derin öğrenme çalışmasına olanak

sağlamıştır. Bu yaklaşımlar, bir grafik işlem birimi kullanan ölçeklendirme yöntemlerini ve dağınık bir ortamda büyük ölçekli kümeleri kullanan ölçeklendirme yöntemlerini kullanır. DeepSpark ve TensorFlow dâhil olmak üzere birkaç derin öğrenme çerçevesi, paralel ve dağıtılmış bilgi işlem yetenekleri sağlar. Derin öğrenme için özel donanımın geliştirilmesi hala emekleme aşamasında olmasına rağmen, uzun vadede önemli hızlanmalar sağlayacak ve çok daha önemli hale gelecektir. Şu anda, alan programlanabilir kapı dizisi tabanlı işlemciler geliştirme aşamasındadır ve beyinden modellenen nöromorfik çipler umut verici teknolojiler olarak umut vermektedir (Ovtcharov vd., 2015).

Geleneksel derin öğrenme mimarilerinin bir araya gelmesi gelecek vaat eden bir alandır. TSA'ların yapılarını güçlendirmeye yönelik birkaç çalışma da yapılmıştır. Son zamanlarda, performansı, insan tarafından algılanan küçük pertürbasyonlarla azaltan rakip örnekler, makine öğrenim topluluğundan daha fazla ilgi görmüştür (Szegedy vd., 2013). Öğrenme metodolojisi açısından, yarı denetimli öğrenme ve takviye öğrenme de dikkat çekmektedir. Yarı gözetimli öğrenme hem etiketsiz hem de etiketlenmiş verileri kullanır. Örneğin, merdiven ağları (Rasmus vd., 2015) ÇKA veya KSA'lara atlama bağlantıları ekler ve aynı zamanda modelin her seviyesindeki temsilleri göstermek için denetlenen ve denetlenmeyen maliyet işlevlerinin toplamını en aza indirir. Takviye öğrenimi, doğru etiketlenmiş verilerden ziyade eylemlerden kaynaklanan ödül sonucu sinyallerini güçlendirir. Takviye öğrenme, insanların gerçekte nasıl öğrenildiğine çok benzediğinden, bu yaklaşım yapay genel zekâ için büyük bir gelişmedir. Halen, uygulamaları ağırlıklı olarak oyun oynama ve robotik üzerine odaklanmıştır.

Büyük verilerin çağına girerken, derin öğrenme uluslararası akademik ve ticari açıdan önem kazanmaktadır. Geleneksel makine öğrenimi ile büyük ilerlemelerin yapıldığı biyoinformatik'de, derin öğrenmenin umut verici sonuçlar elde etmesi kaçınılmazdır. Derin öğrenme söz vermesine rağmen, bir gümüş mermi değildir ve ad hoc biyoinformatik uygulamalarında mükemmel sonuçlar sağlayamaz. Derin öğrenmenin yeteneklerini tam olarak kullanmak için, çok modlu ve derin öğrenmenin hızlandırılması daha fazla çalışma gerektirir.

2.3.7.2. Konvolüsyonel Sinir Ağı

KSA şu anda derin öğrenme için önde gelen algoritmalarından biridir. Pratik uygulamalarda muazzam derecede başarılı oldukları kanıtlanmıştır. Adından da anlaşılacağı

gibi, genel matris çarpımı yerine, katmanlarının en az birinde, konvolüsyon kullanılır (Goodfellow vd., 2016). KSA'nın tasarımı, gözle alınan görsel bilginin, beyinde hiyerarşik şekilde organize edildiği nöronlar tarafından işlendiği görsel korteksin yapısından esinlenmiştir. Görsel uyarılar bir nöronun alıcı alanına ulaştığında, nöronal durumuna bağlı olarak aktive edilebilir. Daha öndeki görsel bölgelerdeki nöronlar daha basit ayarlara ve daha küçük boyutlu alıcı alanlara sahiptir. Bu nedenle, en ilkel görsel formların köşeleri veya kenarları, birincil görsel korteks alanlarında tanınmaktadır yani diğer bir deyişle en düşük seviyede, temel öznitelik detektörleri (yönlendirilmiş kenarlar) vardır. Daha sonra bunlar, daha karmaşık görsel özniteliklerin izlediği satırların birleştirilmesiyle birleştirilir. Bireysel yüzler bir sonraki seviyede tanınırlar. Birden fazla yüz birimi, benzer insanların nasıl görüldüğüne göre kademeli olarak aktiftir. Son olarak, en üst düzeyde, bir kişinin alabileceği eylemler için iyi bir temel teşkil eden önemli işlevsel, anlamsal kategoriler vardır ve bu tür yüksek düzeyli kategorileri geliştirebilmek, akıllı davranış geliştirebilmek için çok önemlidir (O'Reilly vd., 2012). KSA kullanarak algılama, şekil değişikliği gibi bozulmalara karşı dayanıklıdır. Bununla birlikte, aynı ağırlık yapılandırması uzayda kullanıldığından KSA'lar değişmezdir. Bu durumda eğitimin sonucu, girdinin farklı yerlerinde aynı ağırlık desenleri olan çoklu birimlerdir. Bu ağırlık konfigürasyonlarını öğrenmek için, muhtemel varyasyonların alanını kapsayacak şekilde çok sayıda eğitim örneği gerekecektir. Öznitelikleri ayıklamak için tamamen bağlı bir katman kullandığımız bu aynı varsayımsal durumda, 32x32 boyutundaki giriş görüntüsü ve 1000 özelliğe sahip gizli bir katman, 106 katsayı derecesinde, büyük bir bellek gereksinimi gerektirir. Konvolüsyon katmanında, aynı katsayılar boşluktaki farklı konumlarda kullanılır, bu nedenle bellek gereksinimi büyük ölçüde azalır. Yine bir KSA'ına eşdeğer olan standart sinir ağını kullanarak, parametrelerin sayısı çok daha yüksek olacağından, eğitim süresi de orantılı olarak artacaktır. Bir KSA'da, parametre sayısı önemli ölçüde azaldığından eğitim süresi orantılı olarak azalır. Ayrıca, mükemmel eğitimi varsayarak, performansı bir KSA ile aynı olacak bir standart sinir ağı tasarlayabiliriz. Pratik eğitimde, KSA'ına eşdeğer bir standart sinir ağı daha fazla parametreye sahip olacaktı, bu da eğitim süreci boyunca daha fazla gürültü eklenmesini sağlayacaktı. Bu nedenle, bir KSA'ına eşdeğer bir standart sinir ağının performansı her zaman daha zayıf olacaktır.


KSA'ları normal sinir ağlarına çok benzerler, ancak nöronlarını üç boyutta (genişlik, yükseklik ve derinlik) düzenler. Bir katmanın içindeki bir nöron, sadece alıcı alan adı verilen ve tam olarak bağlanmayan katmanın küçük bir bölgesine bağlanır. KSA'lar giriş ve çıkış

katmanları ile giriş ve çıkış arasındaki pek çok gizli katmandan oluşur. Bu katmanların bazıları tekrarlanır.

2.3.7.2.1. Konvolüsyon Tabakası

Adından da anlaşılacağı gibi, bu bir KSA'nın temel yapı taşıdır. Sadece doğrusal ve aktivasyon katmanlarından oluşan Sinir Ağları, özellikle görüntülere iyi ölçeklenemez. Konvolüsyon katmanları, girdilerinin (örneğin, görüntüler veya öznitelik haritaları) birçok mekânsal ilişki sunmasından yararlanır. Aslında, komşu pikseller görüntü içindeki konumlarından etkilenmemelidir. Bir dizi filtre içerir ve bu filtreler görüntünün konvolüsyon işlemine tutulduğu, her biri aynı derinliğe sahip görüntüyle aynı sayıda boyutlara sahiptir. Çıkış genişliği ve yüksekliği, filtrenin boyutuna, adımın (filtrenin her hesaplama arasında taşındığı piksel sayısı) ve görüntünün etrafındaki sıfır doldurma miktarına bağlıdır. Çıkış derinliği uygulanan filtrelerin sayısı ile aynı olacaktır. Konvolüsyon süreci, bir makine öğrenim sisteminin geliştirilmesine yardımcı olabilecek üç fikri, yani seyrek etkileşimleri, parametre paylaşımını ve eşdeğer gösterimi destekler (Goodfellow vd., 2016). Ayrıca, bir dereceye kadar, kaydırma, ölçeklendirme ve çarpıtmaya karşı değişmez yapar. Giriş ve bir filtrenin konvolüsyonun çıkışı, bir öznitelik haritası veya bazen bir aktivasyon haritası olarak adlandırılır. Katmandaki her filtre tarafından oluşturulan bir öznitelik haritası olur ve ve birlikte çıkış derinliğini oluştururlar. Her bir öznitelik haritasının boyutu, giriş görüntüsü boyutuna, dolguya, filtre boyutuna ve adıma bağlıdır. Filtrenin girişten daha küçük olması, seyrek etkileşimlere yol açar. Öznitelik haritasındaki her birim, alıcı alan adı verilen girişteki $n \times n$ alanına n^2 bağlantılarına sahiptir. Görüntü işleme ile bu, kenarlar gibi küçük ve anlamlı özniteliklerin tespit edilebildiği ve daha az parametrenin depolanması gerektiği anlamına gelir. Öznitelik haritasındaki her ünite n^2 eğitilebilir ağırlığa ve eğitilebilir bir sapmaya sahiptir. Bir öznitelik haritasındaki tüm birimler aynı parametreleri paylaşır, bir öznitelik haritasının, adından da anlaşılacağı gibi, yatay veya dikey kenarlar gibi farklı öznitelikleri algıladığı şeklinde yorumlanabilir. Bu, girişte kenarların nerelerde bulunduğunu bağımsız olarak tespit eder. Bunun yerine, önemli olan göreceli konumlandırmalarıdır. Bu parametre paylaşımı önemli miktarda bellek tasarrufu sağlar (LeCun vd., 1998). Ancak, farklı öznitelikler tespit edildiğinden, ayrı öznitelik haritaları parametreleri paylaşmayacaktır. Ayrıca, konvolüsyon durumunda bu parametre paylaşım yapısı, fonksiyonu

eşdeğerleştirmeli çeviriye dönüştürür, yani giriş değişirse, çıkış aynı şekilde değişecektir (Goodfellow vd., 2016). Örnek bir konvolüsyon tabakası Şekil 2.2’de verilmiştir.



Şekil 2.2. Örnek bir konvolüsyon tabakası (URL-4, 2018).

Konvolüsyon işlemi aşağıdaki Denklem 2.30 ile hesaplanır.

$$x_n = \sum_{k=1}^{N-1} y_k f_{n-k} \quad (2.30)$$

Burada y sinyali, f filtreyi, N y 'nin öğelerinin sayısı ve x çıkış vektörünü temsil eder. KSA modeli geri yayılım tekniği ile eğitilir. İleri yayılma sırasında, bir sonraki katman nöronunun giriş haritası, Denklem 2.31’deki gibi ayrı ayrı bölgesel konvolüsyon ile önceki katman nöronlarının çıktı haritalarının birleştirilmesiyle elde edilecektir (Kiranyaz vd., 2016).

$$x_k^l = b_k^l + \sum_{i=1}^{N_{l-1}} conv2D(w_{ik}^{l-1}, s_i^{l-1}) \quad (2.31)$$

Bu denklemde $conv2D$ sınırlarda sıfır doldurma olmadan düzenli bir iki boyutlu konvolüsyondur, x_k^l giriştir, b_k^l tabaka l 'deki k th nöronun sapmasıdır, s_i^{l-1} $l-1$ katmanındaki i th nöronunun çıktısıdır, w_{ik}^{l-1} tabaka $l-1$ 'deki i 'inci nöronun, l tabakasında k 'inci nörona ağırlığıdır. Gizli KSA katmanlarının sayısı herhangi bir sayıya ayarlanabilir. Çıkış KSA katmanının alt örnekleme faktörü otomatik olarak giriş haritasının boyutlarına

ayarlandığından, bu uygulamada mümkündür. Geri yayılım eğitimini gerçekleştirmek için, her nöron için delta hatası Δ_k^l , alt örneklenmiş delta hatası Δ_{sk}^l , ve son olarak, ara çıkışının türevi $f'(x_k^l)$, şeklinde belirlenecek üç kavram daha vardır. Geri yayılım çalışması, çıkış çok katmanlı algılayıcıların katmanından iç katmanlara doğru ilerler. Katmanın l-1'deki çıkışlarının tabaka l'deki k'inci nöronunun çıkışına doğru ileriye doğru ilerlemesi, Denklem 2.32'deki gibi ifade edilebilir (Kiranyaz vd., 2016).

$$x_k^l = b_k^l + \sum_{i=1}^{N_{l-1}} w_{ik}^{l-1} y_i^{l-1} \text{ ve } y_k^l = f(x_k^l) \quad (2.32)$$

Sırasıyla giriş ve çıkış katmanları $l = 1$ ve $l = L$ olsun. Bir giriş vektörü p ve bunun karşılık gelen çıktı vektörü $[y_1^L, \dots, y_{N_L}^L]$ için $[t_1, \dots, t_{N_L}]$ hedef sınıf vektörü olsun. Çıkış katmanındaki ortalama karesel hata Denklem 2.33'deki gibi ifade edilebilir.

$$E = E(y_1^L, \dots, y_{N_L}^L) = \sum_{i=1}^{N_L} (y_i^L - t_i)^2 \quad (2.33)$$

Nöron k'ye bağlı bireysel ağırlıklara (w_{ik}^{l-1}) ve nöron k'nın sapmasına (b_k^l) göre hatanın türevini bulmak böylece hatayı en aza indirmek için gradyan iniş metodunu uygulayabiliriz. Bu süreç Denklem 2.34-35'de verilmiştir.

$$\frac{\partial E}{\partial w_{ik}^{l-1}} = \frac{\partial E}{\partial x_k^l} \frac{\partial x_k^l}{\partial w_{ik}^{l-1}} = \frac{\partial E}{\partial x_k^l} y_i^{l-1} \quad (2.34)$$

$$\frac{\partial E}{\partial b_k^l} = \frac{\partial E}{\partial x_k^l} \frac{\partial x_k^l}{\partial b_k^l} = \frac{\partial E}{\partial x_k^l} \quad (2.35)$$

Her iki türev de hataya karşı girdilerin doğruluğuna bağlıdır. Bu duyarlılıklar genellikle delta hataları olarak adlandırılır. Katman l'de k'inci nöron için çıkışından bir adım geri yayılım ile Denklem 2.36'da verilen delta hatasını yazabiliriz.

$$\Delta_k^l = \frac{\partial E}{\partial x_k^l} = \frac{\partial E}{\partial y_k^l} \frac{\partial y_k^l}{\partial x_k^l} = \frac{\partial E}{\partial y_k^l} f'(x_k^l) \quad (2.36)$$

Bu, hatanın sonuca olan duyarlılıklarını bulduğumuz an, delta hatasını bulabileceğimiz anlamına gelir. Çıkış katmanı $l = L$ için her iki terimi biliyoruz ve Denklem 2.37'yi oluştururuz.


$$\Delta_k^L = \frac{\partial E}{\partial x_k^L} = f'(x_k^L)(y_k^L - t_k) \quad (2.37)$$

Çıkışın hata hassasiyetini Denklem 2.38'deki gibi yazabiliriz.

$$\frac{\partial E}{\partial y_k^l} = \sum_{i=1}^{N_{l+1}} \frac{\partial E}{\partial x_i^{l+1}} \frac{\partial x_i^{l+1}}{\partial y_k^l} = \sum_{i=1}^{N_{l+1}} \Delta_i^{l+1} w_{ki}^l \quad (2.38)$$

2.3.7.2.2. Rektifiye Edilmiş Doğrusal Birim

Rektifiye Edilmiş Doğrusal Birim (ReLU) aktivasyon fonksiyonu $f(x) = \max(0, x)$ uygulayarak doğrusal olmayan özelliğini artırır. Bu aşamada negatif giriş değerlerini sıfır olarak düzeltilir. Ağın doyuma ulaşan fonksiyonlar kullanılarak $f(x) = \tanh(x)$ gibi doyuma ulaşmayan fonksiyonlara göre birkaç kez daha hızlı çalışabileceği görülmüştür ve sistemin bu tabakanın kullanımıyla daha hızlı öğrenmektedir. Uzamsal boyut değiştirilmeden bırakılır. Denklem 2.39'da görüldüğü gibi negatif sayılar için küçük, sıfır olmayan bir eğim, α 'da kullanılabilir. ReLU katmanının nasıl çalıştığı örneği Şekil 2.3'de verilmiştir. Doğrultucu fonksiyonu uygulandıktan sonra sol kutudaki tüm negatif değerli sayılar sıfıra ayarlanmış, diğer tüm değerler değişmeden tutulmuştur.

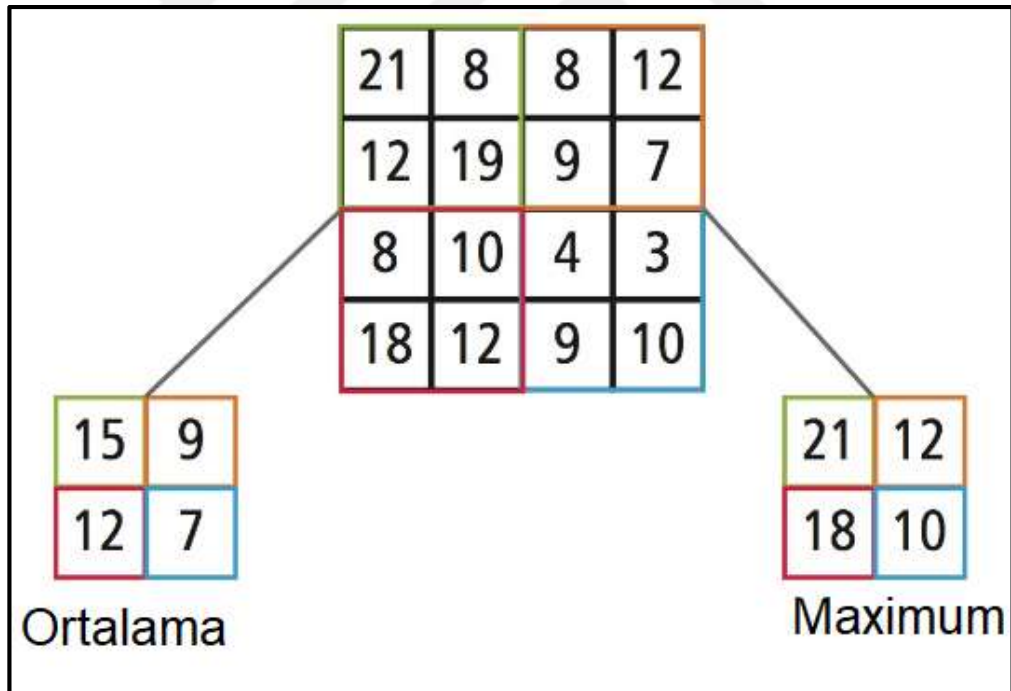


Şekil 2.3. ReLU katmanının nasıl çalıştığını gösteren bir örnek (URL-3, 2018).

$$f(x) = \begin{cases} x, & x > 0 \\ ax, & \text{diğer durumlarda} \end{cases} \quad (2.39)$$

2.3.7.2.3. Havuzlama Katmanı

Havuzlama katmanında önceki katmanın çıkışının dikdörtgen alanlarındaki maksimum veya ortalama değerleri örneklemek için küçük filtreler kullanarak hacmin doğrusal olmayan örnekleme yapılır. Havuzlama, parametrelerin ve hesaplamaların miktarını azaltmak için boyutu azaltır ve ek olarak aşırı eşleştirmeyi önler. Havuzlama katmanının nasıl çalıştığı örneği Şekil 2.4'de verilmiştir. Bu örnekte girişin boyutu 4x4'tür. 2x2 alt örnekleme için, bir 4x4 görüntü, 2x2 boyutunda örtüşmeyen dört matrise bölünür. Maksimum havuzlama durumunda, 2x2 matrisindeki dört değer için maksimum değeri çıktısıdır. Ortalama havuzlama durumunda, dört değer için ortalaması çıktısıdır. İndeks (2,2) çıkışı için, ortalama alma sonucunun, en yakın tamsayıya yuvarlanmış hali olmaktadır (URL-3, 2018).



Şekil 2.4. Havuzlama katmanının nasıl çalıştığını gösteren bir örnek (URL-3, 2018)

2.3.7.2.4. Tamamen Bağlanmış Katman

Tamamen bağlanmış katmandaki nöronlar, normal sinir ağlarında olduğu gibi, önceki katmanlardaki tüm aktivasyonlara tamamen bağlıdır. Bu katmanlar, belirli bir hedef çıktı sonucunu belirlemek için "bileşenlerin" kesin karışımını gösteren, önceki öznitelik katmanının ağırlığını matematiksel olarak toplamlar. Tamamen bağlı bir katman durumunda, önceki katmanın tüm özniteliklerinin tüm elemanları, her bir çıktı özelliğinin her bir elemanının hesaplanmasında kullanılır. Tamamen bağlı bir tabakanın işlenmesi süreci Şekil 2.5'de verilmiştir (URL-3, 2018). Şekilde tamamen bağlı olan L tabakasını açıklanmaktadır. Katman L-1, her biri 2x2 olan, yani dört elemanı olan iki özelliğe sahiptir. Katman L'nin her birinin tek bir elemanı olan iki özelliği vardır.

2.3.7.2.5. Dropout Katmanı

Ağın gizli katmanlarının indeksi $l \in \{1, \dots, L-1\}$ 'dir. Katman l'ye giriş vektörleri $z^{(l)}$, katman l'den çıkış vektörleri $y^{(l)}$, katman l'deki ağırlıklar $W^{(l)}$, katman l'deki sapmalar $b^{(l)}$ ile gösterilirse ve f bir aktivasyon fonksiyonu ise standart bir sinir ağının ileri besleme işlemi Denklem 2.40-41'deki gibi tanımlanabilir (Srivastava vd., 2014).

$$z_i^{(l+1)} = w_i^{(l+1)} y_l + b_i^{(l+1)} \quad (2.40)$$

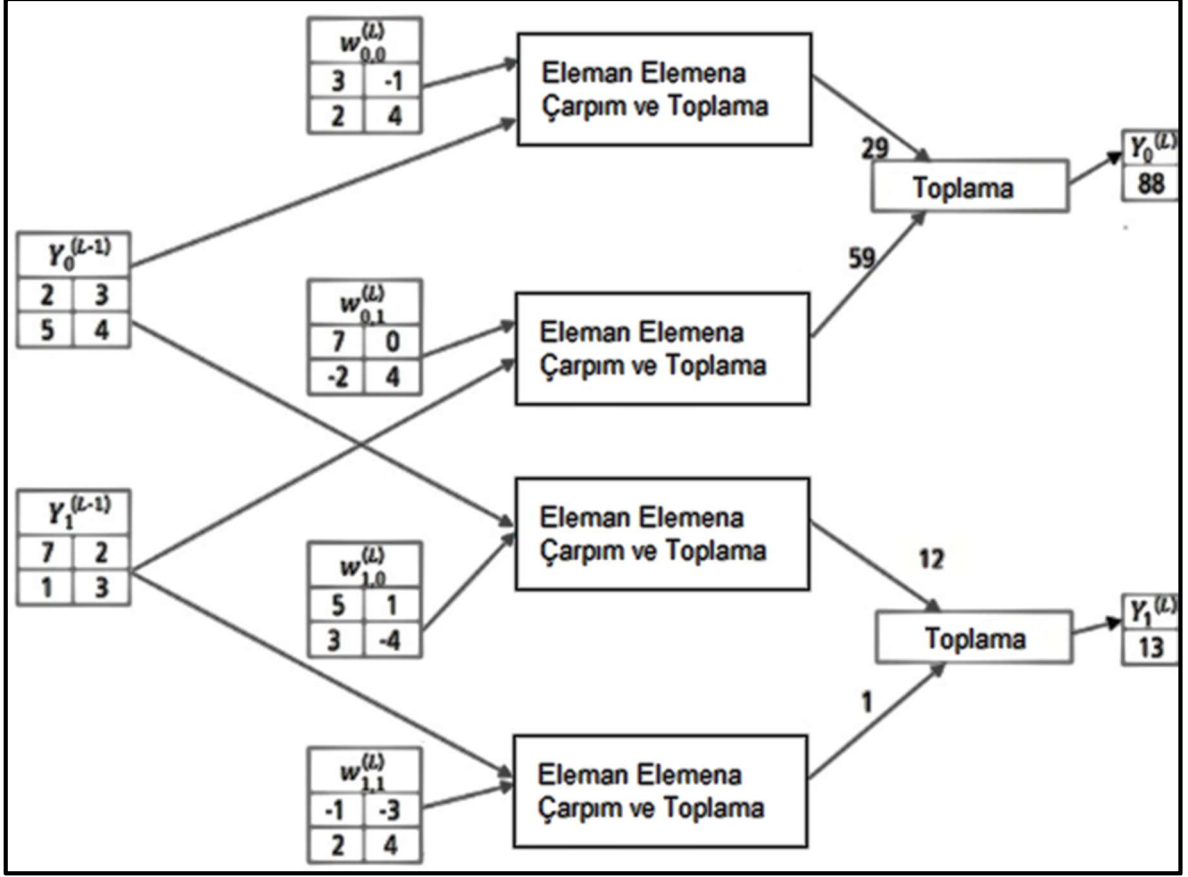
$$y_i^{l+1} = f(z_i^{(l+1)}) \quad (2.41)$$

L gizli katmanı olan bir sinir ağında Dropout ile, ileri besleme işlemi Denklem 2.42'deki gibi düzenlenebilir. Burada * konvolüsyon işlemi göstermektedir.

$$\tilde{y}^{(l)} = r^{(l)} * y^{(l)}, z_i^{(l+1)} = w_i^{(l+1)} \tilde{y}^{(l)} + b_i^{(l+1)}, y_i^{(l+1)} = f(z_i^{(l+1)}) \quad (2.42)$$

Tamamen bağlı bir katman, parametrelerin çoğunu kapladığından, aşırı eşleştirmeye eğilimlidir. Aşırı eşleştirmeyi azaltmak için kullanılan bir yöntem Dropout'tur (Srivastava vd., 2014). Her bir eğitim aşamasında, bireysel düğümler 1-p olasılıkla ağdan dışarı atılır


veya olasılık p ile tutulur, böylece azaltılmış bir ağ kalır. Çıkarılan bir düğüme gelen ve giden kenarlar da kaldırılır. Bu aşamada sadece azaltılmış ağ verileriyle eğitilmiştir.



Şekil 2.5. Tamamen bağlı bir tabakanın işlenmesi süreci (URL-3, 2018).

Kaldırılan düğümler daha sonra orijinal ağırlıkları ile ağa yeniden yerleştirilir. Eğitim aşamalarında, gizli bir düğümün düşürülme olasılığı genellikle 0.5'tir. Giriş düğümleri için bu, sezgisel olarak çok daha düşük olmalıdır, çünkü giriş düğümleri göz ardı edildiğinde bilgiler doğrudan kaybolur. Eğitim bittikten sonra test süresinde ideal olarak tüm olası 2^n çıkış ağlarının örnek ortalamasını bulmak isteriz; ne yazık ki bu n büyük değerleri için mümkün değildir. Bununla birlikte, p faktörü ile ağırlıklandırılmış her bir düğümün çıkışına ait yaklaşımı tam ağı kullanarak bulabiliriz. Böylece, herhangi bir düğümün çıktısının beklenen değeri, eğitim aşamalarındaki ile aynıdır. Bu, Dropout yönteminin en kullanışlı katkılarından biridir. Her ne kadar etkili bir şekilde 2^n sinir ağları oluştursa da, ve bu nedenle model kombinasyonuna izin verse de, test zamanında sadece tek bir ağın test edilmesi gerekir. Tüm eğitim verilerindeki tüm düğümleri eğitmekten kaçınarak, Dropout aşırı eşleştirmeyi azaltır. Yöntem ayrıca eğitim hızını önemli ölçüde artırır. Bu, derin ağlar için

bile model birleşimini pratik yapar. Teknik, düğüm etkileşimlerini azaltarak yeni verileri daha iyi genelleştiren daha sağlam öznelikler öğrenmeye yönlendirir. Örnek bir Dropout yapısı Şekil 2.6’da verilmiştir.



Şekil 2.6. Örnek bir Dropout yapısı (URL-4, 2018).

2.3.7.2.6. Softmax

Genellikle ağıdaki son katman, sınıflandırma gibi görev amacını gerçekleştiren, yaygın olarak kullanılan softmax işlevidir. Olasılık teorisinde, softmax fonksiyonunun çıktısı kategorik bir dağılımı temsil etmek için kullanılabilir. K değişik muhtemel çıkışın üzerinde bir olasılık dağılımıdır. Softmax fonksiyonu, çok terimli lojistik regresyon gibi çeşitli çok sınıflı sınıflandırma yöntemlerinde kullanılır (Bishop, 2006). Özellikle, çok terimli lojistik regresyon ve lineer diskriminant analizinde, fonksiyonun girdisi K'nin farklı lineer fonksiyonlarının sonucudur ve j'inci sınıfı için bir örnek vektörü x ve bir ağırlık vektörü w için öngörülen olasılık Denklem 2.43'deki gibidir.

$$P(y = j|x) = \frac{e^{x^T w_j}}{\sum_{k=1}^K e^{x^T w_k}} \quad (2.43)$$

Bu K lineer fonksiyonların bileşimi ve softmax fonksiyonu olarak görülebilir. Fonksiyon, w ile vektörler ve x ile tanımlanan bir lineer operatörün uygulanmasına eşdeğerdir. Böylece büyük olasılıkla yüksek bir K-boyutlu uzaydaki vektörlere girdi olarak

tanımlanır. Geometrik olarak, softmax fonksiyonu, vektör uzayını standart simpleksinin iç kısmına eşler. Çünkü tüm çıkış toplamının bir hiperdüzlemde olduğu anlamına gelen doğrusal kısıtlama mevcuttur. Ana köşegen boyunca çıktılardaki eşit dağılım ve eşit seviye eşit olasılıklar tanımlanmıştır. Daha genel olarak, softmax, her koordinatta aynı değere göre sapmaya karşı korumalıdır, çünkü her bir üssü aynı faktörle çarpar, bu yüzden oranlar değişmez. Bu süreç Denklem 2.44'de gösterilmiştir. Diğer deyişle geometrik olarak, softmax köşegenler boyunca sabittir. Toplamın sıfır olduğu varsayılarak giriş normalize edilebilir ve daha sonra softmax sıfır olan noktaların hiper düzlemini alır. Fakat softmax ölçeklendirme altında değişmez değildir.

$$\sigma(z + j)_j = \frac{e^{z_j+c}}{\sum_{k=1}^K e^{z_k+c}} = \frac{e^{z_j}.e^c}{\sum_{k=1}^K e^{z_k}.e^c} = \sigma(z)_j \quad (2.44)$$

2.3.7.2.7.KSA Mimarisi

Bir KSA mimarisini oluşturmak için bu katmanların bir kombinasyonu kullanılabilir. KSA için tipik bir mimari modeli Giriş \rightarrow [[Konvolüsyon \rightarrow ReDB]*N \rightarrow Havuzlama?]*M \rightarrow [Tamamen bağlanmış katman \rightarrow ReDB]*K \rightarrow Tamamen bağlanmış katman şeklinde ifade edilebilir (URL-4, 2018). N, M ve K sıfırdan büyük tamsayılardır ve * tekrarlamayı temsil eder. N, genellikle üçten küçük veya eşittir ve K, üçten azdır. Havuzlama? havuzlama katmanının isteğe bağlı olduğunu belirtir. >Havuzlama işleminden önce, konvolüsyon katmanının giriş hacminin daha karmaşık özniteliklerini algılayabilmesi nedeniyle, daha büyük ve daha derin ağlar için havuz katmanından önce birden fazla konvolüsyon katmanının koyulması genellikle iyi bir fikirdir (URL-4, 2018). Tamamen bağlanmış katmanlarda eğitim sırasında Dropout uygulanması yaygındır. Dropout oranı, aşırı eşleştirmeyi azaltmak için basit bir yoldur. Eğitim sırasında, bireysel düğümler 1 - p olasılıkla devre dışı bırakılır veya p olasılıkla aktif tutulur. Devre dışı bırakılan bir düğüme gelen ve giden bağlantılar da düşer. Aşırı eşleştirmeyi azaltmanın yanı sıra, bu da gerekli hesaplamaların miktarını düşürür ve daha iyi performans sağlar. Ancak test sırasında tüm düğümler aktif hale gelir (Srivastava vd., 2014). Başlangıçta ağın ağırlıklarını belirlerken, bunların hepsinin sıfıra ayarlanmaması önemlidir, çünkü bu, güncellemelerde istenmeyen simetriye yol açabilir. Bunları örneğin, bir Gauss dağılımından örnek alarak, küçük, rasgele sayılara ayarlamak genellikle iyi bir fikirdir. Denklem 2.45 ile açıklandığı gibi, tahminler ve hedefler arasında kategorik çapraz

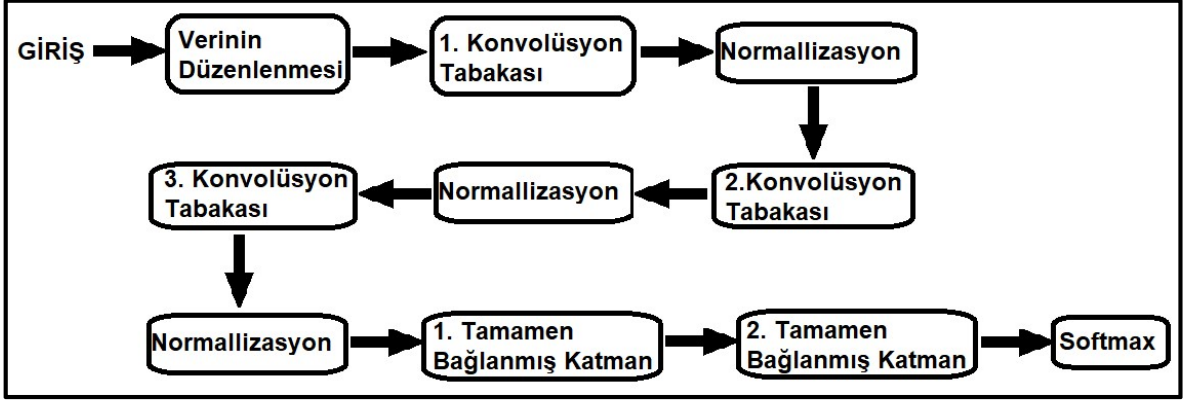
entropi hesaplayarak eğitim için, ihtiyaçların en aza indirilmesi için bir kayıp ifadesi belirlenebilir. Her bir örnek için, p_i 'deki tahmin olasılıkları arasındaki çapraz entropi, örneğin softmax çıkışı ve hedef değer t_i hesaplanır. Amaç, ağı eğitimi sırasında bu kayıp ifadesini en aza indirmektir.

$$L_i = -\sum_j t_{i,j} \log(p_{i,j}) \quad (2.45)$$

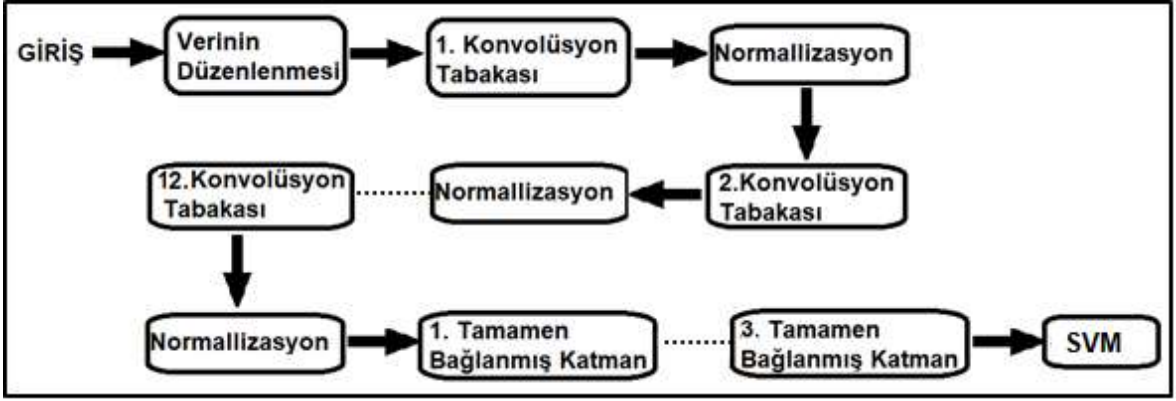
Sisteme giriş katmanından veri girişi yapılmaktadır. Konvolüsyon katmanında bir dizi filtre kullanılır ve her filtre sinyal ile konvolüsyon işlemine tâbi tutulur. Oluşturulan KSA'nda filtre sayısı 5 olarak aktivasyon haritasını elde ederiz. ReDB katmanı, bir rampa fonksiyonu olan bir aktivasyon fonksiyonudur. Ayrıca Z-skor girişi normalizasyonu kullanılmıştır böylece eğitim aşamasında her parametrenin, oluşturulacak modelin tahmin edebilmesine eşit seviyede katkıda bulunabilmesi sağlanmaktadır. Bu normalizasyon aşaması Denklem 2.46'da açıklanmıştır. Burada y' normalize veriyi elde etmek için y_i giriş verisi, μ giriş verisinin ortalaması, σ ise standart sapmasına ihtiyaç vardır.

$$y' = \frac{y_i - \mu}{\sigma} \quad (2.46)$$

Havuzlama katmanı genellikle ReDB tabakasından sonra yerleştirilir. Havuzlama katmanının kullanımı opsiyoneldir. Tamamen bağlanmış katmanda, bir katmandaki her bir nöron başka bir katmandaki başka bir nörona bağlıdır. Dropout Katmanının amacı, ağı belli birkaç düğümünü kaldırmaktır ve bundan sonraki katmanda softmax sınıflandırıcı kullanılmaktadır. KSA genellikle resim sınıflandırılmasında kullanıldığından sistemde genellikle 2 boyutlu matrisler kullanılmaktadır. Çekirdeğin zaman serisi boyunca ilerlemesini istiyoruz, ancak resimler için kullanacağımız ikinci boyut boyunca ilerlememesi için adım argümanını kullanıyoruz. Kullandığımız ilk KSA mimarisi Şekil 2.7'de ve ikinci KSA mimarisi Şekil 2.8'de verilmiştir. İkinci KSA yapısında 12 konvolüsyon tabakası ve 5 filtre boyutunu kullandık. Lekha ve Suchetha (2018) tarafından yapılan çalışmada, KSA ile eğitilen bir SVM sınıflandırıcısının tipik bir Softmax sınıflandırıcısından üstün olduğunu görülmüştür. Bundan dolayı ikinci KSA mimarimizde sınıflandırıcı olarak Softmax yerine SVM kullandık.



Şekil 2.7. Kullandığımız ilk KSA mimarisi.



Şekil 2.8. Kullandığımız ikinci KSA mimarisi.

2.3.7.3. İğnecikli Sinir Ağı


Üçüncü kuşak güçlü bir nöral ağ olarak, son birkaç yılda İSA'ların varlığı, desen tanıma alanında geliştirilmiş yaklaşımlara odaklanan birçok çalışmayı teşvik etmiştir (Kasabov vd., 2013). İSA'lar başlangıçta beyinden ve nöronların uyarlamalı sinapslar aracılığıyla zaman içinde farklı eylem potansiyelleri yoluyla bilgi dönüşümü için kullandıkları iletişim şemasından esinlenmiştir. Biyolojik bir nöronda, presinaptik uyarımdan kaynaklanabilecek membran potansiyelindeki değişikliklerin toplamı bir eşiği geçtiğinde bir tetikleme oluşur. Tetikleme üretiminin hızı ve tetikleme dizilerinin zamansal paterni, dış uyaranlar ve devam eden hesaplamalar hakkında bilgi taşır (Gerstner ve Kistler, 2002). İSA'lar, bu sürece çok benzer bir süreç kullanır. Bir İSA mimarisi, ayarlanabilir skaler

ağırlıklarla modellenen iğnecikli nöronlar ve birbirine bağlanan sinapslardan oluşur. Bir İSA uygulamasındaki ilk adım, analog giriş verilerini tetikleme dizilerine kodlamaktır. Beyindeki biyolojik bir nöron, sinir ağındaki diğer nöronlardan sinaptik girdiler alır. Biyolojik sinir ağları hem etki potansiyeli üretim dinamiğine hem de ağ dinamiğine sahiptir. Gerçek biyolojik ağlara kıyasla, yapay İSA'ların ağ dinamikleri oldukça basitleştirilmiştir. Tetikleme nöronları ağında tetikleme dizileri, sinaptik bağlantılar yoluyla yayılır. Uyarlamalı sinapsların gücü (ağırlıkları), öğrenme sonucunda değiştirilebilir. Tetiklemeli ağlar, tetikleme olmayan ağlarda doğrudan çoğaltılamayan bir tür öğrenme kuralı sağlar. Nörobilimciler, bu öğrenme kuralının, zamana bağımlılığa bağlı esneklik koruması altında kalan birçok biçimini tanımladılar. Başlıca özelliği, önceden ve sonra sinaptik bir nöronu birleştiren ağırlığın (sinaptik etkinlik), kabaca onlarca milisaniyelik bir süre içinde göreceli sıçrama sürelerine göre ayarlanmasıdır (Caporale ve Dan, 2008). Ağırlık ayarlaması yapmak için kullanılan bilgiler, hem sinaps hem de zamanda bölgeseldir. Derin sinir ağları genellikle geri yayılımına dayalı optimizasyon algoritmaları kullanılarak uçtan uca eğitilir. Beyindeki çok katmanlı sinir mimarisi, araştırmacıları birçok nöronlu sığ ağlar kullanmak yerine doğrusal olmayan sinir katmanlarının derinliğine odaklanmak için ilham kaynağı olmuştur. Ayrıca, teorik ve deneysel sonuçlar geniş yapılar yerine derinlerin daha iyi performans gösterdiğini göstermektedir. Derin sinir ağları, geri yayılma algoritması için uygun bir platform sağlamak için lineer olmayan, farklılaşabilir aktivasyon fonksiyonları ile donatılan sıralı nöron katmanları aracılığıyla karmaşık öznitelikler çıkarır. Çoğu sınıflandırma probleminde, derin bir ağın çıktısı katmanı bir softmax modülü kullanır. Eğitimde her vektör bileşeni olası sınıflardan birine karşılık gelir. Çıkış katmanı için softmax modülü, çıkış birimlerinin her birinin değerlerinin sıfır ile bir aralığında olmasını ve ayrıca toplamın bir karşılık gelmesini sağlar. Bu, karşılıklı olarak özel ve ayrıntılı olasılık değerleri sağlar. İSA'lar bir dizi desen tanıma görevinde ümit vaat eden performans göstermektedir. Ancak, sonuçlar KSA'ları kadar iyi değildir.

İSA'lar, eğitim yöntemleri ve hesaplama gereksinimlerinde KSA'lardan farklıdır. Bu noktada, uygulama alanlarında bazı durumlarda tamamlayıcıdır, ancak bu zaman içinde değişebilir. İSA'ların, sıklıkla “tek adımlı öğrenme” olarak adlandırılan, anında eğitilebilme yeteneği dâhil olmak üzere, bazı ilginç ve kullanışlı öznitelikleri vardır. KSA ve İSA modellerinin karşılaştırılmalı gösterimi Şekil 2.9'da verilmiştir.

KSA'lar yüksek özellikli öğrenme süreçleri kullanırlar; bu, birden fazla öğeyi tanımlayabilen bir sınıflandırma sürecinde kullanılan ağırlıkları üretir. İSA'lar daha verimli

bir eğitim mekanizması kullanır, ancak tek bir varlığı tanımlamak için tasarlanmıştır. Hesaplama açısından bakarsak KSA konvolüsyon, ReDB, havuzlama, tamamen bağlanmış, Dropout, Softmax Katmanlarından oluşmakta sonuç olarak yoğun matematik işlemlerine bağlı yüksek güç ihtiyacı oluşmaktadır ve bağlantılı olarak hızlandırıcı bloklar kullanılmaktadır. İSA ise eşik mantığı ve bağlantı güçlendirme özelliği ile daha az matematik işlemine bağlı daha az güç ihtiyacı olmaktadır.



Şekil 2.9. KSA ve İSA modellerinin karşılaştırılmalı gösterimi (URL-5, 2018).

Eğitim açısından bakarsak KSA özellik olarak geri yayılım ile denetimli eğitim şeklindedir bundan dolayı önceden etiketlenmiş büyük veri kümeleri gerektirir. Büyük veri kümeleri uzun eğitim sürelerine ve yüksek kapasiteli donanım gerektirmektedir. Buna karşılık İSA'da ileri beslemeli tek seferlik eğitim kullanılmaktadır böylece alanda çok daha hızlı bir eğitim mümkün olmaktadır. Sınıflandırma açısından bakarsak KSA'da ardışık filtreleme ile öznelilik çıkarımı için daha yüksek tanımlamalı veri gerektirir. Eğer beklenmedik veriler varsa bu sistemin çalışmasında zorluklara neden olur. İSA ise iğnecikli model sınıflandırma yapmaktadır ve örüntüleri daha az veri ile tanır. Düşük çözünürlükte

başarılı sonuçlar sağlar. Sonuç olarak KSA, daha karmaşık eğitim gereksinimleri ile matematiksel açıdan yoğun olma eğilimi gösterirken, sinir ağlarının kullanımı daha kolaydır ancak daha özellikli sınıflandırma sonuçlarını hedefler (URL-5, 2018).

Nöronal ve sinaptik duruma ek olarak, İSA'lar ayrıca zaman kavramını kendi çalışma modellerine dâhil eder. İSA'daki nöronlar her yayılma döngüsünde (tipik çok katmanlı algılayıcı ağlarda olduğu gibi) tetiklememekte, aksine sadece bir zar potansiyeli belirli bir değere ulaştığında tetiklenmektedir (Membranın elektriksel yüküne bağlı nöronun özgün bir niteliği). Bir nöron tetiklediğinde, bu sinyale uygun olarak potansiyellerini artıran veya azaltan diğer nöronlara giden bir sinyal üretir. Sinirsel sinir ağlarını bağlama kapsamında, mevcut aktivasyon seviyesi (bazı diferansiyel denklemler olarak modellenmiştir) normalde nöronun durumu olarak kabul edilir, bu değer daha yüksek olan yükselen sivri uçlarla, ve zamanla ya tetiklenir ya da zamanla bozulur. Bu konudaki ilk bilimsel model Alan Lloyd Hodgkin ve Andrew Huxley tarafından önerildi. Bu model, aksiyon potansiyellerinin nasıl başlatıldığını ve yayıldığını anlatmaktadır (Hodgkin ve Huxley, 1952). İletişim, nörotransmitterler olarak adlandırılan sinaptik aralıktaki kimyasal maddelerin değişimini gerektirir. Nörobilimin temel sorunlarından biri nöronların bir hız veya zamansal kod ile iletişim kurup kurmadığını belirlemektir. Bu tür bir sinir ağı, prensipte bilgi işleme uygulamaları için geleneksel YSA ile aynı şekilde kullanılabilir.

İSA'lar, karmaşık problemleri çözmek için beyin işlevselliğini taklit eden güç verimli platformlara olanak tanır. Bu nedenle, İSA'lar kadar verimli ve biyolojik olarak mantıklı olan ve farklı görevleri yerine getirirken KSA'lar kadar güçlü bir sinir ağının geliştirilmesi, yapay zeka ve hesaplama nörobilim alanındaki ulaşılmaya çalışılan bir hedefdir. Nöral ağlarda biyolojik olarak makul öğrenme yöntemlerini ve geleneksel öğrenme algoritmalarını birbirine bağlamak için bir dizi derin İSA geliştirilmiştir. Örneğin, Bengio ve diğerleri (2015) ileri ve geri nöral aktivite yayılımını kullanarak derin bir öğrenme metodu önermişlerdir. Bu ağdaki öğrenme kuralı, zamanlamaya bağlı esnekliğin gradyan iniş öğrenme kuralı uyguladığı fikrine dayanmaktadır. Pre-ve postsinaptik tetikleme dizileri kullanarak, O'Connor ve Welling (2016), ön ve postsinaptik tetikleme sayılarının dış çarpımını kullanarak derin İSA'larda bir geri-yayılma algoritması geliştirdiler. ReDB ile donatılmış geleneksel derin sinir ağlarının performansıyla karşılaştırılabilir iğnecikli çok katmanlı perceptronun yüksek performansını gösterdi. İSA'larda hesaplama maliyetini daha da azaltmak için Neftci ve diğerleri (2017), geri yayılma zinciri yolunu basitleştiren, olaya dayalı bir rasgele geri yayılım algoritması önermiştir. Bu kuralda, öğrenme için kullanılan

tüm bilgilerin nöron ve sinapsta yerel olarak mevcut olduğu bir hata modülasyonlu sinaptik elastike kullanmıştır. Güçlendirilmiş İSA'lardan yararlanmaya yönelik daha doğrudan bir yaklaşım, çevrimdışı bir eğitilmiş KSA'ı, özellikle donanım uygulaması için, bir nöromorfik tetikleme platformuna dönüştürmektir. Derin ağlardaki aktivasyon değerlerinin yerini almak için, genellikle daha yüksek aktivasyonların daha yüksek tetikleme hızlarıyla değiştirildiği oran tabanlı kodlama kullanılır. Bu yaklaşımı kullanarak, yüksek doğruluk performansı elde eden çeşitli modeller geliştirilmiştir. İSA'ların güç tüketimini değerlendiren bir çalışmada, Neil ve diğeri (2016) hepsi aynı doğruluk oranına ulaşan birçok farklı model üzerinde çalışmışlardır. Aynı üç katmanlı mimariyi kullandılar, ancak modelin gücünü ve gecikmesini azaltmak için optimize edilmiş parametreler ve İSA mimarisi ayarları uyguladılar.

İSA'lar, seyrek, tetikleme tabanlı iletişim çerçevelerinden dolayı güç verimli modeller olarak tanımlanmıştır. Biyolojiden ilham alan, güç verimli platformları uygularken son zamanlarda kanıtlanmış derin ağların yüksek performansına ulaşmak için çok katmanlı bir İSA mimarisi geliştirmek için her iki çerçevenin avantajlarından faydalanmaya çalışılmaktadır. Ayrıca, literatür, beynin uyarlamalı sinapslar aracılığıyla tetikleme dizileri ile iletişim kuran çok katmanlı İSA'lar aracılığıyla uyaran modellerini saptadığını göstermiştir. Biyolojik olarak gerçekçi nöronlar, belirgin türevlere sahip olmayan tetikleme dizileri kullanarak iletişim kurarlar. Bu, İSA'ları eğitim için doğrudan türev tabanlı optimizasyonu kullanamaz hale getirir. Belirli sinir mimarilerine sahip İSA'lar yeni nöron modelleri ve öğrenme teknikleri gerektirir. Tetikleyici nöronları, uyarıcıların modelini ayırt etmek için yerel olarak adapte olan sinapslar aracılığıyla ayrık tetikleme dizileri ile iletişim kurarlar. Bu gereklilikleri karşılama arayışı, uyarıların entegrasyonu ve ayırıcı tetikleme modellerini sinaptik ağırlık setleriyle ilişkili uyarlamalı filtreler göre serbest bırakmak için biyo-kaynaklı sinirsel simülasyonlar ile gerçekleştirilebilir. İSA'ların geliştirilmesinde önemli bir sorun, tetiklemelerin bölgesel modellerini saptamak için uygun öğrenme kuralları geliştirmektir.

Oluşturulan sistemde Birleştir ve Ateşle (The integrate-and-fire,IF) modeli, anlık gerilim darbesi nöronu olarak kullanıldı. Model, nöronun membran potansiyelinin dinamikleri, $v(t)$ ile tanımlanmıştır (Burkitt, 2006). Denklem 2.47'deki C_m , membran kapasitansdır. $I_{leak}(t)$, membranın pasif sızıntısına bağlı akımdır. $I_s(t)$ sinaptik girdinin nörona etkisini açıklayan bir akımdır. $I_{inj}(t)$ nöron içine enjekte edilen bir akımdır.

$$C_m \frac{dv(t)}{dt} = I_{leak}(t) + I_s(t) + I_{inj}(t) \quad (2.47)$$

Membran potansiyeli tetikleme eşiğine ulaştığında bir aksiyon potansiyeli oluşumu genellikle modelin içsel bir parçası olarak kabul edilmez. Sonuç olarak, sadece alt-eşik membran voltajını tanımlamak, IF nöronlarının yapısında olağan bir durumdur. Yine de, iğneli mekanizmayı bir tetikleme akımı cinsinden dâhil etmek mümkündür. Denklem 2.48, membran potansiyeli tetikleme üreten eşiğe ulaştığındaki bir tetiklemeyi açıklar. V_{th} ve daha sonra membran potansiyeli V_{reset} 'e sıfırlanır. $\delta()$ Dirac delta fonksiyonunu gösterir. Mutlak refrakter dönemden sonra membran potansiyeli tekrar gelişmeye başlar.

$$I_{spike}(t) = C_m \left[\frac{dv(t)}{dt} \right]_{v=V_{th}}^{-1} (V_{reset} - V_{th}) \delta[v(t) - V_{th}] \quad (2.48)$$

Nöronların difüzyon modelleri, membran potansiyelini bir difüzyon süreci olarak, yani sürekli bir yolla sürekli-zamanlı bir Markov süreci olarak ele alırlar. Sinaptik girdinin stokastik doğası, membran potansiyelinin modellenmesiyle açıklanabilir. Denklem 2.49'da verilmiştir. Ortalama giriş μ ve yoğunluk katsayısı σ ile bir Gauss beyaz gürültü $\xi(t)$ ile Ornstein – Uhlenbeck modeli olarak adlandırılan bir stokastik diferansiyel denklem tanımlanmıştır.

$$\tau \frac{dv(t)}{dt} = -[v(t) - V_0] + \mu + \sigma \sqrt{2} \xi(t) \quad (2.49)$$

Sızıntısız Birleştir ve Ateşle nöron modeli rasgele yürüyüş sürecinin (Brownian hareketinin) sınırlayıcı durumu olarak elde edilir, burada membran potansiyeli her postsinaptik potansiyellerin gelmesiyle genlikteki adım değişikliklerine maruz kalır. Her adımın genliğinin küçüldüğü durumu inceleyerek, aynı zamanda girdi oranı artarken, membran potansiyelinin yörüngesi sürekli hale gelir. Membran potansiyeli denklem 2.50 tarafından tarif edilmiştir. Burada $v(0) = v_0$ ve varyans parametresi σ_w ve drift parametresi $\mu_w > 0$ ile $W(t)$ standart bir Wiener işlemidir.

$$v(t) = v_0 + \mu_w t + \sigma_w W(t), \quad t > 0 \quad (2.50)$$

Stein modeli, mevcut sinaptik girdiden ötürü, iki ateşleme olayı arasındaki zar potansiyelinin dalgalanmalarını tek boyutlu bir stokastik süreç olarak tanımladı. Her sinaptik

girdi, membran potansiyelinde bir adım süreksizliği olan bir değişikliğe yol açar ve atış-gürültü formunun bir sinaptik yanıt fonksiyonu olarak modellenebilir. Denklem 2.51'de verilmiştir. Sonraki sinaptik girişler arasında, zaman süresi ile potansiyel zaman azalması τ_m zar zamanı sabiti ile belirlenir.

$$\tau_m \frac{dv(t)}{dt} = -[v(t) - V_0] + \alpha_E S_E(t) + a_1 S_1(t) \quad (2.51)$$

Denklem 2.52'de verilen çıkış hızlanma oranı, ilk geçiş süresi yoğunluğunun ilk anı olan ortalama ara mesafe, \bar{T}_{ISI} 'dan belirlenir. τ_r mutlak refrakter süredir. Tetikleme aralığının dağılımının daha yüksek anları da modelin özelliklerinin anlaşılmasında önemli bir rol oynar.

$$\lambda_{out} = [\tau_r + \bar{T}_{ISI}]^{-1}, \quad \bar{T}_{ISI} = E[T_{ISI}] = \int_0^{\infty} dt t f_{\theta}(t) \quad (2.52)$$

Kavramsal bakış açısından, tüm iğnecikli ağ modelleri biyolojik ortaklarıyla aşağıdaki ortak özellikleri paylaşmaktadır. Birçok girdiden gelen bilgileri işler ve tek tetiklemeli çıkış sinyalleri üretirler. Tetikleme oluşturma olasılığı eksitator girişler ile artırılır ve inhibitör girdilerle azalır. Dinamikleri en az bir durum değişkeniyle karakterize edilir; Modelin iç değişkenleri belirli bir duruma ulaştığında, modelin bir veya daha fazla tetikleme üretmesi beklenir. Nöronlar, sinaps adı verilen özel bağlantılarla birbirleriyle bağlantı kurar ve iletişim kurar. Bir sinapsta presinaptik tetikleme gelişi, postsinaptik nörona bir giriş sinyali $i(t)$ tetikler. Bu sinyal biyolojik nörona akan sinaptik elektrik akımına karşılık gelir. Basit bir modelde $i(t)$ 'nin zaman aralığı üstel fonksiyonla tanımlanabilir (Ponulak ve Kasinski, 2011). Denklem 2.53'de verilmiştir. τ_s sinaptik zaman sabiti ve $S_j(t)$ presinaptik tetikleme dizisini gösterir.

$$i(t) = \int_0^{\infty} S_j(s - t) \exp\left(-\frac{s}{\tau_s}\right) ds \quad (2.53)$$

Tipik olarak bir İSA sonlu yönelimli bir grafik (V, E) olarak düşünülür, V bir dizi nöron ve E bir dizi sinaps temsil eder. Özellikle set V, giriş nöronları V_{in} 'in bir alt kümesini ve çıkış nöronları V_{out} 'un bir alt kümesini içerir. Giriş nöronlarının ateşlemesinin, İSA'nın dışından belirlendiği varsayılır, yani ateş etme zamanları kümesi, V_{in} 'deki nöronlar için

İSA'nın girişi olarak verilir. İlk tetikleme zamanında nöral sistemlerdeki bilgi, uyarımın başlangıcı ile nöral yanıtta ilk tetikleme arasındaki gecikme olarak kodlanır. İlk tetikleme zamanının yeterli bilgi taşıdığı görülmüştür. İlk tetikleme zamanı planı ultra-hızlı bilgi işlemeyi mümkün kılar, çünkü bir uyarı ile ilgili karar, bir kaç milisaniye içinde ilk tetiklemenin gelmesiyle bildirilebilir. Bu kod aynı zamanda çok basittir ve ilk tetikleme hariç tümünün yayılımını engelleyen engelleyici geri besleme etkileşimlerine sahip tek bir nöron kullanılarak uygulanabilir.

Sinaptik plastisite, sinaptik bağlantıların kuvvetlerini değiştirebilme yeteneğini ifade eder. Bu, biyolojik sinir ağlarında öğrenme ve hafızanın altında yatan temel mekanizma olarak düşünülebilir. Sinaptik plastisitenin çeşitli formları birlikte bulunur. Genellikle zaman ölçeğinde farklılık gösterirler. Tetikleme tabanlı sinaptik plastisitenin çeşitli formlarını tanımlayan genel bir model, Denklem 2.54'deki gibi ifade edilebilir.

$$\frac{d}{dt} w_{ji}(t) = a_0 + a_1 S_i(t) + a_2 S_j(t) + a_3 S_i(t) \overline{S_j(t)} + a_4 \overline{S_i(t)} S_j(t) \quad (2.54)$$

Burada $w_{ji}(t)$, nöron i 'den j 'ye sinaptik eşleşmenin etkinliğidir $S_i(t)$ ve $S_j(t)$ sırasıyla ön ve postsinaptik tetikleme dizileridir. Her bir tetikleme dizisi, atış zamanlarında t^f Dirac impulslarının toplamı olarak tanımlanır ve Denklem 2.55'de verilmiştir. $S_i(t)$ ve $S_j(t)$, $\overline{S_i(t)}$ ve $\overline{S_j(t)}$ 'nin düşük geçiren filtreli versiyonlarıdır. $a_0 \dots a_4$, sinaptik etkinlikte değişiklik oranını kontrol eden sabit katsayılarıdır.

$$S(t) = \sum_f \delta(t - t^f) \quad (2.55)$$

Aktiviteden bağımsız ağırlıkta ayrışma ve Hebbian terimlerinin dışında, sinaptik değişimlerin, zıt alanda ilave aksiyon potansiyelleri olmaksızın, ön veya sonraki sinaptik terminaldeki bireysel iğne yapılar tarafından da tetiklendiği varsayılmaktadır. Denetimli Hebbian öğrenimine göre, tetikleme tabanlı bir Hebbian süreci, postsinaptik nöronun hedef zamanlarda ateşlenmesini ve diğer zamanlarda sessiz kalmasını sağlayan ek bir öğretim sinyali ile denetlenir. Öğretim sinyali genellikle nörona, sinaptik akımlar biçiminde veya hücre içi olarak enjekte edilen akımlar şeklinde iletilir. ReSuMe algoritması Hebbian süreçlerinden yararlanır, ancak sinaptik plastisiteyi modüle eden öğretici bir sinyalin

postsinaptik somatik membran potansiyeli üzerinde sadece marjinal doğrudan etkiye sahip olduğu varsayılır. Sinaptik ağırlık değişimleri aşağıdaki Denklem 2.56'ya göre düzenlenir.

$$\frac{d}{dt} w_{ji}(t) = a[S_d(t)\overline{S_i(t)} - S_j(t)\overline{S_i(t)}] = a[S_d(t) - S_j(t)]\overline{S_i(t)} \quad (2.56)$$

Burada a öğrenme oranı, $S_d(t)$ hedef tetikleme dizisi, $S_j(t)$ çıkış tetikleme dizisi ve $S_i(t)$ düşük geçirgen filtreli giriş tetikleme dizisi olarak ifade edilir. ReSuMe'nin karmaşık geçici ve zaman mekânsal tetikleme modellerinin yüksek doğrulukta etkili bir şekilde öğrenilmesini sağladığı gösterilmiştir. Algoritmanın, tetikleme dizisi tahmini, tahmini sınıflandırma, model oluşturma görevlerinde de etkili olduğu kanıtlanmıştır.

İğnecikli sinir ağları, hem makine öğrenimi çerçevesinde elde edilen yeni algoritmalarından hem de nörobiyolojideki yeni keşiflerden daha fazla kazanım elde edebilir. Özellikle daha verimli öğrenme yöntemlerinin bulunmasının yeni uygulama alanlarına fayda getirmesi beklenmektedir.

2.4. Eğitim ve Test

Veri kümesi harmanlandıktan sonra eğitim ve test şeklinde iki eş kümeye ayrıldı. Eğitim veri setine on kat çapraz doğrulama uygulandı. Bu, verilerin on set halinde bölündüğü anlamına gelmektedir. Dokuz veri kümesi eğitim aşamasında kullanıldı. Ve test için de kalan veri kümesi kullanıldı. İşlem on defa tekrarlandı ve ortalama doğruluk alındı.

2.4.1. Veri Tabanı

St. Petersburg Kardiyoloji Tekniği Enstitüsü'nün 12 kanallı aritmi veri tabanı 32 adet Holter kayıtlarından çıkarılan 75 açıklamalı kayıttan oluşmaktadır. Her bir kayıt 30 dakikadır ve her biri 257 Hz'de örneklenmiş 12 adet standart kanal içerir. Bu dosyalar iskemiye, iletim anormalliklerine, koroner arter hastalığına ve aritmilere uygun EKG'leri olan hastalara (15 kadın ve 17 erkek, 18-80 yaş arası hastalar) ait verileri içerir (Goldberger vd., 2000). Hiçbir hastada kalp pili yoktur ve en çok ventriküler ektopik atım bulunmaktadır. 175978 atım için referans açıklama dosyası içermektedir. Bu tanılar enzim analizleri, koroner anjiyografi, elektrofizyolojik çalışma ve gerektiğinde basınç takibi ile doğrulandı.

St. Petersburg Kardiyoloji Tekniđi Enstitüsü aritmi veri tabanı dosyalarının içeriğinde tespit edilenler Tablo 2.1’de verilmiştir.

Tablo 2.1. Aritmi veri tabanı dosyalarının içeriğinde tespit edilenler.

Dosya	İçeriğinde tespit edilenler
I01	EVK, Gürültü
I02	Ventriküler Trigemini, Ventriküler Çift
I03	St Yükselmesi, EVK
I04	Bradikardi, Taşikardi, EVK, Ventriküler Çift, Paroksizmal Ventriküler
I05	Paroksizmal Ventriküler Taşikardi
I06	St Deđişimleri, EVK
I07	EVK, Supraventriküler Üçüz
I08	Ventriküler Trigemini, Ventriküler Çift
I09	Ventriküler Çift, Ventriküler Kaçış Atımları, Av Nodal Blođu 2 Derece
I10	Taşikardi, Av Nodal Blođu 2 Derece Moebits 1, Gürültü
I11	EVK, Av Nodal Blođu 2 Derece Moebits 1
I12	ST Çökmesi, Ventriküler Çift
I13	EVK
I14	EVK, Başlangıç Sapması
I15	ST Çökmesi, EVK
I16	Sađ Dal Blođu, Polimorfik EVK, Gürültü
I17	Bradikardi, EVK, Sađ Dal Blođu
I18	EVK, Çok Sayıda Füzyon Atımı
I19	Ventriküler Trigemini, EVK
I20	Ventriküler Çift, Füzyon Atımları, Atriyal Erken Kasılma, Atriyal Çift,
I21	EVK, Atriyal Erken Kasılma, Atriyum Çift, Bloke Atriyal Erken Kasılma
I22	Paroksizmal Ventriküler Taşikardi, Atriyal Erken Kasılma, Atriyal Çift,
I23	Polimorfik EVK, İntraventriküler Blok
I24	ST Çökmesi, EVK
I25	Paroksizmal Ventriküler Taşikardi
I26	Ventriküler Çift, Paroksizmal Supraventriküler Taşikardi
I27	Ventriküler Bigemini, Trigeminy, EVK
I28	Bradikardi üzerinde EVK

Tablo 2.1'in devamı

I29	EVK, Çift, Paroksizmal Ventriküler Taşikardi, Gürültü
I30	Ventriküler Taşikardi
I31	Paroksizmal Ventriküler Taşikardi, Başlangıç Sapması
I32	Ventriküler Bigemini
I33	EVK, Supraventriküler-Ventriküler Ektopik Atımlar, Supraventriküler Çift
I34	Supraventriküler-Ventriküler Ektopik Atımlar, Çiftler, Paroksizmal Supraventriküler Taşikardi
I35	Ventriküler Çift, Taşikardi Füzyon Atımı
I36	EVK, Bigemini Olarak Ventriküler Çift
I37	Bradikardi üzerinde EVK
I38	Taşikardi Üzerinde EVK, Çift, Üçüz
I39	Bradikardi Üzerinde EVK ve Çift
I40	EVK, Ventriküler Bigemini, ST Değişimi
I41	EVK, Sinüs Aritmi, Gürültü
I42	EVK, Ventriküler Çift ve Bigemini, Paroksizmal Supraventriküler Taşikardi
I43	EVK, Ventriküler Çift ve Bigemini, Paroksizmal Supraventriküler Taşikardi, Ventriküler Ritim
I44	EVK, Paroksizmal Supraventriküler Taşikardi
I45	Ventriküler Çift
I46	Taşikardi Üzerinde EVK, Füzyon Atımları
I47	Sinüs Aritmisi, Ventriküler Bigemini Üzerine EVK
I48	EVK, Ventriküler Çift
I49	Bradikardi, Atrial Fibrilasyon Üzerine EVK
I50	EVK, Taşikardi, Atrial Fibrilasyon, ST Düşümü
I51	Taşikardi, Bigemini, Trigemini Üzerine EVK
I52	Bradikardi, Ventriküler Bigemini Üzerine EVK
I53	EVK, Ventriküler Çift, R-On-T
I54	EVK, Ventriküler Çift, Paroksizmal Supraventriküler Taşikardi, Gürültü
I55	Paroksizmal Supraventriküler Taşikardi
I56	EVK, Konumsal Form ve Kalp Atış Oranı Değişimi

Tablo 2.1'in devamı

I57	Füzyon Atımları, Taşikardi Üzerindeki Ventriküler Çift
I58	Bradikardi üzerinde EVK
I59	EVK, Ventriküler Çift, ST Yükselmesi
I60	ST Yükselmesi
I61	Konumsal Değişiklikler, Bradikardi
I62	Ventriküler Ritim, ST Yükselmesi
I63	EVK
I64	EVK, negatif T
I65	EVK, Çiftler, Paroksizmal Supraventriküler Taşikardi, Taşikardi Füzyon Atımları
I66	Paroksizmal Supraventriküler Taşikardi, Gürültü
I67	Paroksizmal Supraventriküler Taşikardi Üzerinde Taşikardi
I68	EVK, Wolff Parkinson White
I69	Bradikardi, Wolff Parkinson White Üzerinde EVK ve Ventriküler Çift
I70	Geniş QRS, Wolff Parkinson White ile Supraventriküler Ve Ventriküler Ektopik Atımlar
I71	Paroksizmal Atriyal Fibrilasyon, Wolff Parkinson White, Demet Dal Blokları
I72	Taşikardi üzerine EVK ve Çiftler
I73	Bradikardi, Supraventriküler ve Ventriküler Ektopik Atımlar, Çiftler üzerinde EVK
I74	Taşikardi Üzerinde Çok Sayıda Füzyon Atımı ve EVK
I75	Bradikardi üzerinde EVK ve Paroksizmal Supraventriküler Taşikardi

Bu veri tabanında hastalara verilen teşhisleri şu şekilde belirtebiliriz. İki hastada akut miyokard infarktüsü, beş hastada geçici iskemik atak (angina pectoris), dört hastada erken miyokard enfarktüsü, yedi hastada hipertansiyonlu koroner arter hastalığı (dört hastanın EKG'si sol ventrikül hipertrofisi ile uyumludur), bir hastada sinüs düğümü disfonksiyonu, onsekiz hastada supraventriküler ektopi, üç hastada atriyal fibrilasyon veya supraventriküler taşikardi, ikisi paroksizmal atriyal fibrilasyon, iki hastada wolff parkinson white sendromu, bir hastada Av bloğu, üç hastada dal bloğu tespit edilmiştir.

Birinci hastada (I01 ve I02 dosyaları) koroner arter hastalığı, arteriyel hipertansiyon tespit edilmiştir. İkinci hastada (I03, I04 ve I05 dosyaları) akut miyokard infarktüsü tespit edilmiştir. Üçüncü hastada (I06 ve I07 dosyaları) geçici iskemik atak tespit edilmiştir. Dördüncü hasta I08 dosyasının, beşinci hasta I09, I10 ve I11 dosyalarının ve altıncı hasta I12, I13 ve I14 dosyalarının sahibidir. Yedinci hastada (I15 dosyası) geçici iskemik atak tespit edilmiştir. Sekizinci hastada (I16 ve I17 dosyaları) geçici iskemik atak tespit edilmiştir. Dokuzuncu hasta I18 ve I19 dosyalarının sahibidir. Onuncu hastada (I20, I21 ve I22 dosyaları) koroner arter hastalığı, arteriyel hipertansiyon, sol ventrikül hipertrofisi tespit edilmiştir. Onbirinci hastada (I23 ve I24 dosyaları) erken miyokard enfarktüsü tespit edilmiştir. Onikinci hastada (I25 ve I26 dosyaları) sinüs düğümü disfonksiyonu tespit edilmiştir. Onüçüncü hasta I27 ve I28 dosyasının, ondördüncü hasta I29, I30, I31 ve I32 dosyalarının ve onbeşinci hasta I33 ve I34 dosyalarının sahibidir. Onaltıncı hastada (I35, I36 ve I37 dosyaları) koroner arter hastalığı, arteriyel hipertansiyon, sol ventrikül hipertrofisi tespit edilmiştir. Onyedinci hastada (I38 ve I39 dosyaları) koroner arter hastalığı, arteriyel hipertansiyon tespit edilmiştir. Onsekizinci hastada (I40 ve I41 dosyaları) geçici iskemik atak tespit edilmiştir. Ondokuzuncu hasta I42 ve I43 dosyalarının sahibidir. Yirminci hastada (I44, I45 ve I46 dosyaları) koroner arter hastalığı, arteriyel hipertansiyon, sol ventrikül hipertrofisi tespit edilmiştir. Yirmibirinci hastada (I47 ve I48 dosyaları) erken miyokard enfarktüsü tespit edilmiştir. Yirmiikinci hasta I49 ve I50 dosyalarının ve yirmiüçüncü hasta I51, I52 ve I53 dosyalarının sahibidir. Yirmidördüncü hastada (I54, I55 ve I56 dosyaları) erken miyokard enfarktüsü tespit edilmiştir. Yirmibeşinci hastada (I57 ve I58 dosyaları) koroner arter hastalığı, arteriyel hipertansiyon tespit edilmiştir. Yirmialtıncı hasta I59, I60 ve I61 dosyalarının sahibidir. Yirmiyedinci hastada (I62, I63 ve I64 dosyaları) akut miyokard infarktüsü tespit edilmiştir. Yirmisekizinci hasta I65, I66 ve I67 dosyalarının, yirmidokuzuncu hasta I68 ve I69 dosyalarının ve otuzuncu hasta I70 ve I71 dosyalarının sahibidir. Otuzbirinci hastada (I72 ve I73 dosyaları) koroner arter hastalığı, arteriyel hipertansiyon, sol ventrikül hipertrofisi tespit edilmiştir. Otuzikinci hastada (I74 ve I75 dosyaları) erken miyokard enfarktüsü tespit edilmiştir. Sınıflara ait kodlar normal, N (152270 adet), erken ventriküler kasılma, V (21049 adet), atriyal prematüre atım, A (2187 adet), ventriküler ve normal atım füzyonu, F (217 adet), sağ dal bloğu atımı, R (15 adet), dal bloğu atımı, B (10 adet), supraventriküler prematür veya ektopik atım (atriyal veya nodal), S (16 adet), nodal (birleşim) kaçış ritmi, j (41 adet), sınıflandırılmaz vuruşlar, Q (9 adet) ve T ise RR aralıkları (177812 adet) şeklindedir ve Tablo 2.2'de verilmiştir.

Tablo 2.2. Dosyalarda Bulunan Değişik Aritmi Sayıları.

	T	N1	V2	A3	F4	R5	B6	S7	Q8	j9
I01	2757	2413	344	0	0	0	0	0	0	0
I02	2674	2445	229	0	0	0	0	0	0	0
I03	2451	2324	125	3	0	0	0	0	0	0
I04	2423	2270	120	16	17	0	0	0	0	0
I05	1776	1520	247	0	9	0	0	0	0	0
I06	2493	2436	9	48	0	0	0	0	0	0
I07	2706	2640	1	65	0	0	0	0	0	0
I08	2131	1777	0	351	2	0	0	0	1	0
I09	2997	2956	41	0	0	0	0	0	0	0
I10	3682	3599	83	0	0	0	0	0	0	0
I11	2106	2102	4	0	0	0	0	0	0	0
I12	2809	2800	6	1	2	0	0	0	0	0
I13	2023	1793	230	0	0	0	0	0	0	0
I14	1866	1802	64	0	0	0	0	0	0	0
I15	2635	2632	3	0	0	0	0	0	0	0
I16	2494	1803	683	8	0	0	0	0	0	0
I17	1672	1645	27	0	0	0	0	0	0	0
I18	3084	2662	366	0	56	0	0	0	0	0
I19	2063	1212	850	0	0	0	1	0	0	0
I20	2652	2361	111	179	1	0	0	0	0	0
I21	2184	2072	8	104	0	0	0	0	0	0
I22	3126	2816	185	124	1	0	0	0	0	0
I23	2205	192	13	0	0	0	0	0	0	0
I24	2571	2565	6	0	0	0	0	0	0	0
I25	1712	1705	5	2	0	0	0	0	0	0
I26	1509	1498	4	5	0	0	0	2	0	0
I27	2605	1885	720	0	0	0	0	0	0	0
I28	1717	1713	4	0	0	0	0	0	0	0

Tablo 2.2'in devamı

I29	2757	2413	344	0	0	0	0	0	0	0
I30	2462	1706	756	0	0	0	0	0	0	0
I31	2494	1803	683	8	0	0	0	0	0	0
I32	1619	1562	57	0	0	0	0	0	0	0
I33	1837	1245	1	591	0	0	0	0	0	0
I34	1965	1429	0	536	0	0	0	0	0	0
I35	3675	3200	457	0	18	0	0	0	0	0
I36	3911	3449	450	0	12	0	0	0	0	0
I37	2461	2009	452	0	0	0	0	0	0	0
I38	2699	2153	545	0	0	0	0	0	1	0
I39	1775	1462	313	0	0	0	0	0	0	0
I40	2666	2568	92	6	0	0	0	0	0	0
I41	1630	1624	1	5	0	0	0	0	0	0
I42	3109	1546	1554	0	9	0	0	0	0	0
I43	2209	1087	1120	0	2	0	0	0	0	0
I44	1928	1437	491	0	0	0	0	0	0	0
I45	1972	1479	478	0	0	0	9	0	7	0
I46	2658	2232	422	1	3	0	0	0	0	0
I47	1953	1859	93	1	0	0	0	0	0	0
I48	2357	2119	237	1	0	0	0	0	0	0
I49	2147	2120	27	0	0	0	0	0	0	0
I50	2998	2994	4	0	0	0	0	0	0	0
I51	2777	1970	803	3	1	0	0	0	0	0
I52	1747	1610	137	0	0	0	0	0	0	0
I53	2262	1151	1111	0	0	0	0	0	0	0
I54	2363	2340	22	1	0	0	0	0	0	0
I55	2166	2148	17	1	0	0	0	0	0	0
I56	1705	1672	7	26	0	0	0	0	0	0
I57	2757	2413	344	0	0	0	0	0	0	0
I58	2325	2313	12	0	0	0	0	0	0	0

Tablo 2.2'in devamı

I59	2148	2026	81	0	0	0	0	0	0	41
I60	2757	2413	344	0	0	0	0	0	0	0
I61	2494	1803	683	8	0	0	0	0	0	0
I62	2269	1453	795	5	12	0	0	4	0	0
I63	1994	1847	138	0	8	0	0	1	0	0
I64	1913	1887	23	0	3	0	0	0	0	0
I65	2664	2273	382	2	4	0	0	3	0	0
I66	2340	2139	200	0	0	0	0	1	0	0
I67	2975	2438	531	0	1	0	0	5	0	0
I68	2644	2481	161	2	0	0	0	0	0	0
I69	2168	1999	167	1	1	0	0	0	0	0
I70	2494	1803	683	8	0	0	0	0	0	0
I71	1677	1627	0	35	0	15	0	0	0	0
I72	2269	1875	386	8	0	0	0	0	0	0
I73	1992	1890	70	32	0	0	0	0	0	0
I74	2404	2082	274	0	48	0	0	0	0	0
I75	2103	1483	613	0	7	0	0	0	0	0

2.4.2. Doğruluk, Hassaslık ve Özgünlük

Bu çalışmanın performans hesaplamalarında doğruluk, hassaslık ve özgünlük değerlerinden yararlanılmıştır. Doğruluk, hassaslık ve özgünlük tanımıyla beraber genel olarak bilinen birkaç ifade vardır. Bu ifadeler gerçek negatif (true negative,TN), gerçek pozitif (true positive,TP), yanlış pozitif (false positive,FP) ve yanlış negatif (false negative,FN) olarak bilinmektedir. Eğer sinyalimizde var olan bozukluk kanıtlanmışsa, o zaman verilen sonuç var olan bozukluğun varlığını göstermektedir, test sonucu ise gerçek pozitif ifade edilir. Benzer olarak bozukluğun sinyalimizin yapısında bulunmadığı kanıtlanırsa, sonuç da bu bozukluğun var olmadığı göstermektedir, test sonucu bu durumda gerçek negatiftir. Eğer ki, bozukluk olmayan sinyalimizde bozukluğun varlığını görünüyorsa, test sonucu bu durumda yanlış pozitifdir. Son olarak ise, bozukluk olan sinyalimizde bozukluğun olmadığını gösteriyorsa, test sonucu bu durumda yanlış negatiftir. Hem gerçek negatif hem de gerçek pozitif, test ile kanıtladığımız durum arasındaki tutarlı

bir sonucun olduğunu düşündürmektedir. Fakat yanlış negatif ve yanlış pozitif test sonuçlarımızın gerçek durumun tersi olduğuna ifade eder. Hassaslık, testle doğru olarak ifade edilen gerçek pozitiflerimizin oranı olarak açıklanabilir. Hassaslık, bozukluğun bulunmasında testin ne kadar başarılı olduğunu göstermektedir, diğer deyişle testimizin doğru tespit edebilme yeteneğini gösterir. Özgünlük, gerçek negatifler için doğru şekilde tanısal bir testle tanımladığımız orandır. Özgünlük, testimizin bozukluk bulunmayan durumlar için doğru tespit etme yeteneğiyle ilişkilidir, diğer bir ifadeyle testin normal durumu tanımada ne kadar başarılı olduğunu ifade etmektedir. Doğruluk, gerçek sonuçlarımızın yani gerçek negatif veya gerçek pozitif değerlerimizin toplam değerlere olan oranıdır. Tanı testimizin doğruluğunu ölçmektedir. Doğruluk, sistematik hatalarımızın tarifi, istatistiksel bir önyargı ölçütü olarak ifade edilebilir (Tomak ve Kayıkçıoğlu, 2017). Doğruluk, özgünlük ve de hassaslık ifadelerimizin matematiksel olarak ifadesi Denklem 2.57-59'da verilmektedir.

$$\text{Hassaslık} = \frac{TP}{TP+FN} \quad (2.57)$$

$$\text{Özgünlük} = \frac{TN}{TN+FP} \quad (2.58)$$

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+FN+TN} \quad (2.59)$$

TP=Gerçek Pozitif, FP=Yanlış Pozitif, TN=Gerçek Negatif, FN=Yanlış Negatif.

2.5.Gerçek Zamanlı Aritmi Tespiti

Bu süreçte oluşturulan yöntem, gerçek zamanlı aritmi algılama için tasarlanmış bir simulink modelidir. Giriş bloğu, MATLAB .mat formatında önceden kaydedilmiş bir dosyayı seçmek için kullanıcı dostu bir arayüz olacak şekilde tasarlanmıştır. Bu aşamada, sadece önceden kaydedilmiş dosyalar ile çalışmaktadır, ancak kullanılabilir olduklarında harici cihazlarla çalışmak için kolayca adapte edilebilir. Sistem söz konusu verilerin örnek dosyalarda olduğu gibi bir val dizisi olduğu bir MATLAB .mat dosyası formatını bekler. Bloğun geri dönüşleri onu Simulink harici değişken giriş blokları tarafından tercih edilen bir zaman dizisi nesnesine dönüştürür. Filtreler, yüksek geçiren ve alçak geçiren olarak

tanımlanan iki Butterworth filtresidir. Filtrelerin çıktısı orijinal verilerle scope üzerinde karşılaştırılabilir. Öznitelik çıkarma algoritmaları, aynı anda tüm veri penceresinde çalışır. Bu nedenle, girişinin son 0,7 saniyesini bir vektör olarak çıkararak bir gecikme bloğu kullanıyoruz. Kullanıcı, giriş bloğundaki örnek sayısını değiştirdiğinde ve program çalıştırıldığında blokta görüntülenen örnek sayısını güncellenir.

Kullandığımız öznitelikler P-P aralığı, ortalama, standart sapma, çarpıklık, Q ile S arasındaki mesafe, Q ile R arasındaki eğim, R ile S arasındaki eğim, Q'dan S'ye varyans şeklindeki morfolojik özniteliklerdir. Öznitelik çıkarma, herhangi bir giriş sinyali penceresinde düzgün çalışmayabilir. Ayrıca, hesaplama süreci bilgisayar kaynaklarını zorlayabilir. Bu yüzden kalp atışı başına sadece bir kez hesaplanmasının istenmesi tercih edilir. Basitlik ve güvenilirlik için model bunun yerine R zirvesinin yakınında birkaç nokta alır. Kalp atışlarının çok hızlı hale gelmesi ve iki R zirvesinin bir pencerede olması durumuyla sonuçlanabilir. İki paralel çizgi vardır: mevcut pencerenin MinMax bloğu ile maksimum değerini hesaplar ve 0,3 saniye önce mevcut olan filtrelenmiş sinyalin değerini tutar. Bu son değer, pencerenin maksimumunun 0.9'un altına düştüğünde (İlişkisel Operatör bloğu tarafından belirlendiği gibi), model bir zirveye ulaştığımızı ve hesaplamalar yapmamız gerektiğini varsayar. Pencerenin maksimum değeri (0.9 ile çarpılır) Scope1 kapsamında görülebilir. Filtreler başlangıçta garip çıktılar verebilir (pencereleri uygun değerlerle doldurulmadan önce), bu yüzden sadece ikinci saniye bittikten sonra hesaplama yapılması tercih edilir.

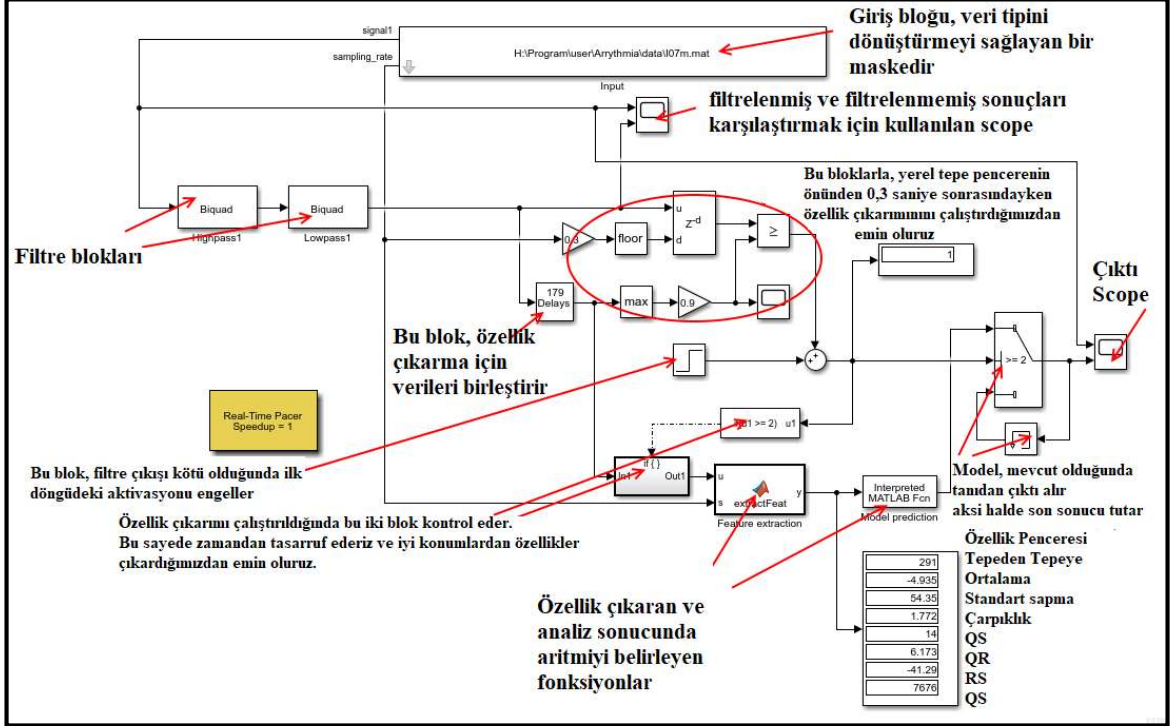
Bunu kolaylaştırmak için, sadece 1 saniye geçtikten sonra "1" e geçiş yapan bir adım fonksiyonumuz vardır. Çıktısı, ilişkisel operatörün çıktısına eklenir. Toplam, izleme için ekranda görüntülenir. Bir "If" bloğu, toplamın 2 ya da daha fazla olup olmadığını kontrol eder (yani, her iki ilişkisel operatör bloğu ve adım fonksiyonunun, hesaplamaların başlatılmasında aynı fikirde olduğu anlamına gelir). Bu olduğunda, toplu veri öznitelik çıkarma bloğuna geçirilir. Aynı anda, "Switch1" anahtar bloğu, tanılama bloğundan gelen verileri kabul etmeye hazır hale gelir. Bir kapsamı doğrudan analiz yoluna eklemenin, eğer if bloğunu göz ardı etmesine ve eğer eylemi engellerse ve her adımda yerine getirerek performansın önemli ölçüde düşmesine neden olabileceği gözönünde bulundurulmalıdır. öznitelik çıkarımı aşaması bu tezin önceki morfolojik öznitelik çıkarımı gibidir ancak bazı farklar mevcuttur. Smooth fonksiyonu, eşdeğer bir Sgolay filtresiyle değiştirildi. Diff fonksiyonu manuel fark hesaplaması ile değiştirildi. Çıkış, sırayla tüm gerekli değerleri içeren bir y vektörüne değiştirildi, ayrıca, başlatma işleminin başlaması için gerekli olan

birkaç kontrol içermektedir. Sabit sayıda çerçeve veren tüm değerler, saniyede 257 örnek için aynı sonuçları veren yuvarlatılmış yaklaşımlarla değiştirildi. Bunun tek istisnası, düzeltme için kullanılan sgolay filtre penceresidir. QS mesafesi ve QR ve RS eğimleri, 257'lik örnekleme oranıyla elde edilen sonuçlara uyacak şekilde ölçeklendirilmiştir.

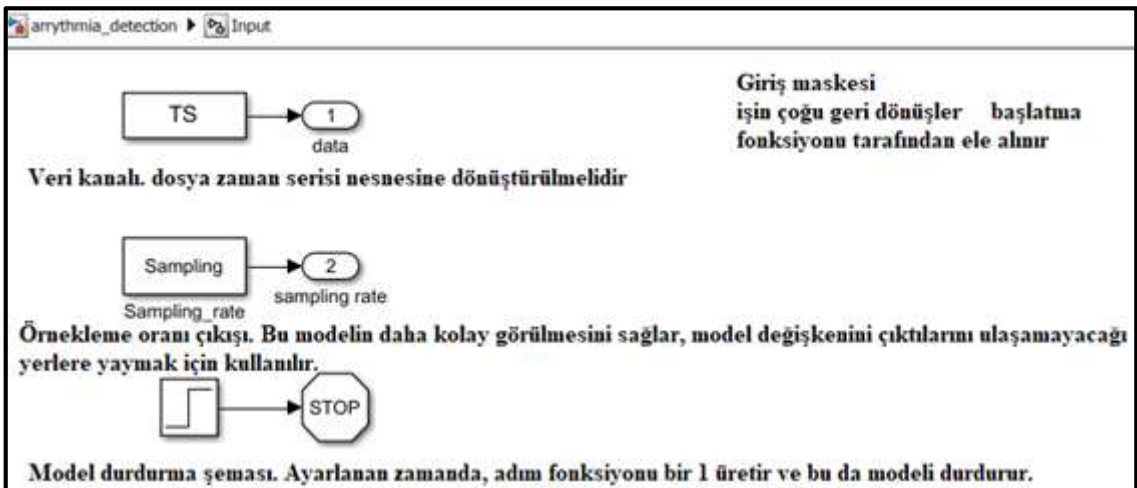
Gerçek zamanlı aritmi tespitinde geliştirilen simulink modelinde analiz, saniyede sadece birkaç örnekte gerçekleştiğinden, kullanıcının sonuçları algılamasına yardımcı olmak için sonucu bir süre tutmak gerekir. Switch1 ve Memory blokları için bellek, teşhisteki son değeri hatırlar ve her defasında mevcut duruma getirildiğinde anahtar yeni bir değer verir. Herhangi bir sonuç bulunmadan önce, bellek herhangi bir olası sonuçtan ayırt etmek için "0" değerini içerir. Son olarak, tanı ve ilk sinyal, model başlatıldığında otomatik olarak açılacak şekilde yapılandırılan "Scope2" kapsamında görüntülenir. Sistem sinyalin sadece son 10 saniyesini gösterir ve kullanıcının sinyali makul bir ölçekte görmesini sağlar. Ekran, sürüklenmeden bağımsız olarak mevcut sinyal aralığını göstermek için otomatik ölçeklendirir. Bu, kullanıcının sabit ölçek değişiklikleri ile rahatsızlık vermemesi için saniyede bir kez gerçekleşir. Gerçek zamanlı aritmi tespitinde geliştirilen simulink modeli Şekil 2. 10'de, simulink modeline ait giriş Şekil 2.11'de ve çıkış ekranı Şekil 2. 12'de verilmiştir. İlk ekrandaki EKG sinyalinden öznitelik hesaplamasına dayalı olasılıksal bir sınıfa dâhil olma durumu hesaplanır. Aritmi tespitinde ikinci ekranda bir uyarı olarak çıkış değeri birden ikiye geçer.

RealTime Pacer bloğu, gerçek geçen süreyi izlemek için simülasyon zamanını yavaşlatır. Yavaşlama derecesi, Speedup parametresi üzerinden kontrol edilebilir. Bu bloğu kullanmak için, modelinizin herhangi bir yerinde (en üst düzeyde olması gerekmez) kopyalamak yeterlidir (URL-2, 2018). Blok, gerçek zamana uymasını sağlamak için bir simülasyonu yavaşlatmaya dayanır. Modelin çok fazla hesaplama gerektiriyorsa, 1 saniyelik simülasyon süresinin 1 saniyeden daha uzun sürmesi gerekirse, bu bloğun herhangi bir etkisi olmaz. Bizim çalışmamız oldukça hızlı sonuçlar verdiği için bu bloğun kullanılmasında bir sorun yaşanmamaktadır. Blok simülasyonu yavaşlatmak için MATLAB PAUSE fonksiyonunu kullanır. PAUSE komutu duraklatma sırasında işlemciden vazgeçer, bu nedenle sistem performansı düşmez. Simülasyon zamanı ile geçen gerçek zaman arasındaki eşleşme yaklaşık 10 ila 30 milisaniye arasında beklenen farklılıklar ile yaklaşık değerlerdir. Bu sınırlama, çok görevli bir işletim sistemi ile hassas zamanlamanın zorluklarından kaynaklanmaktadır. Speedup, simülasyon zamanı ve gerçek zaman arasındaki oranı belirler. Hızlanma sıfırdan büyük herhangi bir gerçek değer olabilir. 1'den küçük bir değer, gerçek

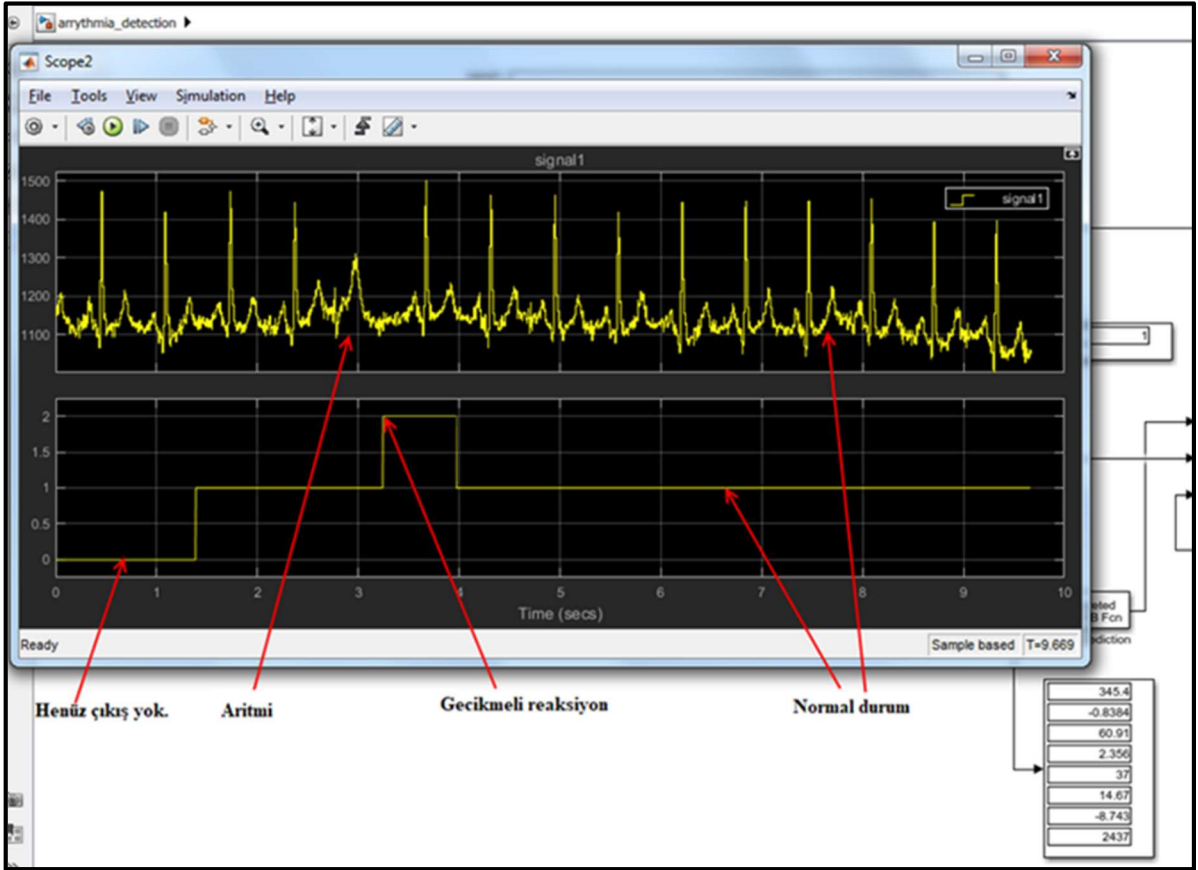
geçen sürenin, simülasyon süresinden daha büyük olmasını zorlar. Örneğin, 0.5'lik bir hızlanma ile, 1 saniyelik simülasyon süresi gerçek zamanda 2 saniye alır. $Speedup = N$ ise, N saniye simülasyon süresinin gerçek zamanın bir saniyesine karşılık geldiğini belirtir. $Speedup = \infty$ ise, benzetimin normal hızda, tam hızda çalışması gerektiğini belirtir.



Şekil 2.10. Gerçek zamanlı aritmi tespitinde geliştirilen simulink modeli.



Şekil 2.11. Simulink modeline ait giriş.



Şekil 2.12. Gerçek zamanlı aritmi tespitinde çıkış ekranı.

3.BULGULAR

Kronik hastalık sayısı artan ölüm yaşına bağlı olarak artmakta ve bunun sonucu olarak ülkelerin sağlık için harcaması gereken parada artmaktadır. Ayrıca insanlar da sosyal ve ekonomik açıdan derinden etkilenmektedir. Tele-tıp teknolojisini kullanarak özellikle kronik hastalıklara ait harcamalarda azalma, kaliteli ve hızlı bir şekilde sağlık servislerine erişim sağlanabilir. Bu teknolojiyi kullanarak hasta günlük hayatına ait aktivitelere devam ederken, hastanın rahatsızlığını teşhis edilebilmek mümkün olmaktadır. Böylece erken tedavi edilmesi ve hastalığın ilerlemesiyle kişiye vereceği zararın önüne geçilmesi sağlanacaktır. Kalp hastalarının uzaktan takibinde ve kişiye ait hastalık bilgilerine kısa zamanda ulaşılmasında tele-tıp teknolojisinin kullanımı yaygınlaşmaktadır. Hastalığın teşhisinin daha doğru ve hızlı yapılabilmesi için oluşturulmuş makine öğrenmesi temelli bilgisayar uygulamaları Klinik-Karar Destek Sistemleri olarak bilinmektedir (Shibl vd., 2013). Uygun bir sistem tasarlayabilmek için pek çok öznitelik ve sınıflandırma yöntemi inceleyerek bir karar vermemiz gerekmektedir.

3.1. Dalgacık Katsayıları Kullanılarak Yapılan Analizin Sonuçları

EKG sinyallerinden gelen öznitelikleri doğru bir şekilde çıkarmak için, farklı çözünürlüklerde veya ölçeklerde sinyalleri işlemek için DD'ünden yararlandık. Fourier dönüşümüyle sinyalde var olan frekansların tümü belirlenebilir, yüksek frekansda çözünürlüğe sahiptir fakat bu frekansların ne zamanda var olduğuna ilişkin bir zaman bilgisi yoktur. Bu durumdan dolayı geçici durum analizinde istenilen sonuçları vermemektedir. Shannon dönüşümünde yüksek zaman çözünürlüğü vardır, ancak frekans çözünürlüğü bulunmamaktadır. Kısa zamanlı Fourier dönüşümü belirli zaman penceresinde uygulanmaktadır. Bundan dolayı dalgacık dönüşümü kullanıldı. Araştırmanın bu aşamasının önemini çeşitli aşamalarla ifade edersek, ilk olarak, St. Petersburg Kardiyoloji Teknik Enstitüsü 12 kanallı aritmi veri tabanından veri kullanıldı ve bu sinyaller dalgacık yöntemiyle sıkıştırıldı. Çoğu araştırma 48 adet yarım saatlik, iki kanallı EKG kayıtlarını içeren MIT-BIH aritmi veri tabanını kullanmaktadır. Fakat biz çalışmamızda, 30 dakika süren 75 açıklanmalı kayıt içeren St. Petersburg Kardiyoloji Tekniği Enstitüsü'nün 12 kanallı aritmi veri tabanından toplanan EKG sinyallerini kullandık. Her kayıt 257 Hz'de örneklenir.

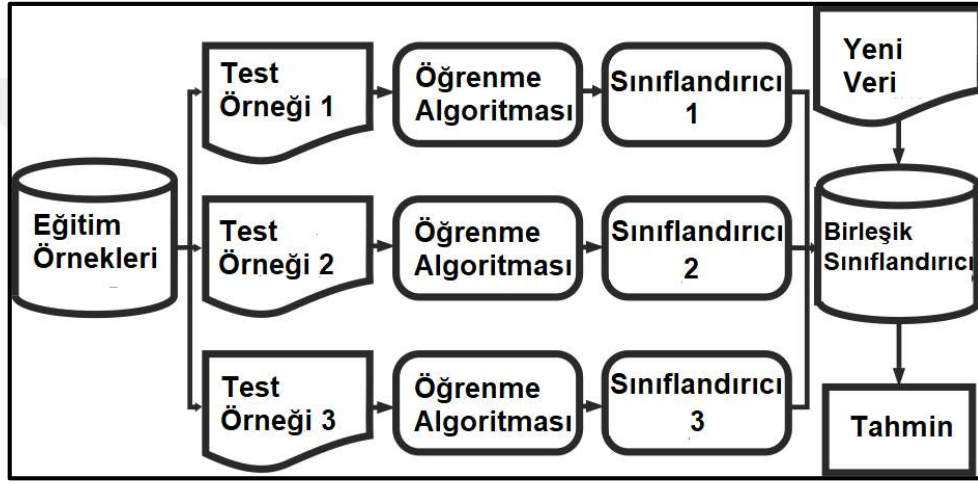
Bu dosyalar iskemiye, iletim anormalliklerine, koroner arter hastalığına ve aritmilere uygun EKG'leri olan hastalara (15 kadın ve 17 erkek, 18-80 yaş arası hastalar) ait verileri içerir (Goldberger vd., 2000). Bu veri tabanını seçmemizin ilk sebebi 12 kanal kaydı içermesidir. MIT-BIH aritmi veri tabanı sadece iki kanallı kayıtları içerir. 12 kanallı EKG kayıtları, kalbin elektriksel aktivitesini 12 farklı perspektiften görmemizi sağlıyor. Bu veri tabanını seçmenin bir diğer nedeni büyük bir veri tabanı olmasıdır. Metodumuzu daha büyük bir veri tabanında test etmek sonuçlarımızı daha güvenilir kılacaktır. Ayrıca bu veri tabanındaki EKG'ler iskemi, iletim anormallikleri, koroner arter hastalığı ve aritmiler ile tutarlıdır. Ek olarak bu veri tabanının MIT-BIH aritmi veri tabanı ile karşılaştırıldığında daha yeni olduğu unutulmamalıdır. Bu, hastalık geçmişinin güncel olduğu anlamına gelir.

Bu analizde dalgacık katsayılarını hesaplarken iki küçük pencere kullanıldı. Her bir kayıt için, R tepe noktasının her iki tarafından 60 örnek alındı. Toplam 120 örnekle sonuçlanan iki pencere kullandık. Bu kullanım, öznitelik çıkarma için yalnızca bir pencere kullanma eğiliminde olan çoğu araştırmadan farklıdır. Bu araştırmada öznitelik sayısı önemli ölçüde azaltıldı. Bu azaltma, sınıflandırma üzerinde en önemli etkiye sahip olan katsayıların belirlenmesi ve TBA kullanımıyla elde edildi. Sınıflandırma için tüm dalgacık katsayılarını kullanmamaya karar verdik. Sınıflandırma üzerinde en önemli etkiye sahip olan katsayılar seçildi ve öznitelik olarak kullanıldı. Daha az katsayı ile daha hızlı sınıflandırmak mümkündür.

Bu analizde değişik sınıflandırma yöntemleri karşılaştırıldı. Kullanabileceğimiz en iyi sınıflandırıcıyı belirlemek için temel sınıflandırma yöntemlerini ve derin öğrenme algoritmalarını kullandık. Veriler harmanlandı ve verilerin yarısı eğitim için diğer yarısı da test için kullanıldı. Araştırmamızda, sınıflandırma için dokuz sınıf belirledik. Bu sınıflar şu şekildedir: normal (sağlıklı), erken ventriküler kasılma, atriyal prematüre atım, ventriküler ve normal atım füzyonu, sağ dal bloğu atımı, dal bloğu atımı (belirtilmemiş), supraventriküler prematür veya ektopik atım (atriyal veya düğüm), düğüm (birleşim) kaçış ritmi ve sınıflandırılmaz vuruşlar. Classification Learner sıklıkla kullanıldı, ancak bazen MATLAB fonksiyonları tercih edildi. Sonuçta eğitim doğruluğu, test sürecinde ise doğruluk, hassaslık ve özgünlük değerleri belirlendi.

Temel sınıflandırma yöntemleri arasında en başarılı olan Bagged Trees (Torbalama Karar Ağaçları) tekniğiydi. Torbalama Karar Ağaçları metodunun blok diyagramı Şekil 3.1'de verilmiştir (Breiman, 1996). Torbalama Karar Ağaçları için topluluk yöntemi Bag olarak seçilmiştir. Öğrenme tipi karar ağacıdır ve yorumlanması kolaydır. Ayrıca hafıza kullanımı

da düşüktür. Öğrenenlerin sayısı 30 ve maksimum bölünme sayısı 20 olarak belirlendi. Eğitim veri setine on kat çapraz doğrulama uygulandı. Bu, verilerin on set halinde bölündüğü anlamına gelmektedir. Dokuz veri kümesi eğitim aşamasında kullanıldı. Ve test için de kalan veri kümesi kullanıldı. İşlem on defa tekrarlandı ve ortalama doğruluk alındı. Bu çapraz doğrulama yöntemi, verileri aşırı eşleştirmeye (overfitting) karşı korur. Aşırı eşleştirme durumunda belirli bir veri kümesine çok yakın veya tam olarak karşılık gelen bir analizin üretilir ve bu nedenle ek verilere uymaması veya gelecekteki gözlemlerin güvenilir şekilde tahmin edilememesi söz konusu olabilir.



Şekil 3.1. Torbalama Karar Ağaçları metodunun blok diyagramı.

Seçilen topluluk metodu AdaBoost olarak belirlendi. Öğrenici tipi olarak karar ağacı seçildi. Maksimum bölünme sayısı 20'ye ayarlandı. Öğrenenlerin sayısı 30 olarak belirlendi ve öğrenme oranında 0.1'e ayarlandı. Altuzay Ayırımı için, seçilen topluluk yöntemi alt uzaydır ve öğrenici tipi olarak diskriminant seçilmiştir. Öğrenicilerin sayısı 30'a ayarlandı ve altuzay boyutu 2 olarak belirlendi. Altuzay K-EYK için seçilen topluluk metodu altuzaydır ve öğrenici tipi olarak K-EYK seçildi. Öğrenicilerin sayısı 30'a ayarlandı ve altuzay boyutu 2 olarak belirlendi. RUSGeliştirilmiş Ağaçlar için seçilen topluluk yöntemi RUSBoost'dur ve öğrenici tipi olarak karar ağacı seçilmiştir. Maksimum bölünme sayısı 20'ye ayarlandı, öğrenici sayısı 30 ve öğrenme oranı 0.1 olarak belirlendi. Mesafe temelli sınıflandırmanın etkili ve basit bir yöntem olmasından dolayı K-EYK sınıflandırma yöntemleri de incelendi. Mesafe metriği olarak Öklid Mesafesi seçilmiştir. Hassas K-EYK için komşu sayısını 1, Orta Seviye K-EYK, Kosinüs K-EYK, Kübik K-EYK ve Ağırlıklı K-EYK için 10; ve Yüzeysel

K-EYK için 100 olarak belirlendi. Basitliğinden dolayı eşit ağırlıklandırma fonksiyonunu mesafe ağırlık fonksiyonu olarak seçtik. Her bir koordinat mesafesini ölçeklendirmek, karar vermemiz gereken başka bir özneliktir. Araştırmamız için verileri standartlaştırmayı seçtik. Verileri ayrıştırmak için en uygun hiperdüzeyi (sınıfların arasındaki en büyük mesafeyi bulan) bularak sınıflandırma yapan DVM'lerini test ettik. Kutu kısıtlama seviyesini tanımlayarak, sınırlı bölgede Lagrange çarpanlarını tutabiliyoruz. Kutu sınırlama seviyesini 1 olarak belirledik. Çekirdek ölçeğini Doğrusal, Kuadratik ve Kübik DVM için otomatik olarak belirlendi. Çekirdek ölçeği Hassas Gauss, Orta Seviye Gauss ve Yüzeysel Gauss DVM için Gauss olarak belirlendi. Karar ağaçları düşük bellek kullanımı ve kolay yorumlanabilirliği nedeniyle tercih edilir. Bölünme kistası Gini çeşitlilik endeksi olarak belirlendi. Derinliği denetlemek için maksimum bölünme değerini kullanırız. Maksimum bölünme değeri basit karar ağaç algoritması için 4 olarak belirlendi. 12 kanallı ve 30 dakika uzunluğundaki sinyal için hesaplanan ortalama boyut 11.102.424 bayt (10,6 MB) olarak bulundu. Sıkıştırılmadan sonraki sinyalin birinci kanal ortalama boyut değeri 95.121 bayt (92,9 KB) olarak bulundu. Böylece dosya boyutunun ihtiyaç duyduğu hafıza miktarının oldukça düştüğünü söyleyebiliriz. Ayrıca, 30 dakika uzunluğundaki sinyalin sıkıştırılması için 2.23 s'ye ihtiyaç duyulmuştur. TBA'nın kullanımı ve sınıflandırılma üzerinde en önemli etkiye sahip olan katsayılar karar vermek suretiyle öznelik sayısı 6'ya düşürülmüştür. Sistemimiz, eğitim için % 98.6 doğruluk, test için % 97.8 doğruluk, % 87.4 hassaslık ve % 99,7 özgünlük elde etti (ortalama değerler) oranının elde edildiğini söyleyebiliriz, Db6 dalgacık 5. Seviye sıkıştırılmış sinyalleri kullandığımızda elde ettiğimiz katsayılar kullanıldığında bulunan sonuçlar Tablo 3.3'de verilmiştir. Torbalama Karar Ağaçlar sınıflandırması kullanılarak 12 kanal kayıttan elde edilen sonuçlar Tablo 3.4'de verilmiştir.

Basit bir KSA yapısında, sinyaller bir dizi katmandan geçmektedir. Sisteme giriş katmanından (Input Layer) veri verilmektedir. Giriş katmanı sistemin ilk katmanıdır. Konvolüsyon katmanında bir dizi filtre kullanılır ve her filtre sinyal ile konvolüsyon işlemine tâbi tutulur. Yani filtreler sinyal boyunca kaydırılarak, sinyalin değerlerini filtredeki değerlerle çarpılır ve elde ettiğimiz değerler toplanır ve net sonucumuzu buluruz. Bu işlemi sinyalin tümüne uyguladığımızda, elimizde yeni bir sinyal olur. Böylece aktivasyon haritasını elde etmiş oluruz. ReDB katmanı, bir rampa fonksiyonu olan bir aktivasyon fonksiyonudur ve konvolüsyon katmanından sonraki katmandır. Bu katman negatif giriş değerlerini sıfır olarak düzeltir. Ağın doğrusal olmayan öznelikleri bu katmanda artmaktadır ve sistem bu tabakanın kullanımı ile daha hızlı öğrenmektedir.

Havuzlama katmanı genellikle ReDB tabakasından sonra yerleştirilir. Havuzlama katmanının ana amacı, bir sonraki dönüşüm katmanının giriş boyutunu düşürmektir. Ağın ezberlemesini engeller ve takip eden ağ katmanlarının hesaplama yükünü azaltır. Bu katmanda, sinyal tanımlanmış bir adım değerini kullanarak bir filtreden geçirilir ve değerlerin maksimum veya ortalamaları alınarak işlenir. Tamamen bağlanmış katmanda, bir katmandaki her bir nöron başka bir katmandaki başka bir nörona bağlıdır. Dropout Katmanının temel amacı, ağın belli birkaç düğümünü kaldırmaktır. Böylece ağın ezberlemesi engellenebilir. Bundan sonra sınıflandırıcı seçimi yapılır. Genellikle bu katmanda softmax sınıflandırıcı kullanılmaktadır. KSA genellikle resim sınıflandırılmasında kullanıldığından sistemde genellikle 2 boyutlu matrisler kullanılmaktadır. Çekirdeğin zaman serisi boyunca ilerlemesini istiyoruz, ancak resimler için kullanacağımız ikinci boyut boyunca ilerlememesi için adım argümanını kullanıyoruz. Kanal 1'in db1 ile 5. seviyesinde ayrışmasından elde edilen indirgenmiş katsayılar kullanılarak elde edilen doğruluk, hassaslık ve özgünlük sonuçları Tablo 3.1'de verilmekte ve Torbalama Karar Ağaçları aralarında en iyi performansı vermektedir. Sıkıştırılmış sinyallerde db1 kullanarak 5. seviye ayrıştırılma sonucunda bulunan katsayıları kullandığımızda elde ettiğimiz katsayılar kullanıldığında bulunan sonuçlar Tablo 3.2'de verildi.

Tablo 3. 1. Db1 kullanarak 5. seviye ayrıştırılma sonuçları.

Sınıflandırma	Eğitim	Test		
	Doğruluk	Doğruluk	Hassaslık	Özgünlük
En Yakın Komşular				
Hassas K-EYK	93.7	93.93	0.74	0.97
Orta Seviye K-EYK	93.9	94.1	0.62	0.99
Yüzeysel K-EYK	92.1	92.4	0.51	0.99
Kosinüs K-EYK	94.2	94.5	0.66	0.99
Kübik K-EYK	93.8	93.9	0.61	0.99
Ağırlıklı K-EYK	94.4	94.6	0.67	0.99
Destek Vektör Makineleri				
Hassas K-EYK	93.7	93.93	0.74	0.97
Orta Seviye K-EYK	93.9	94.1	0.62	0.99
Yüzeysel K-EYK	92.1	92.4	0.51	0.99
Kosinüs K-EYK	94.2	94.5	0.66	0.99
Kübik K-EYK	93.8	93.9	0.61	0.99
Ağırlıklı K-EYK	94.4	94.6	0.67	0.99
Topluluk Sınıflandırıcıları				
Geliştirilmiş Karar Ağaçlar	93.3	93.4	0.57	0.98
Torbalama Karar Ağaçlar	95.1	95.1	0.66	0.99
Altuzay Ayırımı	87.4	87.4	0.03	0.99
Altuzay K-EYK	94.3	94.3	0.56	0.99
RUSGeliştirilmiş Ağaçlar	84.9	85.1	0.83	0.85
Karar Ağaçları				
Basit Ağaç	88.9	89.1	0.26	0.95
Orta Seviye Ağaç	90.7	90.9	0.34	0.99
Karmaşık Ağaç	92.4	92.5	0.57	0.98
Lojistik Regresyon				
Lojistik Regresyon	88.5	88.7	0.19	0.99
Diskriminant Analiz				
Doğrusal Diskriminant	88.4	88.6	0.16	0.99
Kuadratik Diskriminant	81.9	81.8	0.29	0.90

Tablo 3. 2. Sıkıştırılmış sinyallerde Db1 kullanarak 5. seviye ayrıştırılma sonuçları.

Sınıflandırma	Eğitim	Test		
	Doğruluk	Doğruluk	Hassaslık	Özgünlük
En Yakın Komşu				
Hassas K-EYK	91.1	88.1	0.68	0.96
Orta Seviye K-EYK	92.4	90.7	0.48	0.98
Yüzeysel K-EYK	90.9	88.1	0.41	0.97
Kosinüs K-EYK	92.2	87.5	0.31	0.96
Kübik K-EYK	92.3	90.1	0.51	0.99
Ağırlıklı K-EYK	93.2	90.5	0.34	0.96
Destek Vektör Makineleri				
Doğrusal DVM	89.2	88.3	0	1
Kuadratik DVM	90.6	89.6	0.23	0.99
Kübik DVM	90.2	88.2	0	1
Hassas Gauss DVM	92.2	91.1	0.43	0.99
Orta Seviye Gauss DVM	91.6	90.8	0.44	0.99
Yüzeysel Gauss DVM	89.6	88.2	0.05	0.99
Topluluk Sınıflandırıcıları				
Geliştirilmiş Karar Ağaçlar	91.5	89.6	0.2	0.99
Torbalama Karar Ağaçlar	94.8	91.7	0.48	0.99
Altuzay Ayırımı	89.2	88.2	0	1
Altuzay K-EYK	93.1	90.5	0.36	0.98
RUSGeliştirilmiş Ağaçlar	83.8	80.2	0.56	0.90
Karar Ağaçları				
Basit Ağaç	89.6	84.1	0.02	0.98
Orta Seviye Ağaç	90.5	88.2	0.25	0.94
Karmaşık Ağaç	91.5	89.6	0.24	0.98
Lojistik Regresyon				
Lojistik Regresyon	89.2	87.2	0	1
Diskriminant Analiz				
Doğrusal Diskriminant	89.2	87.4	0.01	0.99
Kuadratik Diskriminant	81.8	80.1	0.23	0.90

Tablo 3.3. Db6 dalgacık 5. seviye sıkıştırılmış sinyallerde sulunan sonuçlar.

Sınıflandırma	Eğitim	Test		
	Doğruluk	Doğruluk	Hassaslık	Özgünlük
En Yakın Komşu				
Hassas K-EYK	94.2	93.8	0.68	0.98
Orta Seviye K-EYK	94.0	93.7	0.55	0.99
Yüzeysel K-EYK	92.5	91.8	0.39	0.99
Kosinüs K-EYK	93.8	93.1	0.50	0.99
Kübik K-EYK	93.9	93.5	0.52	0.99
Ağırlıklı K-EYK	94.8	94.4	0.60	0.99
Destek Vektör Makineleri				
Doğrusal DVM	88.1	87.5	1	0.99
Kuadratik DVM	90.9	90.1	0.27	0.99
Kübik DVM	91.5	90.9	0.40	0.98
Hassas Gauss DVM	94.5	93.9	0.54	0.99
Orta Seviye Gauss DVM	92.5	91.9	0.39	0.99
Yüzeysel Gauss DVM	88.7	88.1	0.06	0.99
Topluluk Sınıflandırıcıları				
Geliştirilmiş Karar Ağaçlar	93.2	93.0	0.51	0.99
Torbalama Karar Ağaçlar	98.9	97.8	0.87	0.99
Altuzay Ayırımı	88.9	88.1	0.09	0.99
Altuzay K-EYK	95.6	94.9	0.67	0.99
RUSGeliştirilmiş Ağaçlar	86.6	84.7	0.75	0.86
Karar Ağaçları				
Basit Ağaç	90.0	89.3	0.38	0.97
Orta Seviye Ağaç	92.0	91.5	0.46	0.98
Karmaşık Ağaç	93.6	92.8	0.52	0.99
Lojistik Regresyon				
Lojistik Regresyon	88.3	87.1	0.10	0.99
Diskriminant Analiz				
Doğrusal Diskriminant	81.1	80.9	0.57	0.85
Kuadratik Diskriminant	78.9	77.7	0.60	0.81
Derin Öğrenme				
Konvolüsyonel Sinir Ağı 1	99.3	98.1	0.90	0.99
Konvolüsyonel Sinir Ağı 2	99.7	99.4	0.99	0.99
İğnecikli Sinir Ağı	97.1	95.2	0.87	0.99

Tablo 3.4. Torbalama karar ağaçlar sınıflandırması 12 kanal kayıt sonuçları.

Kanal	Eğitim	Test		
	Doğruluk	Doğruluk	Hassaslık	Özgünlük
Kanal 1	98.9	97.8	0.87	0.99
Kanal 2	99.0	97.9	0.88	0.99
Kanal 3	97.9	96.6	0.81	0.99
Kanal 4	99.1	98.7	0.93	0.99
Kanal 5	98.2	97.1	0.82	0.99
Kanal 6	98.7	98.1	0.88	0.99
Kanal 7	98.8	98.1	0.90	0.99
Kanal 8	98.9	98.1	0.89	0.99
Kanal 9	98.5	97.9	0.87	0.99
Kanal 10	98.3	97.7	0.87	0.99
Kanal 11	98.3	97.8	0.88	0.99
Kanal 12	98.5	98.0	0.89	0.99

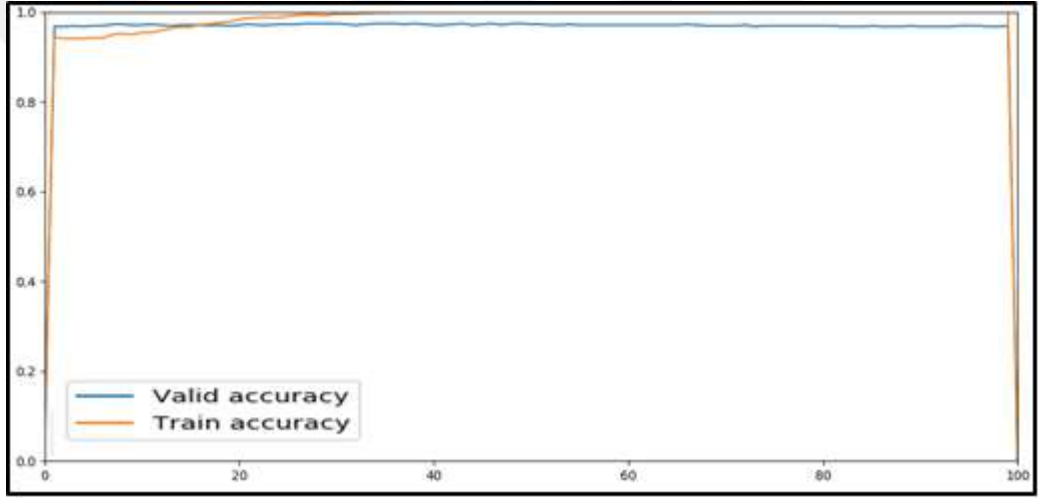
Dalgacık katsayılarının sisteme giriş olarak verildiği KSA ile analiz Python ile yapıldı. Bu aşamada Python ile makine öğrenimini yapmayı kolaylaştıran açık kaynaklı Anaconda platformunu tercih ettik. Anaconda platformu 250'den fazla popüler veri bilimi paketi ve conda paketi ve sanal ortam yöneticisi içerir. Tensorflow bu aşamada tercih edilen yüksek performanslı sayısal hesaplama için açık kaynaklı bir yazılım kütüphanedir. Esnek mimarisi, çeşitli platformlarda (CPU'lar, GPU'lar, TPU'lar) ve masaüstü bilgisayarlardan sunucu kümelerine ve mobil cihazlara kadar hesaplamaların kolayca yapılmasını sağlar. Orijinal olarak Google'ın AI organizasyonu içindeki Google Beyin ekibinden araştırmacılar ve mühendisler tarafından geliştirilen tensorflow derin öğrenmeye güçlü bir destekle birlikte gelir. Stokastik öğrenim için 10'luk grup büyüklüğünde standart geri yayılım uygulanır. Ağırlıklar, Denklem 3.1'e göre güncellenir (Bouvrerie, 2006).

$$w_l = \left(1 - \frac{n_\sigma}{ts}\right) w_{l-1} - \frac{n}{x} \frac{\partial c}{\partial w} \quad (3.1)$$

Bu denklemde w ağırlığı, l katman sayısını, n öğrenme oranını, σ normalleştirme parametresini, ts toplam eğitim örneği sayısını, x grup büyüklüğünü ve c maliyet fonksiyonunu gösterir. Sapmalar Denklem 3.2 aracılığıyla güncellenir.

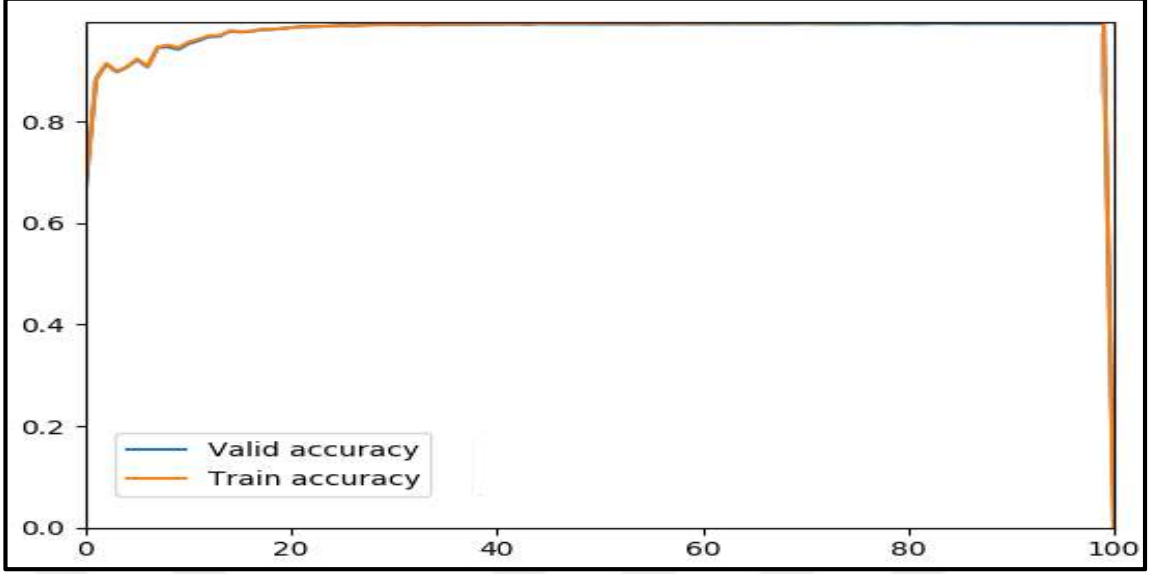
$$b_l = b_{l-1} - \frac{n}{x} \frac{\partial c}{\partial w} \quad (3.2)$$

Oluşturulan İlk KSA’nda üç konvolüsyon katmanı kullanılmıştır ve konvolüsyon katmanındaki filtre sayısı 5 alınmıştır. Tamamen bağlı katmandaki nöron sayısı 40’dır. Tamamen bağlı katmandaki Dropout oranı 0.95’dir. Öğrenme oranı $3e^{-5}$ olarak seçilmiştir. Z-skor girişi normalizasyonu kullanılmıştır böylece eğitim aşamasında her parametrenin, oluşturulacak modelin tahmin edebilmesine eşit seviyede katkıda bulunabilmesi sağlanmaktadır. Test aşamasındaki doğruluk %98 seviyesindedir. Doğruluk seviyelerine ait grafik Şekil 3.2’de verilmiştir. İkinci KSA’da konvolüsyon tabakası sayısı onikiye yükseltilmiştir ve bu ikinci mimariye ait doğruluk seviyelerine ait grafik Şekil 3.3’de verilmiştir. Test aşamasındaki doğruluk %99.4 seviyesindedir.



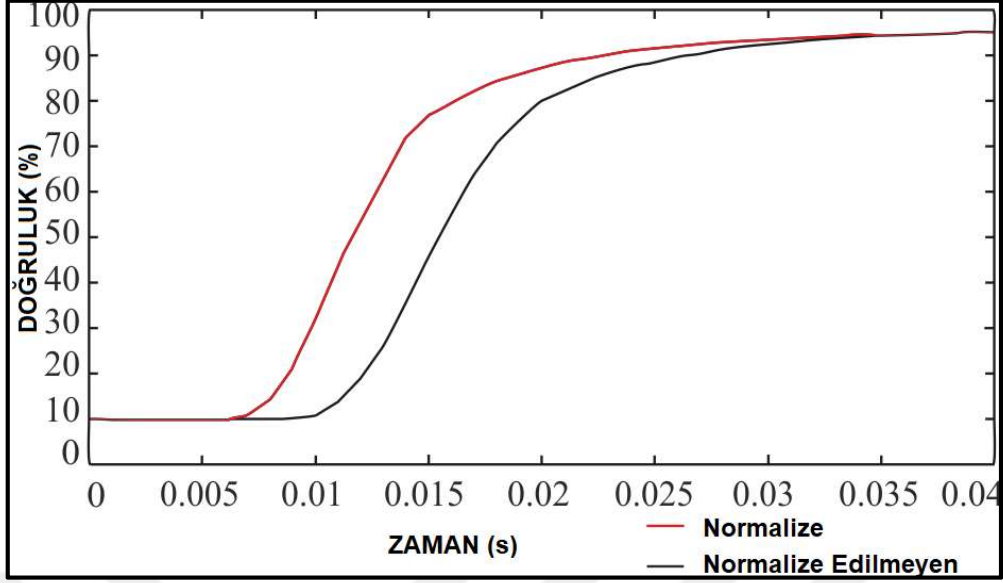
Şekil 3.2. Dalgacık katsayılarıyla yapılan ilk KSA ile analiz doğruluk seviyeleri.

Hesaplama yükünden dolayı, KSA’ları hızlı cevap verecek uygulamalar için çok uygun değildir. Bu yüzden daha hızlı hesaplamalar için İSA kullandık. Bu gerçek zamanlı uygulamalar için kullanılabilecek benzer bir ağ yapısıdır. İSA, beyni taklit edecek gerçekçi bir sinir ağı olarak inşa edildi. İSA’lar nöral bir simülasyonda gerçekçilik düzeyini artıran, üçüncü nesil sinir ağı modellerine girer (Maass, 1997). Bu model performans kaybına rağmen hesaplama yükü açısından daha verimli bulunmuştur (Diehl vd., 2015). İSA’larında, girdiler olaylar akışı olarak sunulur. Kanıtlar sunum sırasında nöronlar tarafından birleştirilir ve bilgi iletmek için anlık gerilim darbeleri oluşturulur (Gerstner ve Kistler, 2002).



Şekil 3.3. Dalgacık katsayılarıyla yapılan ikinci KSA ile analiz doğruluk seviyeleri

Bizim çalışmamızda dalgacık katsayıları sisteme giriş olarak verilmiştir. IF modeli, anlık gerilim darbesi nöronu olarak kullanıldı. ReDB'ların ağırlıkları doğrudan IF birimlerinin bir ağına eşleştirildi. Ters yönlendirme ile eğitim sırasındaki sapma sıfırlandı. Daha hızlı yakınsama ve kayıpsıza yakın doğruluk elde etmek için ağırlık normalizasyonu kullanıldı. Ağ ağırlıkları, ReDB'ların çıkış aktivasyonlarını olduğundan fazla tahmin etmesini önlemek için ve aktivasyonların yeterince küçük olduğundan emin olmak için normalleştirilmiştir (Diehl vd., 2015). Tüm ağırlıklar mümkün olan maksimum pozitif giriş ile yeniden ölçeklendirilmiştir. Beş katmanlı tamamen bağlı bir sinir ağı eğitildi.%1'lik öğrenme oranı ve %50 Dropout oranı kullandık. Ağırlıklar için rastgele 0.1 ve -0.1 arasında değerler atandı. Ağlar için %96.73 bir eğitim doğruluk oranı elde ettik. Test setinde ise normalize edilmiş ağ için %95.17'lik bir doğruluk oranı ve normalize edilmeyen ağ için %95.22'lik bir doğruluk oranı elde ettik. Normalizasyon, doğruluk kaybı olmadan gecikmeleri azalttı. Normalize ve normalize edilmeyen İSA'nın zamana göre doğruluğu Şekil 3.4'de verilmiştir.



Şekil 3.4. Dalgacık katsayılarıyla yapılan İSA'nın zamana göre doğruluğu.


3.2. Hjorth Tanımlayıcıları Kullanılarak Yapılan Analizin Sonuçları

Hjorth tanımlayıcılarını kullanarak yaptığımız analizde bu değişkenlere ilave olarak korelasyon katsayısı ve Akaike Bilgi Ölçütünü, sinyal gücünün aktiviteye oranı ve standart sapma eklendi. Öznitelikleri belirledikten sonra sınıflandırma aşamasına geçtik. İlk analizde kullanılan veriler MIT aritmi veri tabanından alınmıştır (Goldberger vd., 2000). Toplam veri miktarı 98260 R-R tepe noktaları arasındaki sinyallerden oluşmaktadır. Bu sinyallerden 29746 tanesi aritmi içermektedir. Aynı miktarda veri kalan 68514 RR tepe noktaları arasındaki sinyallerden rastgele seçilmektedir. Bu nedenle verilerin yarısı aritmi içerir ve verilerin diğer yarısı aritmi içermez. Her sinyal 5 parçaya ayrılmıştır. öznitelikler her parça için ayrıca hesaplanır. Sinyalin her bölümü için altı öznitelik hesaplanmıştır. Bölünme kriteri, karar ağaçları için Gini çeşitlilik indeksi olarak seçildi. En fazla bölünme miktarı karmaşık ağaç için 100, orta seviye ağaç için 20 ve basit ağaç için 4 olarak belirlendi. DVM için kutu kısıtlama düzeyi 1'dir. Çekirdek ölçeği Doğrusal, Kuadratik, Kübik DVM için otomatik olarak seçildi. Çekirdek fonksiyonu Hassas Gauss, Orta Seviye Gauss, Yüzeysel Gauss için Gauss olarak seçildi K-EYK sınıflandırması için mesafe ağırlığı eşit olarak seçildi. Mesafe metriği, hassas, orta, yüzeysel, ağırlıklı K-EYK için öklid olarak seçildi, kosinüs K-EYK için kosinüs ve kübik K-EYK için Minkowski seçildi. Hassas K-EYK için komşu sayısı 1, orta, kosinüs, kübik, ağırlıklı K-EYK için 10 ve yüzeysel K-EYK için 100 olarak belirlendi Geliştirilmiş Karar Ağaçları için topluluk yöntemi AdaBoost, öğrenici şekli

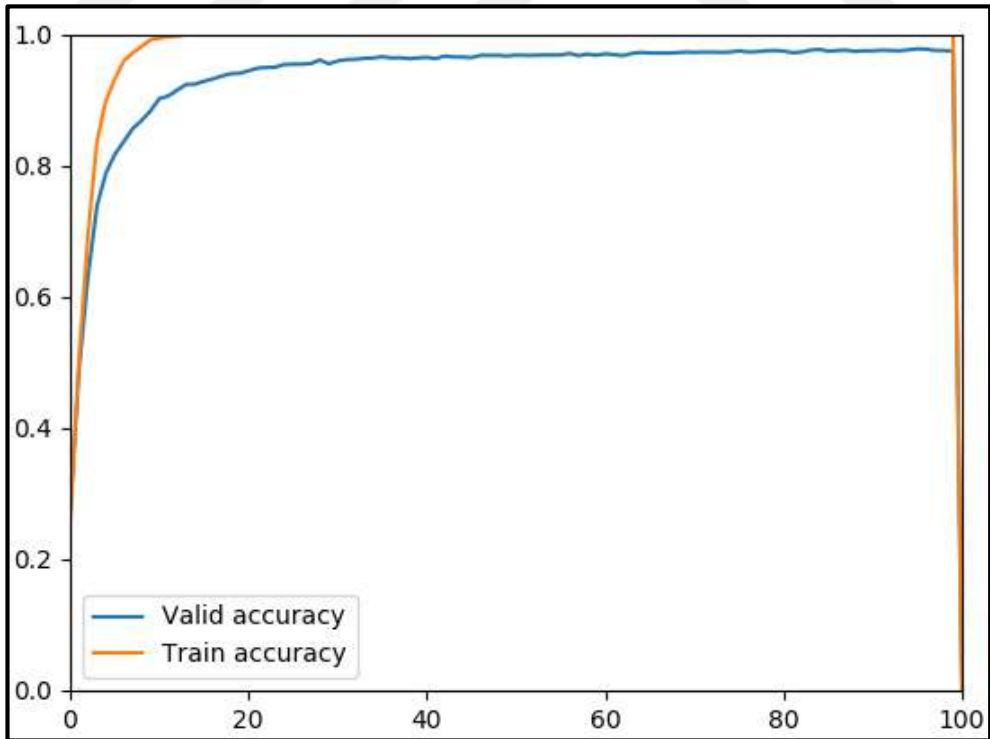
karar ağacı, maksimum bölünme miktarı 20, öğrencilerin sayısı 30, öğrenme oranı 0.1'dir. Torbalama Karar Ağaçlar için topluluk yöntemi bag, öğrenci şekli karar ağacı, öğrencilerin sayısı 30'dur. Altuzay Ayırımı için topluluk yöntemi altuzay, öğrenci şekli diskriminant, öğrenci sayısı 30, altuzay boyutu ise 2'dir. Altuzay K-EYK için topluluk yöntemi altuzay, öğrenci şekli K-EYK, öğrencilerin sayısı 30, altuzay boyutu 2'dir. RUSGeliştirilmiş Ağaçlar için topluluk yöntemi RUSBoost, öğrenci şekli karar ağacı, en fazla bölünme miktarı 20, öğrenci sayısı 30, öğrenme oranı 0,1'dir. yapıya sahip sınıflandırma yöntemlerinin MIT aritmi veri tabanındaki performans sonuçları Tablo 3.5'de verilmiştir. St. Petersburg aritmi veri tabanında sınıflandırma sonuçları Tablo 3.6'da verilmiştir.

Farklı sınıflandırma yöntemlerinin karşılaştırılmasında, Torbalama Karar Ağaçların daha iyi bir eğitim başarısına (ortalama % 97.82) ve test başarısına (ortalama % 90.8) ve ayrıca daha iyi hassasiyete (ortalama değer 0.86) sahip olduğu görülmektedir. Orta Seviye K-EYK daha iyi özgünlüğe (ortalama değer 0.98) sahiptir. Genel sonuçlara bakıldığında, Torbalama Karar Ağaçların en iyi sonuçları gösterdiği açıktır. Sınıflandırma için ihtiyaç duyulan süre benzer çalışmalara göre azdır. Ancak analiz için kullanılan öznitelik sayısındaki artış ve özniteliklerin sinyali 5 eşit parçaya bölüp tekrar hesaplanması süreyi artırmıştır. Örnek olarak 100m dosyasındaki 2272 kalp atımına ait öznitelik çıkarımı AMD A6-6310 işlemci ve 8 GB RAM ile bir bilgisayarda MATLAB ile 13.84 saniye sürmüştür. 202m dosyasındaki 2272 kalp atımına ait öznitelik çıkarımı 11.801 saniye sürmüştür. R tepe noktalarının tespiti dışında öznitelik çıkarımı 6 ms civarında sürmektedir.

KSA ile analiz Python programlama dili ve Anaconda platformu kullanılarak yapıldı. Tensorflow tercih ettiğimiz yazılım kütüphanesidir. Oluşturulan KSA mimarisinde konvolüsyon katmanındaki filtre sayısı 5 alınmıştır. Tamamen bağlı katmandaki nöron sayısı 40'dır. Tamamen bağlı katmandaki Dropout oranı 0.95'dir. Öğrenme oranı $3e^{-5}$ olarak seçilmiştir. Z-skor girişi normalizasyonu kullanılmıştır. Test aşamasındaki doğruluk %86.3 seviyesindedir. Hjorth Tanımlayıcılarının kullanıldığı verildiği KSA ile analizin doğruluk seviyelerine ait grafik Şekil 3.5'de verilmiştir. İkinci KSA'da konvolüsyon tabakası sayısı onikiye yükseltilmiştir ve bu ikinci mimariye ait doğruluk seviyelerine ait grafik Şekil 3.6'da verilmiştir. Test aşamasındaki doğruluk %96.5 seviyesindedir.




Şekil 3.5. Hjorth Tanımlayıcılarla ilk KSA ile analiz doğruluk seviyeleri.



Şekil 3.6. Hjorth Tanımlayıcılarla ikinci KSA'da doğruluk seviyeleri.

İSA'nın girişine yine KSA ile aynı öznitelikler verildi. Beş katmanlı tamamen bağlı bir sinir ağı eğitildi. %1'lik öğrenme oranı ve %50 Dropout oranı kullandık. Ağırlıklar için rastgele 0.1 ve -0.1 arasında değerler atandı. Ağlar için %81.21 bir eğitim doğruluk oranı elde ettik. Test setinde ise normalize edilmiş ağ için %80.09'lik bir doğruluk oranı ve normalize edilmeyen ağ için %80.17'lik bir doğruluk oranı elde ettik. Normalizasyon, doğruluk kaybı olmadan gecikmeleri azalttı. Hjorth Tanımlayıcılarının kullanıldığı normalize ve normalize edilmeyen iğnecikli sinir ağının zamana göre doğruluğu Şekil 3.7'de verilmiştir.



Şekil 3. 7. Hjorth Tanımlayıcılarla İSA'nın zamana göre doğruluğu.

Tablo 3.5. Hjorth Tanımlayıcılarla Eğitim Ve Test Başarıları.

Sınıflandırma	Eğitim	Test		
	Doğruluk	Doğruluk	Hassaslık	Özgünlük
En Yakın Komşular				
Hassas K-EYK	97.3 ± 0.90	91.4±0.06	0.84±0.13	95.8±2.05
Orta Seviye K-EYK	96.8 ± 0.69	90.3±0.07	0.81±0.14	98.0±0.71
Yüzeysel K-EYK	94.6 ± 1.05	88.6±0.05	0.78±0.11	96.4±0.55
Kosinüs K-EYK	96.0 ± 2.67	88.9±0.06	0.81±0.13	95.8±5.07
Kübik K-EYK	95.0 ± 2.96	88.7±0.04	0.85±0.04	91.2±4.09
Ağırlıklı K-EYK	93.7 ± 5.17	87.5±0.05	0.81±0.12	92.2±6.06
Destek Vektör Makineleri				
Doğrusal DVM	84.3 ± 3.91	78.9±0.06	0.72±0.01	84.8±1.64
Kuadratik DVM	95.5 ± 1.76	89.1±0.03	0.83±0.08	95.2±1.92
Kübik DVM	78.5 ± 18.5	72.5±0.15	0.63±0.15	86.8±9.23
Hassas Gauss DVM	93.5 ± 1.9	85.3±0.08	0.74.2±0.18	95.6±2.07
Orta Seviye Gauss DVM	96.3 ± 2.48	88.2±0.03	0.77±0.06	95.8±2.17
Yüzeysel Gauss DVM	90.0 ± 2.14	82.4±0.02	0.75.6±0.05	89.4±1.95
Topluluk Sınıflandırıcıları				
Geliştirilmiş Karar Ağaçları	86.3 ± 6.21	78.2±0.01	0.66±0.02	90.0±1.00
Torbalama Karar Ağaçlar	97.8 ± 0.46	91.7± 0.06	0.85±0.11	95.6±2.97
Altuzay Ayırımı	78.9 ± 3.1	74.3± 0.03	0.67±0.05	80.2±5.50
Altuzay K-EYK	80.0 ± 5.43	74.8±0.03	0.62±0.07	86.6±1.82
RUSGeliştirilmiş Ağaçlar	78.9 ± 9.66	69.9±0.06	0.54±0.10	83.4±2.07
Karar Ağaçları				
Basit Ağaç	79.4 ± 2.83	75.5±0.02	0.67±0.04	82.6±2.30
Orta Seviye Ağaç	85.3 ± 3.2	79.3±0.02	0.67±0.04	91.4±1.82
Karmaşık Ağaç	89.9 ± 2.22	83.2±0.02	0.71±0.04	95.0±1.000


Tablo 3.6. Hjorth Tanımlayıcılarla St. Petersburg veri tabanının sonuçları.

Sınıflandırma	Eğitim	Test		
	Doğruluk	Doğruluk	Hassaslık	Özgünlük
En Yakın Komşu				
Hassas K-EYK	92.4	89.2	0.82	0.93
Orta Seviye K-EYK	91.9	87.8	0.80	0.96
Yüzeysel K-EYK	90.6	84.9	0.76	0.96
Kosinüs K-EYK	93.0	86.1	0.80	0.94
Kübik K-EYK	92.1	87.5	0.84	0.90
Ağırlıklı K-EYK	90.1	86.2	0.81	0.90
Destek Vektör Makineleri				
Doğrusal DVM	81.1	75.7	0.72	0.83
Kuadratik DVM	91.1	86.2	0.82	0.91
Kübik DVM	76.6	70.7	0.62	0.82
Hassas Gauss DVM	90.1	82.1	0.71	0.92
Orta Seviye Gauss DVM	91.6	87.4	0.77	0.91
Yüzeysel Gauss DVM	88.2	80.2	0.71	0.86
Topluluk Sınıflandırıcıları				
Geliştirilmiş Karar Ağaçlar	86.1	77.6	0.65	0.89
Torbalama Karar Ağaçlar	95.9	90.1	0.84	0.92
Altuzay Ayırımı	76.3	70.5	0.65	0.78
Altuzay K-EYK	79.6	70.9	0.60	0.83
RUSGeliştirilmiş Ağaçlar	75.9	65.0	0.54	0.75
Karar Ağaçları				
Basit Ağaç	76.6	73.2	0.66	0.79
Orta Seviye Ağaç	82.1	77.9	0.65	0.89
Karmaşık Ağaç	85.4	78.8	0.70	0.90
Lojistik Regresyon				
Lojistik Regresyon	85.2	77.1	0.79	0.76
Diskriminant Analiz				
Doğrusal Diskriminant	84.4	77.1	0.70	0.79
Kuadratik Diskriminant	83.7	75.5	0.70	0.76
Derin Öğrenme				
Konvolüsyonel Sinir Ağı 1	98.9	86.3	0.83	0.91
Konvolüsyonel Sinir Ağı 2	99.1	96.5	0.90	0.99
İğnecikli Sinir Ağı	89.8	80.2	0.70	0.87


3.3. Morfolojik Öznitelikler Kullanılarak Yapılan Analizin Sonuçları

Bu aşamada kullandığımız öznitelikler P-P aralığı, ortalama, standart sapma, çarpıklık, Q ile S arasındaki mesafe, Q ile R arasındaki eğim, R ile S arasındaki eğim, Q'dan S'ye varyans değeri şeklindedir. Bu sekiz öznitelik kullanılarak değişik sınıflandırma yöntemleri karşılaştırılmış ve bu özniteliklerle kullanılabilecek en uygun sınıflandırma yöntemi belirlenmiştir. Matlab içinde bulunan Classification Learner yazılımı yardımıyla yapılan sınıflandırma sonuçları Tablo 3.7'de verilmiştir. En başarılı bulunan Torbalama Karar Ağaçları ile eğitim doğruluğu %96.7, test doğruluğu %95.8, hassaslık 0.89 ve özgünlük 0.99 olarak bulunmuştur.

Morfolojik öznitelikler kullanılarak konvolüsyonel sinir ağı ile aritmi analizinde öznitelik olarak P-P aralığı, ortalama, standart sapma, çarpıklık, Q ile S arasındaki mesafe, Q ile R arasındaki eğim, R ile S arasındaki eğim, Q'dan S'ye varyans değeri değeri kullanılmıştır. KSA ile analiz Python programlama dili ve Anaconda platformu kullanılarak yapıldı. Tensorflow tercih ettiğimiz yazılım kütüphanesidir. Oluşturulan KSA mimarisinde konvolüsyon katmanındaki filtre sayısı 5 olarak alınmıştır. Tamamen bağlı katmandaki nöron sayısı 40'dır. Tamamen bağlı katmandaki Dropout oranı 0.95'dir. Öğrenme oranı $3e^{-5}$ olarak seçilmiştir. Z-skor girişi normalizasyonu kullanılmıştır. Test aşamasındaki doğruluk %95.9 seviyesindedir. Morfolojik özniteliklerin kullanıldığı verildiği ilk KSA ile analiz doğruluk seviyelerine ait grafik Şekil 3.8'de verilmiştir. İkinci KSA'da konvolüsyon tabakası sayısı onikiye yükseltilmiştir ve bu ikinci mimariye ait doğruluk seviyelerine ait grafik Şekil 3.9'da verilmiştir. Test aşamasındaki doğruluk %99.8 seviyesindedir.




Şekil 3.8. Morfolojik özniteliklerle ilk KSA'nın analiz doğruluk seviyeleri.



Şekil 3.9. Morfolojik özniteliklerle ikinci KSA'nın analiz doğruluk seviyeleri.

İSA'nın girişine yine KSA ile aynı öznitelikler verildi. Beş katmanlı tamamen bağlı bir sinir ağı eğitildi. %1'lik öğrenme oranı ve %50 Dropout oranı kullandık. Ağırlıklar için rastgele 0.1 ve -0.1 arasında değerler atandı. Ağlar için %90.92 bir eğitim doğruluk oranı elde ettik. Test setinde ise normalize edilmiş ağ için %90.11'lik bir doğruluk oranı ve normalize edilmeyen ağ için %90.19'lik bir doğruluk oranı elde ettik. Normalizasyon, doğruluk kaybı olmadan gecikmeleri azalttı Morfolojik özniteliklerin kullanıldığı normalize ve normalize edilmeyen İSA'nın zamana göre doğruluğu. Şekil 3.10'da verilmiştir.



Şekil 3.10. Morfolojik özniteliklerin kullanıldığı İSA'nın zamana göre doğruluğu.

Tablo 3.7. Morfolojik Özniteliklerin Kullanıldığı Sınıflandırma Sonuçları.


Sınıflandırma	Eğitim	Test		
	Doğruluk	Doğruluk	Hassaslık	Özgünlük
En Yakın Komşu				
Hassas K-EYK	94.5	94.3	0.81	0.97
Orta Seviye K-EYK	95.4	95.3	0.76	0.99
Yüzeysel K-EYK	94.2	94.1	0.70	0.99
Kosinüs K-EYK	95.1	94.9	0.77	0.98
Kübik K-EYK	95.3	95.1	0.75	0.99
Ağırlıklı K-EYK	95.5	95.4	0.78	0.99
Destek Vektör Makineleri				
Doğrusal DVM	89.1	89.0	0.52	0.98
Kuadratik DVM	90.4	87.1	0.78	0.94
Kübik DVM	78.2	71.4	0.51	0.85
Hassas Gauss DVM	95.5	95.4	0.84	0.99
Orta Seviye Gauss DVM	94.4	94.3	0.78	0.99
Yüzeysel Gauss DVM	90.2	90.2	0.52	0.98
Topluluk Sınıflandırıcıları				
Geliştirilmiş Karar Ağaçlar	93.5	93.3	0.65	0.98
Torbalama Karar Ağaçlar	96.7	95.8	0.89	0.99
Altuzay Ayırımı	88.4	88.4	0.43	0.98
Altuzay K-EYK	93.6	93.8	0.72	0.99
RUSGeliştirilmiş Ağaçlar	26.7	19.5	0.99	0.19
Karar Ağaçları				
Basit Ağaç	93.6	93.3	0.68	0.98
Orta Seviye Ağaç	92.0	91.7	0.64	0.97
Karmaşık Ağaç	89.0	88.74	0.56	0.96
Derin Öğrenme				
Konvolüsyonel Sinir Ağı 1	99.1	95.9	0.90	0.99
Konvolüsyonel Sinir Ağı 2	99.9	99.8	0.99	0.99
İğnecikli Sinir Ağı	96.4	90.2	0.80	0.99

3.4. EKG Verilerinin Öznitelik Olarak Kullanılması

KSA modelinde, öznitelik girişi olmadan sinyali giriş olarak girerek sınıflandırma yapmak mümkündür. Bu şekilde hesaplama yükünün azalması ve işlemlerin kolaylaşması mümkündür.


Bu aşamada EKG sinyalleri KSA modellerine giriş olarak verilmiş ve analizler yapılmıştır. Derin öğrenmede tüm verileri tek seferde işlemek ve öğrenmek, bellek ve zaman açısından zorlayıcıdır. Öğrenme aşamasının her tekrarında geriye yayılım ile ağda geriye dönük gradyan hesaplaması yapılır ve ağırlık değerleri güncellenir. Bu hesaplama aşamasında veri ne kadar çoksa hesaplama o kadar uzun sürmektedir. Bundan dolayı veri küçük parçalara ayrılır ve öğrenme bu küçük parçalar üzerinde yapılır. Önerilen mimari, çarpım ve toplama işlemlerini gerektiren 1 boyutlu konvolüsyon işlemlerini gerektirmektedir. 257 Hz' de örneklenmiş EKG sinyalleri her R-R aralığında parçalara ayrılmakta ve KSA yapısına giriş olarak verilmektedir. Sinyallerin yarısı eğitim ve diğer yarısı da test için kullanılmıştır. Basit ama etkili bir yaklaşım olan momentum yaklaşımıyla Olasılıksal Dereceli Azaltma (Stochastic Gradient Descent) kullanarak KSA'ını optimize ettik. Momentumla olasılıksal dereceli azalmadaki salınımları azaltıp tutarlı ve hızlı bir optimizasyon yapılabilir. Burada momentum değeri 0.9 olarak kullanıldı. Konvolüsyon tabakalarının çekirdek boyutu 5'dir. Parametreleri güncelleme geriye yayılım ile olmaktadır. Güncellemede geri yönde türev alınarak fark bulunur. Sonrasında bulunan değer öğrenme oranı ile çarpılır. Elde edilen değer ağırlık parametrelerinden çıkarılmasıyla bulunan yeni değer hesaplanır. Burada kullanılan öğrenme oranı sabit değer $3e^{-5}$ olarak belirlenmiştir. Tamamen bağlı katmandaki nöron sayısı 40'dır. Grup boyutu 64'dür. Tamamen bağlı katmandaki Dropout oranı 0.95'dir. Z-skor girişi normalizasyonu kullanılmıştır. Validasyon kaybı 20 epok boyunca düşmeyi bıraktığında eğitimi durduran karar verme kıstası kullanıldı. İlk KSA mimarisinde üç konvolüsyon katmanı kullanılmıştır. İkinci KSA'da konvolüsyon tabakası sayısı onikiye yükseltilmiştir.

İlk KSA mimarimizin doğruluğu %90.3 seviyesindedir. EKG verilerinin öznitelik olarak kullanıldığı ilk KSA'nın zamana göre doğruluğu. Şekil 3.11'de verilmiştir.



Şekil 3.11. EKG verilerinin öznitelik olarak kullanıldığı ilk KSA'nın doğruluğu.

İkinci KSA mimarimizin doğruluğu %94.1 seviyesindedir. EKG verilerinin öznitelik olarak kullanıldığı ikinci KSA'nın zamana göre doğruluğu. Şekil 3.12'de verilmiştir.



Şekil 3.12. EKG verilerinin öznitelik olarak kullanıldığı ilk KSA'nın doğruluğu.

Hızlı bir öğrenme yapısına sahip olan ve yüksek doğruluk sağlayan optimize edilmiş bir KSA mimarisi tasarlamayı hedefledik. Yüksek sınıflandırma doğruluğuna rağmen, KSA'da sonuçların sezgisel olmadığı görülmektedir. KSA algoritmasında gömülü otomatik öznitelik çıkarımı, çalışmamızda göz önüne alınan özniteliklere ek ayırt edici bilgi veren önemli ve yeni öznitelikler üretir. Ayrıca, çoğu KSA özniteliklerinin birbirleriyle istatistiksel olarak anlamlı bir şekilde ilişkilidir. Böylece, performans kaybı olmaksızın, korelasyon temelli bir boyut azaltma yapmanın mümkün olduğu görülmüştür. Ancak pek çok makine öğrenme yöntemi, anlamlı öznitelik değişkenlerinin tanımlanmasını tercih etmektedir.

3.5.Değişik Özniteliklerin Aritmi Türlerine Göre Performans Değerleri

Değişik özniteliklerin dokuz sınıflı veri kümelerinde farklı sınıflandırma yöntemlerine göre performansları karşılaştırılmış ve yorumlanmıştır. Karşılaştırma sırasında sınıflara ait kodlar normal, N, erken ventriküler kasılma, V, atriyal prematüre atım, A, ventriküler ve normal atım füzyonu, F, sağ dal bloğu atımı, R, dal bloğu atımı, B, supraventriküler prematür veya ektopik atım (atriyal veya nodal), S, nodal (birleşim) kaçış ritmi, j, sınıflandırılmaz vuruşlar, Q şeklindedir. Dokuz sınıflı kümenin performansları Tablo 3.8-10'da verilmiştir

Tablo 3.8. Dalgacık Katsayılarıyla Dokuz Sınıflı Kümede Performans Karşılaştırması

Sınıflandırma	Test		
	Doğruluk	Hassaslık	Özgünlük
Ağırlıklı K-EYK			
N	96.9	0.80	0.99
V	94.2	0.91	0.90
A	95.7	0.73	0.99
F	97.1	0.80	0.99
R	98.2	0.87	0.99
B	98.6	0.88	0.99
S	97.3	0.84	0.99
j	96.9	0.90	0.86
Q	95.7	0.89	0.90
Hassas Gauss DVM			
N	94.4	0.74	0.99
V	92.0	0.71	0.94

Tablo 3.8'in devamı

A	93.9	0.67	0.97
F	97.9	0.85	0.99
R	98.0	0.85	0.99
B	98.5	0.72	0.99
S	97.4	0.69	0.99
j	98.1	0.66	0.99
Q	96.2	0.61	0.99
Torbalama Karar Ağaçlar			
N	98.5	0.91	0.99
V	97.1	0.87	0.99
A	95.5	0.81	0.98
F	96.0	0.78	0.99
R	99.6	0.99	0.99
B	99.1	0.83	0.99
S	99.7	0.75	0.99
j	99.4	0.90	0.99
Q	99.0	0.94	0.99
Basit Ağaç			
N	90.1	0.65	0.97
V	88.3	0.55	0.95
A	85.9	0.50	0.91
F	91.5	0.71	0.99
R	93.2	0.60	0.99
B	94.7	0.81	0.99
S	93.9	0.47	0.99
j	95.5	0.61	0.99
Q	97.1	0.70	0.99
Konvolüsyonel Sinir Ağ 1			
N	98.1	0.89	0.99
V	97.5	0.87	0.99
A	98.5	0.90	0.99
F	97.8	0.82	0.99
R	98.1	0.91	0.99
B	99.5	0.90	0.99
S	99.4	0.85	0.99
j	98.9	0.82	0.99
Q	99.0	0.90	0.99

Tablo 3.8'in devamı

Konvolüsyonel Sinir Ağ 2			
N	99.4	0.99	0.99
V	98.8	0.90	0.99
A	99.0	0.92	0.99
F	99.8	0.90	0.99
R	99.3	0.92	0.99
B	99.6	0.90	0.99
S	99.8	0.89	0.99
j	99.7	0.91	0.99
Q	99.5	0.90	0.99
İğnecikli Sinir Ağı			
N	95.1	0.91	0.99
V	93.0	0.76	0.98
A	94.9	0.89	0.99
F	98.1	0.82	0.99
R	98.9	0.79	0.99
B	99.0	0.88	0.99
S	98.6	0.85	0.99
j	99.1	0.70	0.99
Q	98.9	0.77	0.99

Tablo 3.9. Hjorth Tanımlayıcılarıyla Dokuz Sınıflı Kümede Performans Karşılaştırması

Sınıflandırma	Test		
	Doğruluk	Hassaslık	Özgünlük
Ağırlıklı K-EYK			
N	85.9	0.72	0.95
V	83.1	0.69	0.92
A	85.7	0.55	0.91
F	92.1	0.60	0.99
R	93.9	0.46	0.99
B	92.2	0.66	0.99
S	94.2	0.51	0.99
j	94.7	0.70	0.99
Q	93.4	0.49	0.99
Hassas Gauss DVM			
N	82.1	0.70	0.90
V	77.7	0.65	0.87

Tablo 3.9'un devamı

A	80.1	0.49	0.91
F	90.3	0.58	0.99
R	90.1	0.70	0.99
B	92.9	0.59	0.99
S	91.7	0.48	0.99
j	92.9	0.71	0.99
Q	90.8	0.49	0.99
Torbalama Karar Ağaçlar			
N	85.5	0.80	0.91
V	81.9	0.72	0.90
A	84.7	0.80	0.91
F	88.9	0.70	0.99
R	89.7	0.65	0.99
B	90.1	0.55	0.99
S	90.5	0.49	0.99
j	89.2	0.50	0.99
Q	89.3	0.60	0.99
Basit Ağaç			
N	76.1	0.70	0.81
V	74.4	0.68	0.79
A	73.9	0.61	0.77
F	87.1	0.42	0.99
R	85.5	0.69	0.99
B	88.1	0.72	0.99
S	89.6	0.68	0.99
j	88.2	0.59	0.99
Q	87.4	0.47	0.99
Konvolüsyonel Sınır Ağ 1			
N	86.1	0.82	0.91
V	81.2	0.71	0.90
A	84.7	0.80	0.90
F	90.9	0.62	0.99
R	90.0	0.85	0.99
B	90.3	0.80	0.99
S	90.8	0.65	0.99
j	92.3	0.70	0.99
Q	93.3	0.71	0.99

Tablo 3.9'un devamı

Konvolüsyonel Sinir Ağ 2			
N	96.3	0.90	0.91
V	93.2	0.81	0.90
A	92.7	0.80	0.90
F	98.9	0.72	0.99
R	99.0	0.85	0.99
B	99.5	0.80	0.99
S	99.8	0.85	0.99
j	99.1	0.79	0.99
Q	99.3	0.81	0.99
İğnecikli Sinir Ağı			
N	79.4	0.69	0.85
V	76.2	0.54	0.82
A	75.9	0.60	0.81
F	89.0	0.47	0.99
R	90.1	0.60	0.99
B	91.8	0.70	0.99
S	90.7	0.44	0.99
j	91.1	0.46	0.99
Q	90.4	0.59	0.99

Tablo 3.10. Morfolojik Özniteliklerin Dokuz Sınıflı Kümede Performansları

Sınıflandırma	Test		
	Doğruluk	Hassaslık	Özgünlük
Ağırlıklı K-EYK			
N	95.1	0.77	0.99
V	94.7	0.77	0.99
A	92.2	0.70	0.99
F	98.9	0.70	0.99
R	99.4	0.72	0.99
B	99.0	0.73	0.99
S	99.5	0.79	0.99
j	99.1	0.77	0.99
Q	99.0	0.71	0.98
Hassas Gauss DVM			
N	95.0	0.83	0.99
V	93.1	0.77	0.98

Tablo 3.10'un devamı

A	92.7	0.75	0.98
F	99.3	0.69	0.99
R	99.7	0.82	0.99
B	99.5	0.80	0.99
S	99.1	0.65	0.99
j	99.2	0.79	0.99
Q	98.1	0.85	0.99
Torbalama Karar Ağaçlar			
N	96.0	0.90	0.99
V	96.8	0.91	0.99
A	94.5	0.89	0.99
F	99.7	0.85	0.99
R	99.8	0.87	0.99
B	99.4	0.88	0.99
S	99.6	0.89	0.99
j	99.2	0.84	0.99
Q	99.5	0.87	0.99
Basit Ağaç			
N	93.1	0.70	0.98
V	90.4	0.70	0.96
A	91.9	0.80	0.97
F	99.6	0.81	0.99
R	99.1	0.77	0.99
B	99.2	0.80	0.99
S	99.7	0.71	0.99
j	99.4	0.76	0.99
Q	99.0	0.62	0.99
Konvolüsyonel Sinir Ağ 1			
N	95.5	0.91	0.99
V	93.1	0.90	0.99
A	94.8	0.79	0.99
F	99.7	0.69	0.99
R	99.4	0.80	0.99
B	99.6	0.70	0.99
S	99.0	0.65	0.99
j	99.2	0.79	0.99
Q	99.0	0.77	0.99

Tablo 3.10'un devamı

Konvolüsyonel Sinir Ağ 2			
N	99.7	0.99	0.99
V	99.6	0.97	0.99
A	99.7	0.98	0.99
F	99.9	0.88	0.99
R	99.9	0.89	0.99
B	99.8	0.91	0.99
S	99.9	0.95	0.99
j	99.8	0.99	0.99
Q	99.7	0.87	0.99
İğnecikli Sinir Ağı			
N	90.1	0.66	0.97
V	87.6	0.61	0.96
A	88.1	0.70	0.96
F	99.2	0.76	0.99
R	99.6	0.61	0.99
B	99.0	0.70	0.99
S	99.4	0.70	0.99
j	89.2	0.55	0.99
Q	89.1	0.62	0.99

3.6. Gerçek Zamanlı Aritmi Tespitinde Başarı Seviyeleri

Gerçek zamanlı aritmi algılama için tasarlanmış simulink modelin sinyal başarısı Tablo 3.11'de verilmiştir. Genel ortalama başarı seviyesi %99.8'dir.

Tablo 3.11. Gerçek zamanlı aritmi tespitinde kullanılan modelin sinyal başarısı.

Sinyal	Doğruluk	Hassaslık	Özgünlük
I01m	100	1	1
I02m	100	1	1
I03m	100	1	1
I04m	99.8	0.92	1
I05m	100	1	1
I06m	100	1	1
I07m	100	1	1
I08m	98.7	0.84	0.99
I09m	100	1	1
I10m	100	1	1

Tablo 3.11'in devamı

I11m	100	1	1
I12m	100	1	1
I13m	100	1	1
I14m	100	1	1
I15m	100	1	1
I16m	100	1	1
I17m	100	1	1
I18m	99.3	0.92	0.99
I19m	100	1	1
I20m	99.5	0.85	1
I21m	100	1	1
I22m	99.5	0.84	1
I23m	99.9	0.75	1
I24m	100	1	1
I25m	100	1	1
I26m	100	1	1
I27m	99.8	1	1
I28m	100	1	1
I29m	100	1	1
I30m	98.5	0.92	0.98
I31m	100	1	1
I32m	100	1	1
I33m	100	1	1
I34m	100	1	1
I35m	97.3	0.63	0.99
I36m	97.9	0.73	0.99
I37m	99.9	0.99	1
I38m	99.7	0.99	1
I39m	99.9	0.99	1
I40m	100	1	1
I41m	100	1	1
I42m	99.3	0.99	0.97
I43m	99.9	1	1
I44m	100	1	1
I45m	100	1	1
I46m	99.9	0.99	1
I47m	100	1	1
I48m	99.7	0.94	1
I49m	100	1	1
I50m	99.9	0.7	1
I51m	99.6	0.98	0.99
I52m	100	1	1
I53m	99.5	0.99	0.99
I54m	99.9	0.86	1
I55m	100	1	1

Tablo 3.11'in devamı

I56m	100	1	1
I57m	100	1	1
I58m	100	1	1
I59m	100	1	1
I60m	100	1	1
I61m	100	1	1
I62m	99.6	0.98	0.99
I63m	99.5	0.86	1
I64m	99.8	0.67	1
I65m	99.2	0.9	0.99
I66m	99.9	1	0.99
I67m	98.1	0.84	0.98
I68m	100	1	1
I69m	99.9	0.98	1
I70m	100	1	1
I71m	100	1	1
I72m	99.9	0.99	1
I73m	100	1	1
I74m	100	1	1
I75m	100	1	1

4.SONUÇLAR

Klinik karar destek sistemleri kullanılarak hızlı ve doğru tanı mümkündür. Bunlar doktorlara yardım etmek için oluşturulan biyolojik sinyal işleme uygulamalarıdır. Biyomedikal sinyal işlemenin belli bir mesafedeki hasta bakımında önemli bir rol oynayacağı olasıdır.

Dalgacık katsayılarının öznitelik olarak kullanıldığı analizlerde eğitim ve test için St. Petersburg Kardiyoloji Teknik Enstitüsü 12 kanallı aritmi veri tabanı kullanıldı. EKG sinyallerinde öznitelik hesaplamasından önce veriler sıkıştırıldı ve ön işleme sürecinden geçirildi. Sıkıştırma ile dosya boyutunun kullandığı hafıza miktarının azaldığı görülmektedir. Anlamlı veride bir kayıp olmadığı için performans değerlerinde belirgin bir değişiklik olmadı. Bu konuda sıkıştırma ve ön işleme yapılan veri üzerinde sınıflandırma yapan benzer bir çalışmaya rastlanılmamıştır. Ön işleme aşaması gürültünün yok edilmesi, trend eliminasyonu, taban düzeltmesi ve normalleştirme şeklindedir. Dalgacık katsayılarını hesaplariken iki küçük pencere kullanıldı. Bu kullanım, öznitelik çıkarma için yalnızca bir pencere kullanma eğiliminde olan çoğu araştırmadan farklıdır. Öznitelik seti oluşturulurken sınıflandırmada en önemli etkiyi gösteren dalgacık katsayıları seçildi ve standart sapma ve varyans da eklendi. Özniteliklerin sayısını azaltmada ayrıca temel bileşen analizi (TBA) kullanıldı. Öznitelik sayısı benzer çalışmalara göre daha fazla azaltılmıştır. Daha az öznitelik ile daha hızlı sınıflandırma yapmak mümkündür.

Sınıflandırma için dokuz sınıf belirlenmiştir. Temel sınıflandırıcılar olarak Ağaç yöntemleri, K En Yakın Komşuluk algoritmaları, Destek Vektör Makineleri, Topluluk sınıflandırıcıları, Lojistik Regresyon ve Diskriminant Analiz kullanılmıştır. Temel Sınıflandırıcılar arasında başarılı bulunan torbalama karar ağaçlarında eğitim için %98.6 doğruluk, test için %97.8 doğruluk, %87.4 hassaslık ve %99,7 özgünlük elde edildi.

Derin öğrenme ile sınıflandırmada aşamasında yaygın kullanılan KSA ve daha nadir kullanılan İSA kullanılmıştır. KSA yüksek başarıyı sağlayan bir yöntemdir ancak hesaplama yükünden dolayı, KSA'lar hızlı cevap verecek uygulamalar için çok uygun değildir. Bu yüzden daha hızlı hesaplamalar için İSA incelendi. Temel sınıflandırma yöntemlerinin ve derin öğrenme algoritmalarının sınıflandırma performansları karşılaştırıldı. Dalgacık katsayılarının kullanıldığı bu kadar çok sınıflandırma yöntemini birbiriyle karşılaştırıldığı bir çalışmaya rastlanılmamıştır.

Dalgacık katsayıları kullanılarak EKG sinyallerinde aritmi analizini derin öğrenme ile yapan bir çalışmaya rastlanılmamıştır. Bu alanda yapılan çalışmalarda genellikle KSA tercih edilmiştir. Bu süreçte doğruluk oranı daha yüksek olan KSA ve daha hızlı hesaplanabilen İSA analizler için tercih edilmiştir. Dalgacık katsayıları kullanılarak KSA ile yapılan sınıflandırmanın test aşamasındaki doğruluğu %99.4 seviyesindedir. İSA ile yapılan sınıflandırmanın test setinde ise normalize edilmiş ağ için %95.17'lik bir doğruluk oranı ve normalize edilmeyen ağ için %95.22'lik bir doğruluk oranı elde edildi ve normalizasyon ile doğruluk oranında belirgin bir değişim olmadan gecikmeler azaltıldı. KSA'ında başarı daha yüksek ancak hesaplama yükü fazladır. İSA'larda başarı daha düşük ancak hesaplama yükü daha azdır.

Dalgacık katsayılarının kullanıldığı yöntemin benzer çalışmalarla karşılaştırılması Tablo 4.1'de verilmiştir. Çalışma 20 hariç diğer çalışmalar tek kanal analizi yapmışlardır. Çalışma 1-12, 14,16,19,21-23,25-26 MIT-BIH aritmi veri tabanını kullanmaktadır. Çalışma 13 Complex Phys. aritmi veri tabanını, çalışma 15 Physionetteki çeşitli aritmi veri tabanını, çalışma 17,24 PTB aritmi veri tabanını, çalışma 18 Southampton aritmi veri tabanını, çalışma 20 Physikalisch T. aritmi veri tabanını, çalışma 27 OHCA aritmi veri tabanını kullanmaktadır. Bu çalışmada daha nadir kullanılan St. Petersburg veri tabanı kullanıldı. Dalgacık katsayılarını kullanan benzer çalışmalar arasında bu veri tabanını kullanana rastlanılmamıştır. Çalışma 1-3, 6, 11-12, 19, 25, 27 tercih edilen sınıflandırıcı olarak yaygın olarak kullanılan sinir ağlarını kullanmıştır. Çalışma 4-5, 8, 14, 16, 18, 21-22, 24 tercih edilen sınıflandırıcı olarak DVM'i, çalışma 7, 23 tercih edilen sınıflandırıcı olarak K-EYK'i, çalışma 9 tercih edilen sınıflandırıcı olarak Random Forest, çalışma 10, 17 tercih edilen sınıflandırıcı olarak Lineer Sınıflandırıcıları, çalışma 13 tercih edilen sınıflandırıcı olarak Morphology C., çalışma 15 tercih edilen sınıflandırıcı olarak Cluster Centroid, çalışma 20 tercih edilen sınıflandırıcı olarak eşige dayalı sınıflandırıcı, çalışma 26 tercih edilen sınıflandırıcı olarak Naive Bayes kullanmıştır. Bu çalışmada temel sınıflandırıcılar ve derin öğrenme yöntemleri karşılaştırılarak en başarılı olarak konvolüsyonel sinir ağı olarak bulundu. Dalgacık katsayılarının öznitelik olarak kullanıldığı analizlerde başarılı bulunan konvolüsyonel sinir ağında eğitim için %99.7 doğruluk, test için %99.4 doğruluk, 0.99 hassaslık ve 0.99 özgünlük elde edildi. Benzer çalışmalardaki başarı seviyelerinin %78.5 ile % 99.8 arasında olduğu görülmektedir. En yüksek başarı seviyesine ait çalışmalar çok miktarda öznitelik barındırmakta, daha küçük bir veritabanı kullanılmaktadır.

Tablo 4.1. Dalgacık yöntemin benzer çalışmalarla karşılaştırılması

No	Çalışmayı yapan	Sınıf Sayısı	Kanal Sayısı	Kullanılan Veri Tabanı	Tercih Edilen Sınıflandırıcı	Doğruluk Oranı
1	Dokur	10	1	MIT-BIH	Sinir Ağları	99.4
2	Prasad	12	1	MIT-BIH	Sinir Ağları	96.77
3	Shyu	2	1	MIT-BIH	Sinir Ağları	99.79
4	Zhao	6	1	MIT-BIH	DVM	99.68
5	Jiang	14	1	MIT-BIH	DVM	98.65
6	Yu	6	1	MIT-BIH	Sinir Ağları	99.65
7	İşler	2	1	MIT-BIH	K-EYK	96.39
8	Zellmer	6	1	MIT-BIH	DVM	99.72
9	Emanet	5	1	MIT-BIH	Random Forest	99.8
10	Llamedo	2	1	MIT-BIH	Lineer Sınıflandırıcı	93
11	Rai	5	1	MIT-BIH	Sinir Ağları	99.8
12	Rai	2	1	MIT-BIH	Sinir Ağları	97.8
13	Li	2	1	Complex Phys.	Morphology C.	93
14	Ye	16	1	MIT-BIH	DVM	99.3
15	Llamedo	3	1	Physionet	Cluster Centroid	96
16	Faziludeen	3	1	MIT-BIH	DVM	98.46
17	Chen	2	1	PTB database	Lineer Discrim.	85.57
18	Dima	2	1	Southampton	DVM	89.22
19	Saminu	3	1	MIT-BIH	Sinir Ağları	98.22
20	Banerjee	2	3	Physikalisch T.	Eşiğe Dayalı	97.6
21	Sahoo	5	1	MIT-BIH	DVM	98.11
22	Jacob	2	1	MIT-BIH	DVM	94.8
23	Saini	10	1	MIT-BIH	K-EYK	87.5
24	Sharma	2	1	PTB Diag.	DVM	96
25	Dewangan	5	1	MIT-BIH	Sinir Ağları	87
26	Sayilgan	7	1	MIT-BIH	Naive Bayes	92
27	Rad	5	1	OHCA	Sinir Ağları	78.5
	Yöntem	9	12	St. Petersburg	KSA	99.4

MATLAB ile 75 yarım saatlik EKG kayıtlarının (177812 RR aralığı) öznitelik hesaplaması için 777.626 saniye aldı. Öznitelik çıkarımı her RR aralığı için 4.37 ms sürmüştür. Özniteliklerin azaltılmasından sonra, testi tamamlamak için sadece 7.754 saniyeye ihtiyaç duyulmuştur. Benzer çalışmalarda analizler ile ilgili bir hız testi verisine rastlanılmamıştır. Ancak yöntemin diğer yöntemlere göre daha hızlı olduğu düşünülmektedir. Hjorth değişkenlerinin EKG sinyallerini işleme uygulamaları alanında kullanımı henüz az keşfedilmiştir. Benzer çalışmalarda Hjorth değişkenlerinin sadece birisi öznitelik olarak kullanılmıştır. Ancak bu çalışmada Hjorth değişkenlerinin hepsi öznitelik olarak kullanılmıştır. Hjorth tanımlayıcılar olarak bilinen değişkenler hareketlilik (mobility), aktivite (activity), karmaşıklık (complexity veya form-factor) olarak isimlendirilmiştir. Hareketlilik değişkeni güç spektruma ait standart sapmanın oranı ifade etmektedir. Aktivite enerjisiyi temsil eden sinyalin varyansıdır. Karmaşıklık frekanstaki değişimi temsil eder. Hjorth tanımlayıcılarını temel öznitelikler kabul edildiği ilk analizde bu değişkenlere ek olarak yine kolay hesaplanan korelasyon katsayısı, Akaike Bilgi Ölçütü (Akaike Information Criterion), sinyal gücünün aktiviteye oranı ve standart sapma ilave edildi. Bu analizde torbalama karar ağaçları sınıflandırma yöntemi kullanılarak eğitim için %97.82 doğruluk, test için %95.6 doğruluğa ulaşıldı. Diğer analizde ise Hjorth tanımlayıcılara ek olarak, sinyal ile matlab ortamında oluşturulmuş yapay EKG sinyalinin korelasyonu, içkin kip işlevi standart sapma değeri, sinyalin gücün aktivite değerine oranı ve de standart sapma değerinden oluşmakta olan öznitelikler kullanılmıştır. Bu analizde torbalama karar ağaçları sınıflandırma yöntemi kullanılarak eğitim için %98.8 doğruluk, test için %95.6 doğruluk elde edildi. Bu analizlerde sinyal 5 parçaya bölünmüştür ve öznitelikler her parça için ayrıca hesaplanmıştır. Öznitelik çıkarımı her RR aralığı için ortalama 6 ms sürmüştür. Hjorth tanımlayıcılarını temel öznitelikler kabul edildiği KSA ile yapılan sınıflandırmanın test aşamasındaki doğruluğu %96.5 seviyesindedir. İSA ile yapılan sınıflandırmada ise %80.2'lik bir doğruluk oranı elde edildi

Leite ve ark. RR aralığı, genlik ve Hjorth tanımlayıcılarını kullanarak % 90.4'lük doğruluk elde etti. Fujita ve ark. Hjorth tanımlayıcılarının içinde bulunduğu öznitelik seti ile AKÖ tespitinde DVM sınıflandırıcı kullanılarak iki, üç ve dört dakika önce % 97.3, % 89.4, % 89.4 ve % 94.7'lük başarı elde ettiler. Rizal ve ark. Physionet veri tabanında K-EYK ve ÇKA ile % 99.3'e ulaşan başarıya ulaşmıştır. Hadiyoso ve ark. benzer çalışmada % 90.4

başarı elde ettiler. Bu çalışmalarda hız değerleri ile ilgili sayısal bir değer verilmemiştir. Ancak çalışmamızın hız bilgisi verilmiştir ve hızlı olduğu düşünülmektedir. Yapılan bu çalışmada benzer çalışmalara göre geniş bir veri tabanında çalışma yapıldı. Böylece sonuçlar daha gerçekçi olmuştur. Ayrıca benzer çalışmalarda bir veya birkaç sınıflandırma yöntemi kullanılırken, bu çalışmada temel sınıflandırma yöntemlerine ait pek çok algoritma test edilmiştir. İlk analizde R-R aralığındaki sinyal 5 parçaya ayırdık ve her parça için çıkarılacak özniteliklere ek olarak yapay EKG sinyali ile korelasyon değeri, sinyal gücünün aktiviteye oranı, standart sapma ve Akaike Bilgi Ölçütünü ilave ederek temel sınıflandırma yöntemlerini karşılaştırdık. Torbalama Karar Ağaçları ile eğitim aşamasında ortalama %97.82 ve test aşamasında ortalama %95.6 başarıya ulaştık. İkinci analizde öznitelik olarak yapay EKG sinyali ile korelasyon değeri, içkin kip işlevi standart sapma değeri, sinyalin gücün aktivite değerine oranı ve de standart sapma öznitelikleri ilave ederek ve sınıflandırıcı olarak Torbalama Karar Ağaçlarını kullanarak eğitim için %98.8 ve test için %95.6 başarı elde edildi.

EKG sinyalinde aritmi tespitinde kullandığımız morfolojik öznitelikler P-P aralığı, ortalama, standart sapma, çarpıklık, Q ile S arasındaki mesafe, Q ile R arasındaki eğim, R ile S arasındaki eğim, Q'dan S'ye varyans değeri şeklindedir. St. Petersburg Kardiyoloji Tekniği Enstitüsü'nün 12 kanallı aritmi veri tabanında bu sekiz öznitelik kullanılarak değişik sınıflandırma yöntemleri karşılaştırılmış ve bu özniteliklerle kullanılabilir en uygun sınıflandırma yöntemi torbalama karar ağaçları olarak belirlenmiştir. Bu sınıflandırmada eğitim doğruluğu %95.9, test doğruluğu %95.8, hassaslık 0.89 ve özgünlük 0.99 olarak bulunmuştur. Öznitelik çıkarımı 177812 adet RR aralığı için 401.1 saniye sürmüştür. Her RR aralığı için ortalama 2.255 ms bulunmuştur. Diğer özniteliklere göre bu öznitelik çıkarımlarında elde ettiğimiz en hızlı süredir. . Yöntemimizin gerçek zamanlı aritmi tespiti için yeterince hızlı olduğunu söylenebilir. Morfolojik özniteliklerin kullanıldığı KSA ile yapılan sınıflandırmanın test aşamasındaki doğruluğu %99.8 seviyesindedir. İSA ile yapılan sınıflandırmada ise %90.2'lik bir doğruluk oranı elde edildi

Bu çalışmalar genellikle MIT-BIH aritmi veri tabanı kullanılarak yapılmıştır. Dalgacık katsayıları, Hjorth parametreleri, Morfolojik öznitelikleri birbirleri ile karşılaştırdığımızda dalgacık katsayılarının kararlı olduğu ve doğru sonuçlar verdiği tespit edildi. Hjorth parametreleri kullanılarak yapılan analizde sadece bu parametreleri kullanmanın yeterince kararlı sonuçlar vermediği görüldü. Bundan dolayı Hjorth parametrelerinin başka öznitelikler ile birlikte kullanımı daha kararlı ve başarılı sonuçlar elde etmek için tercih

edilmelidir. Morfolojik öznitelikler hızlı ve başarılı sonuçlar için kullanılabilir. Öznitelik hesaplama süresi en kısa olan yöntemdir ve özellikle gerçek zamanlı aritmi tespitinde kullanımı için daha uygundur. Bundan dolayı morfolojik öznitelikler kullanarak gerçek zamanlı aritmi tespiti için simulink modeli geliştirilmiştir. Bu analizde KSA kullanılarak oluşturulmuş bir karar verme mekanizması tercih edilmiştir. Tüm analizler için hızlı karar verme imkânı veren ve doğruluğu yüksek sistemler oluşturulması hedeflenmiştir. Basit ve güvenilir ve geliştirilmesi kolay olması hedeflenmiştir. Sistem yeterince hızlı hesaplama yapabilmekte, bundan dolayı gerçek zamanlı aritmi tespiti için RealTime Pacer bloğu kullanılabilir. Aritmi tespiti için geliştirilmiş benzer bir simulink modeline rastlanılmamıştır.

Öznitelik girişi olmadan sinyali giriş olarak kullanıp KSA’ında sınıflandırma yaparak hesaplama yükünün azalması ve işlemlerin kolaylaşması mümkündür. EKG sinyallerini giriş olarak verildiği ilk KSA mimarimizin test aşamasındaki doğruluğu %90.3 seviyesindedir ve ikinci KSA mimarimizin test aşamasındaki doğruluğu %94.1 seviyesindedir. Yüksek doğruluklu sınıflandırma yapmasına rağmen, KSA’da sonuçlar sezgisel değildir. KSA yapısında bulunan otomatik öznitelik çıkarımı sayesinde, çalışmamızda kullandığımız özniteliklere ek ayırt edici ve bilgi veren önemli ve yeni öznitelikler üretilebilir. Ayrıca, çoğu KSA özniteliklerinin birbirleriyle istatistiksel olarak ilişkili olduğu görülmüştür. Böylece, performans kaybı olmadan, korelasyon esaslı bir boyut azaltma kullanılabilir. Ancak çoğu makine öğrenme tekniği, anlamlı öznitelik değişkenlerinin tanımlanmasını tercih etmektedir. Öznitelik tanımlaması ve KSA kullanımının birlikte kullanılmasıyla daha başarılı sonuçlara ulaşılmaktadır. Böylece hızlı şekilde öğrenebilen ve yüksek doğruluğa ulaşan optimize edilmiş bir KSA’ı oluşturulabilir.

5.KAYNAKLAR

- Akdemir, B., Yarmohammadi, H., Alraies, M. C., ve Adkisson, W. O., 2016. Premature ventricular contractions: Reassure or refer?. Cleveland Clinic Journal of Medicine, 83,7, 525.
- Al Rahhal, M. M., Bazi, Y., AlHichri, H., Alajlan, N., Melgani, F., ve Yager, R. R., 2016. Deep learning approach for active classification of electrocardiogram signals. Information Sciences, 345, 340-354.
- Alipanahi, B., Delong, A., Weirauch, M. T., ve Frey, B. J., 2015. Predicting the sequence specificities of DNA-and RNA-binding proteins by deep learning. Nature Biotechnology, 33,8, 831.
- Altan, G., Kutlu, Y., ve Allahverdi, N., 2016. A Multistage Deep Belief Networks Application on Arrhythmia Classification. International Journal of Intelligent Systems and Applications in Engineering, 4(Special Issue-1), 222-228.
- An, X., Kuang, D., Guo, X., Zhao, Y., ve He, L., 2014. A deep learning method for classification of EEG data based on motor imagery. In International Conference on Intelligent Computing. Springer, Eylül, Çin, Bildiriler Kitabı: 203-210.
- Assodiky, H., Syarif, I., ve Badriyah, T., 2017. Deep learning algorithm for arrhythmia detection. In Knowledge Creation and Intelligent Computing (IES-KCIC), 2017 International Electronics Symposium, IEEE. ,Eylül, Surabaya, Bildiriler Kitabı: 26-32.
- Ayhan, S., ve Erdoğan, Ş., 2014. Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi, 9,1.
- Baldi, P., ve Sadowski, P. J., 2013. Understanding dropout. In Advances in neural information processing systems, Aralık, ABD, Bildiriler Kitabı: 2814-2822.
- Banerjee, S., ve Mitra, M., 2014. Application of cross wavelet transform for ECG pattern analysis and classification. IEEE Transactions on Instrumentation and Measurement, 63,2, 326-333.
- Bengio, Y., Lee, D. H., Bornschein, J., Mesnard, T., ve Lin, Z., 2015. Towards biologically plausible deep learning. arXiv preprint arXiv:1502.04156.
- Bengio, Y., Simard, P., ve Frasconi, P., 1994. Learning long-term dependencies with gradient descent is difficult. IEEE Transactions on Neural Networks, 5,2, 157-166.
- Bergstra, J. S., Bardenet, R., Bengio, Y., ve Kégl, B., 2011. Algorithms for hyper-parameter optimization. In Advances in neural information processing systems, 2546-2554.

- Bergstra, J., ve Bengio, Y., 2012. Random search for hyper-parameter optimization. Journal of Machine Learning Research, 13(Feb), 281-305.
- Bishop, C. M. ,2006. Pattern recognition and machine learning, Springer, 359-422.
- Blanco-Velasco, M., Cruz-Roldan, F., Godino-Llorente, J. I., ve Barner, K. E., 2010. Nonlinear trend estimation of the ventricular repolarization segment for T-wave alternans detection. IEEE Transactions on Biomedical Engineering, 57,10, 2402-2412.
- Bottou, L., 1991. Stochastic gradient learning in neural networks. Proceedings of NeuroNimes, 91,8, 12.
- Bouvier, J., 2006. Notes on convolutional neural networks. Unpublished.
- Breiman, L., 1996. Bagging predictors Machine learning, Chapman and Hall, 24,2, 123-140.
- Breiman, L., 2017. Classification and regression trees, Chapman and Hall, Routledge.
- Burch, G. E., ve DePasquale, N. P., 1990. A history of electrocardiography (No. 1). Norman Publishing.
- Burkitt, A. N., 2006. A review of the integrate-and-fire neuron model: I. Homogeneous synaptic input. Biological cybernetics, 95,1, 1-19.
- Burnham, K. P., ve Anderson, D. R., 2003. Model selection and multimodel inference: a practical information-theoretic approach. Springer Science and Business Media.
- Cao, Y., Steffey, S., He, J., Xiao, D., Tao, C., Chen, P., ve Müller, H., 2014. Medical image retrieval: a multimodal approach. Cancer informatics, 13, CIN-S14053.
- Caporale, N., ve Dan, Y., 2008. Spike timing–dependent plasticity: a Hebbian learning rule. Annual Review Of Neuroscience, 31, 25-46.
- Cecotti, H., ve Graser, A., 2011. Convolutional neural networks for P300 detection with application to brain-computer interfaces. IEEE Transactions on Pattern Analysis and Machine Intelligence, 33,3, 433-445.
- Chen, T., Mazomenos, E. B., Maharatna, K., Dasmahapatra, S., ve Niranjana, M., 2013. Design of a low-power on-body ECG classifier for remote cardiovascular monitoring systems. IEEE Journal on Emerging and Selected Topics in Circuits and Systems, 3,1, 75-85.
- Cheng, P., ve Dong, X., 2017. Life-Threatening Ventricular Arrhythmia Detection with Personalized Features. IEEE Access, 5, 14195-14203.
- Chiu, C. C., Lin, T. H., ve Liao, B. Y., 2005. Using correlation coefficient in ECG waveform for arrhythmia detection. Biomedical Engineering: Applications, Basis and Communications, 17,03, 147-152.

- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., ve Bengio, Y., 2014. Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078.
- Clifford, G. D., Azuaje, F., ve McSharry, P., 2006. Advanced methods and tools for ECG data analysis, Norwood, MA: Artech house, 55-57.
- Coppersmith, D., Hong, S. J., ve Hosking, J. R., 1999. Partitioning nominal attributes in decision trees. Data Mining and Knowledge Discovery, 3,2, 197-217.
- Cortes, C., ve Vapnik, V., 1995. Support-vector networks. Machine Learning, 20,3, 273-297.
- Cover, T., ve Hart, P., 1967. Nearest neighbor pattern classification. IEEE Transactions on Information Theory, 13,1, 21-27.
- Cristianini, N., ve Shawe-Taylor, J., 2000. An introduction to support vector machines and other kernel-based learning methods. Cambridge university press.
- Dash, S., Chon, K. H., Lu, S., ve Raeder, E. A., 2009. Automatic real time detection of atrial fibrillation. Annals of Biomedical Engineering, 37,9, 1701-1709.
- Davidson, P. R., Jones, R. D., ve Peiris, M. T., 2007. EEG-based lapse detection with high temporal resolution. IEEE Transactions on Biomedical Engineering, 54,5, 832-839.
- De Cooman, T., Goovaerts, G., Varon, C., Widjaja, D., ve Van Huffel, S., 2014. Heart beat detection in multimodal data using signal recognition and beat location estimation. In Computing in Cardiology Conference (CinC), IEEE, Eylül, ABD Bildiriler Kitabı: 257-260.
- Dewangan, N. K., ve Shukla, S. P., 2016. ECG arrhythmia classification using discrete wavelet transform and artificial neural network. In Recent Trends in Electronics, Information and Communication Technology (RTEICT), Mayıs, New Delhi, Bildiriler Kitabı: 1892-1896.
- Diehl, P. U., Neil, D., Binas, J., Cook, M., Liu, S. C., ve Pfeiffer, M., 2015. Fast-classifying, high-accuracy spiking deep networks through weight and threshold balancing. In Neural Networks (IJCNN), 2015 International Joint Conference. IEEE, Temmuz, İrlanda, Bildiriler Kitabı: 1-8.
- Dima, S. M., Panagiotou, C., Mazomenos, E. B., Rosengarten, J. A., Maharatna, K., Gialelis, J. V., ... ve Morgan, J., 2013. On the detection of myocardial scar based on ECG/VCG analysis. IEEE Transactions on Biomedical Engineering, 60,12, 3399-3409.
- Dokur, Z., Olmez, T., ve Yazgan, E., 1999. ECG waveform classification using the neural network and wavelet transform. In [Engineering in Medicine and Biology, 1999. 21st Annual Conference and the 1999 Annual Fall Meeting of the Biomedical Engineering Society] BMES/EMBS Conference, 1999. Proceedings of the First Joint. Mart, Londra, Bildiriler Kitabı: 273.

- Emanet, N., 2009, September. ECG beat classification by using discrete wavelet transform and Random Forest algorithm. In *Soft Computing, Computing with Words and Perceptions in System Analysis, Decision and Control, 2009. ICSCCW 2009. Fifth International Conference IEEE*, Eylül, ABD, Bildiriler Kitabı: 1-4.
- Erhan, D., Bengio, Y., Courville, A., ve Vincent, P., 2009. Visualizing higher-layer features of a deep network. *University of Montreal*, 1341(3), 1.
- Erhan, D., Bengio, Y., Courville, A., Manzagol, P. A., Vincent, P., ve Bengio, S., 2010. Why does unsupervised pre-training help deep learning?. *Journal of Machine Learning Research*, 11(Feb), 625-660.
- Faziludeen, S., ve Sabiq, P. V., 2013. ECG beat classification using wavelets and SVM. In *Information and Communication Technologies (ICT), 2013 IEEE*, Nisan, Hindistan, Bildiriler Kitabı: 815-818.
- Ferrucci, D., Brown, E., Chu-Carroll, J., Fan, J., Gondek, D., Kalyanpur, A. A., ve Schlaefer, N., 2010. Building Watson: An overview of the DeepQA project. *AI Magazine*, 31,3, 59-79.
- Fisher, R. A., 1936. The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 7,2, 179-188.
- Freund, Y., ve Schapire, R. E., 1997. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 55,1, 119-139.
- Fujita, H., Acharya, U. R., Sudarshan, V. K., Ghista, D. N., Sree, S. V., Eugene, L. W. J., ve Koh, J. E., 2016. Sudden cardiac death (SCD) prediction based on nonlinear heart rate variability features and SCD index. *Applied Soft Computing*, 43, 510-519.
- Gerstner, W., ve Kistler, W. M., 2002. *Spiking neuron models: Single neurons, populations, plasticity*. Cambridge university press.
- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark R.G., Mietus, J. E., Moody, G.B., Peng, C. K. ve Stanley, H. E., 2000. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 101(23):e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/content/101/23/e215.full>].
- Goldberger, A. L., Goldberger, Z. D., ve Shvilkin, A., 2017. *Clinical Electrocardiography: A Simplified Approach E-Book*. Elsevier Health Sciences..
- Goodfellow, I. J., Warde-Farley, D., Mirza, M., Courville, A., ve Bengio, Y., 2013. Maxout networks. arXiv preprint arXiv:1302.4389.
- Goodfellow, I., Bengio, Y., Courville, A., ve Bengio, Y., 2016. *Deep learning Vol. 1*. Cambridge: MIT press.

- Gradl, S., Kugler, P., Lohmüller, C., ve Eskofier, B., 2012, August. Real-time ECG monitoring and arrhythmia detection using Android-based mobile devices. In *Engineering in Medicine and Biology Society (EMBC), 2012 Annual International Conference of the IEEE, Ağustos, ABD, Bildiriler Kitabı: 2452-2455.*
- Graves, A., ve Schmidhuber, J., 2009. Offline handwriting recognition with multidimensional recurrent neural networks. *In Advances in Neural Information Processing Systems, 545-552.*
- Hadiyoso, S., ve Rizal, A., 2017. Electrocardiogram Signal Classification Using Higher-Order Complexity of Hjorth Descriptor. *Advanced Science Letters, 23,5, 3972-3974.*
- Hadsell, R., Sermanet, P., Ben, J., Erkan, A., Scoffier, M., Kavukcuoglu, K., ... ve LeCun, Y., 2009. Learning long-range vision for autonomous off-road driving. *Journal of Field Robotics, 26,2, 120-144.*
- Hecht-Nielsen, R., 1989 . Theory of the backpropagation neural network. In: *Neural Networks. IJCNN., International Joint Conference IEEE, ABD, Bildiriler Kitabı: 593-605.*
- Hochreiter, S., ve Schmidhuber, J., 1997. Long short-term memory. *Neural Computation, 9,8, 1735-1780.*
- Hodgkin, A. L., ve Huxley, A. F., 1952 . A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of Physiology, 117,4, 500-544.*
- Horowitz, S. L., 1975. A syntactic algorithm for peak detection in waveforms with applications to cardiography. *Communications of the ACM, 18, 5, 281-285.*
- Houghton, A., ve Gray, D., 2008. Making sense of the ECG: a hands-on guide. CRC Press.
- Hsu, D., Kakade, S. M., ve Zhang, T., 2012. A spectral algorithm for learning hidden Markov models. *Journal of Computer and System Sciences, 78,5, 1460-1480.*
- Huanhuan, M., ve Yue, Z., 2014. Classification of electrocardiogram signals with deep belief networks. In *Computational Science and Engineering (CSE), 2014 IEEE 17th International Conference IEEE, Aralık, Çin, Bildiriler Kitabı: 7-12.*
- Hubel, D. H., ve Wiesel, T. N., 1968. Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology, 195,1, 215-243.*
- Huff, J., 2006. ECG workout: Exercises in arrhythmia interpretation. Lippincott Williams and Wilkins.
- Hutter, F., Hoos, H. H., ve Leyton-Brown, K., 2011. Sequential model-based optimization for general algorithm configuration. In *International Conference on Learning and Intelligent Optimization, Ocak, Berlin, Bildiriler Kitabı: 507-523.*

- Ioffe, S., ve Szegedy, C., 2015. Batch normalization: Accelerating deep network training by reducing internal covariate shift. arXiv preprint arXiv:1502.03167.
- Iwata, A., Nagasaka, Y., ve Suzumura, N., 1990. Data compression of the ECG using neural network for digital Holter monitor. IEEE Engineering in Medicine and Biology Magazine, 9,3, 53-57.
- İşler, Y., ve Kuntalp, M., 2007. Combining classical HRV indices with wavelet entropy measures improves to performance in diagnosing congestive heart failure. Computers in Biology and Medicine, 37,10, 1502-1510.
- Jacob, N., ve Joseph, L. A., 2015. Classification of ECG beats using cross wavelet transform and support vector machines. In Intelligent Computational Systems (RAICS), 2015 IEEE Recent Advances, Aralık, Thiruvananthapuram, Bildiriler Kitabı: 191-194.
- Jekova, I., ve Krasteva, V., 2004. Real time detection of ventricular fibrillation and tachycardia. Physiological Measurement, 25,5, 1167.
- Jia, X., Li, K., Li, X., ve Zhang, A., 2014. A novel semi-supervised deep learning framework for affective state recognition on eeg signals. In Bioinformatics and Bioengineering (BIBE), 2014 IEEE, Kasım, ABD, Bildiriler Kitabı: 30-37.
- Jiang, C., Song, S., ve Meng, M. Q. H., 2017. Heartbeat classification system based on modified stacked denoising autoencoders and neural networks. In Information and Automation (ICIA), 2017 IEEE, Temmuz, Çin, Bildiriler Kitabı: 511-516.
- Jiang, X., Zhang, L., Zhao, Q., ve Albayrak, S., 2006. ECG arrhythmias recognition system based on independent component analysis feature extraction. In TENCON 2006. IEEE, Aralık, Çin, Bildiriler Kitabı: 1-4.
- Jolliffe, I., 2011. Principal component analysis. In International encyclopedia of statistical science, Springer, Berlin, Heidelberg, 1094-1096.
- Kardys, I., Kors, J. A., van der Meer, I. M., Hofman, A., van der Kuip, D. A., ve Witteman, J. C., 2003. Spatial QRS-T angle predicts cardiac death in a general population. European Heart Journal, 24,14, 1357-1364.
- Kasabov, N., Dhoble, K., Nuntalid, N., ve Indiveri, G., 2013. Dynamic evolving spiking neural networks for on-line spatio-and spectro-temporal pattern recognition. Neural Networks, 41, 188-201.
- Kelley, D. R., Snoek, J., ve Rinn, J. L., 2016. Basset: learning the regulatory code of the accessible genome with deep convolutional neural networks. Genome research.
- Kiranyaz, S., Ince, T., ve Gabbouj, M., 2016. Real-time patient-specific ECG classification by 1-D convolutional neural networks. IEEE Transactions on Biomedical Engineering, 63,3, 664-675.

- Krogh, A., ve Hertz, J. A., 1992. A simple weight decay can improve generalization. In *Advances in neural information processing systems*, 950-957.
- Kundu, M., Nasipuri, M., Basu, D. K., ve Bhattacharya, A., 1993. A reasoning system for on-line interpretation of ECG signal. In *TENCON'93. Proceedings. Computer, Communication, Control and Power Engineering. 1993 IEEE Region 10 Conference*, Ekim, Çin, *Bildiriler Kitabı*: 626-630.
- Kutlu, Y., Altan, G., ve Allahverdi, N., 2016. Arrhythmia classification using waveform ECG signals. In *International conference on advanced technology and sciences Google Scholar*.
- Le, Q. V., Ngiam, J., Coates, A., Lahiri, A., Prochnow, B., ve Ng, A. Y., 2011. On optimization methods for deep learning. In *Proceedings of the 28th International Conference on International Conference on Machine Learning Omnipress, Haziran, ABD, Bildiriler Kitabı*: 265-272.
- LeCun, Y., ve Ranzato, M., 2013. Deep learning tutorial. In *Tutorials in International Conference on Machine Learning (ICML'13), Haziran, ABD, Bildiriler Kitabı*: 1-29.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015. *Deep learning. Nature*, 521,7553, 436-44.
- LeCun, Y., Bottou, L., Bengio, Y., ve Haffner, P., 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86,11, 2278-2324.
- Lee, T., ve Yoon, S., 2015. Boosted categorical restricted Boltzmann machine for computational prediction of splice junctions. In *International Conference on Machine Learning, Haziran, Fransa, Bildiriler Kitabı*: 2483-2492.
- Leite, J. P. R., ve Moreno, R. L., 2017. Heartbeat classification with low computational cost using Hjorth parameters. *IET Signal Processing*, 12,4, 431-438.
- Lekha, S., ve Suchetha, M., 2018. A Novel 1-D Convolution Neural Network With SVM Architecture for Real-Time Detection Applications. *IEEE Sensors Journal*, 18,2, 724-731.
- Lena, P. D., Nagata, K., ve Baldi, P. F., 2012. Deep spatio-temporal architectures and learning for protein structure prediction. In *Advances in Neural Information Processing Systems*, 512-520.
- Leung, M. K., DeLong, A., Alipanahi, B., ve Frey, B. J., 2016. Machine learning in genomic medicine: a review of computational problems and data sets. *Proceedings of the IEEE*, 104,1, 176-197.
- Li, J., Luong, M. T., ve Jurafsky, D., 2015. A hierarchical neural autoencoder for paragraphs and documents. arXiv preprint arXiv:1506.01057.
- Li, W., ve Li, J., 2018. Local Deep Field for Electrocardiogram Beat Classification. *IEEE Sensors Journal*, 18,4, 1656-1664.

- Li, Y., Bisera, J., Weil, M. H., ve Tang, W., 2012. An algorithm used for ventricular fibrillation detection without interrupting chest compression. IEEE Transactions on Biomedical Engineering, 59,1, 78-86.
- Lim, J. S., 2009. Finding features for real-time premature ventricular contraction detection using a fuzzy neural network system. IEEE Transactions on Neural Networks, 20,3, 522-527.
- Liu, Y., Huang, Y., Wang, J., Liu, L., ve Luo, J., 2018. Detecting Premature Ventricular Contraction in Children with Deep Learning. Journal of Shanghai Jiaotong University (Science), 23,1, 66-73.
- Llamedo, M., ve Martínez, J. P., 2011. Heartbeat classification using feature selection driven by database generalization criteria. IEEE Transactions on Biomedical Engineering, 58,3, 616-625.
- Llamedo, M., ve Martínez, J. P., 2012. An automatic patient-adapted ECG heartbeat classifier allowing expert assistance. IEEE Transactions on Biomedical Engineering, 59,8, 2312-2320.
- Luong, M. T., Pham, H., ve Manning, C. D. , 2015. Effective approaches to attention-based neural machine translation. arXiv preprint arXiv:1508.04025.
- Maass, W., 1997. Networks of spiking neurons: the third generation of neural network models. Neural Networks, 10,9, 1659-1671.
- Mallat, S., 2008. A wavelet tour of signal processing: the sparse way. Academic press.
- Martens, J., 2010, June. Deep learning via Hessian-free optimization. In ICML, Haziran, İsrail, Bildiriler Kitabı: 735-742.
- Masci, J., Meier, U., Cireşan, D., ve Schmidhuber, J., 2011. Stacked convolutional auto-encoders for hierarchical feature extraction. In International Conference on Artificial Neural Networks, Haziran, Berlin, Bildiriler Kitabı: 52-59.
- Menard, S., 2002. Applied logistic regression analysis (Vol. 106). Sage.
- Min, S., Lee, B., ve Yoon, S., 2017. Deep learning in bioinformatics. Briefings in Bioinformatics, 18,5, 851-869.
- Mirowski, P., Madhavan, D., LeCun, Y., ve Kuzniecky, R., 2009. Classification of patterns of EEG synchronization for seizure prediction. Clinical Neurophysiology, 120,11, 1927-1940.
- Moon, T., Choi, H., Lee, H., ve Song, I., 2015. Rnndrop: A novel dropout for rnns in asr. In Automatic Speech Recognition and Understanding (ASRU), 2015 IEEE Workshop, Aralık, ABD, Bildiriler Kitabı: 65-70.

- Nair, V., ve Hinton, G. E., 2010. Rectified linear units improve restricted boltzmann machines. In Proceedings of the 27th international conference on machine learning (ICML-10), Haziran, İsrail, Bildiriler Kitabı: 807-814.
- Neftci, E. O., Augustine, C., Paul, S., ve Detorakis, G., 2017. Event-driven random back-propagation: Enabling neuromorphic deep learning machines. Frontiers in Neuroscience, 11, 324.
- Neil, D., Pfeiffer, M., ve Liu, S. C., 2016. Learning to be efficient: algorithms for training low-latency, low-compute deep spiking neural networks. In Proceedings of the 31st Annual ACM Symposium on Applied Computing ACM, Nisan, Kanada, Bildiriler Kitabı: 293-298.
- Ngiam, J., Khosla, A., Kim, M., Nam, J., Lee, H., ve Ng, A. Y., 2011. Multimodal deep learning. In Proceedings of the 28th international conference on machine learning (ICML-11), Temmuz, ABD, Bildiriler Kitabı: 689-696.
- O'Connor, P., ve Welling, M., 2016. Deep spiking networks. arXiv preprint arXiv:1602.08323.
- O'Reilly, R. C., Munakata, Y., Frank, M. J., ve Hazy, T. E., 2012. Computational cognitive neuroscience. PediaPress.
- Oresko, J. J., Jin, Z., Cheng, J., Huang, S., Sun, Y., Duschl, H., ve Cheng, A. C., 2010. A wearable smartphone-based platform for real-time cardiovascular disease detection via electrocardiogram processing. IEEE Transactions on Information Technology in Biomedicine, 14,3, 734-740.
- Ovtcharov, K., Ruwase, O., Kim, J. Y., Fowers, J., Strauss, K., ve Chung, E. S., 2015. Accelerating deep convolutional neural networks using specialized hardware. Microsoft Research Whitepaper, 2(11).
- Pan, J., ve Tompkins, W. J., 1985. A real-time QRS detection algorithm. IEEE Transactions on Biomedical Engineering, 32,3, 230-236.
- Papakonstantinou, G., ve Gritzali, F., 1981. Syntactic filtering of ECG waveforms. Computers and Biomedical Research, 14,2, 158-167.
- Papakonstantinou, G., Skordalakis, E., ve Gritzali, F., 1986. An attribute grammar for QRS detection. Pattern Recognition, 19,4, 297-303.
- Patel, A. M., Gakare, P. K., ve Cheeran, A. N., 2012. Real time ECG feature extraction and arrhythmia detection on a mobile platform. International Journal of Computer Applications, 44,23, 40-45.
- Petrosian, A., Prokhorov, D., Homan, R., Dasheiff, R., ve Wunsch II, D., 2000. Recurrent neural network based prediction of epileptic seizures in intra-and extracranial EEG. Neurocomputing, 30,1-4, 201-218.

- Ponulak, F., ve Kasinski, A., 2011. Introduction to spiking neural networks: Information processing, learning and applications. Acta Neurobiologiae Experimentalis, 71,4, 409-433.
- Prasad, G. K., ve Sahambi, J. S., 2003. Classification of ECG arrhythmias using multi-resolution analysis and neural networks. In TENCON 2003. Conference on Convergent Technologies for the Asia-Pacific Region Vol. 1, IEEE, Ekim, Hindistan, Bildiriler Kitabı: 227-231.
- Rad, A. B., Eftestøl, T., Engan, K., Irusta, U., Kvaløy, J. T., Kramer-Johansen, J., ... ve Katsaggelos, A. K., 2017. ECG-based classification of resuscitation cardiac rhythms for retrospective data analysis. IEEE Transactions on Biomedical Engineering, 64,10, 2411-2418.
- Rai, H. M., ve Trivedi, A., 2012. ECG signal classification using wavelet transform and Back Propagation Neural Network. In Computers and Devices for Communication (CODEC), 2012 5th International Conference IEEE, Aralık, Hindistan, Bildiriler Kitabı: 1-4.
- Rai, H. M., Trivedi, A., Shukla, S., ve Dubey, V., 2012, . ECG arrhythmia classification using daubechies wavelet and radial basis function neural network. In Nirma University International Conference on Engineering (NUiCONE), Aralık, Hindistan, Bildiriler Kitabı: 1-4.
- Rasmus, A., Berglund, M., Honkala, M., Valpola, H., ve Raiko, T., 2015. Semi-supervised learning with ladder networks. In Advances in Neural Information Processing Systems, 3546-3554.
- Rizal, A., ve Hadiyoso, S., 2015. ECG signal classification using Hjorth Descriptor. In Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology (ICACOMIT), 2015 International Conference IEEE, Ekim, Endonezya, Bildiriler Kitabı: 87-90.
- Rizal, A., Hidayat, R., ve Nugroho, H. A., 2015. Determining lung sound characterization using Hjorth descriptor. In Control, Electronics, Renewable Energy and Communications (ICCEREC), 2015 International Conference IEEE, Ağustos, Endonezya, Bildiriler Kitabı: 54-57.
- Rodriguez, J., Goni, A., ve Illarramendi, A., 2005. Real-time classification of ECGs on a PDA. IEEE Transactions on Information Technology in Biomedicine, 9,1, 23-34.
- Rokach, L., ve Maimon, O. Z., 2008. Data mining with decision trees: theory and applications (Vol. 69). World scientific.
- Ruha, A., Sallinen, S., ve Nissila, S., 1997. A real-time microprocessor QRS detector system with a 1-ms timing accuracy for the measurement of ambulatory HRV. IEEE Transactions on Biomedical Engineering, 44,3, 159-167.

- Sahoo, S. K., Subudhi, A., Kanungo, B. ve Sabut, S. K., 2015. Feature extraction of ECG signal based on wavelet transform for arrhythmia detection. In: Electrical, Electronics, Signals, Communication and Optimization (EESCO), International Conference, Ocak, Hindistan, Bildiriler Kitabı: 1-5.
- Saini, R., Bindal, N., ve Bansal, P., 2015. Classification of heart diseases from ECG signals using wavelet transform and kNN classifier. In Computing, Communication and Automation (ICCCA), 2015 International Conference IEEE, Mayıs, Hindistan, Bildiriler Kitabı: 1208-1215.
- Saminu, S., Özkurt, N., ve Karaye, I. A., 2014. Wavelet feature extraction for ECG beat classification. In Adaptive Science and Technology (ICAST), 2014 IEEE 6th International Conference on (pp. 1-6). IEEE, Ekim, Lagos, Bildiriler Kitabı: 1-6.
- Sayilgan, E., Cura, Ö. K., ve İşler, Y., 2017. Use of clustering algorithms and extreme learning machine in determining arrhythmia types. In Signal Processing and Communications Applications Conference (SIU), IEEE, Mayıs, Antalya, Türkiye, Bildiriler Kitabı: 1-4.
- Schapire, R. E., ve Singer, Y., 1999. Improved boosting algorithms using confidence-rated predictions. Machine Learning, 37,3, 297-336.
- Sharma, L. N., Tripathy, R. K., ve Dandapat, S., 2015. Multiscale energy and eigenspace approach to detection and localization of myocardial infarction. IEEE Transactions on Biomedical Engineering, 62,7, 1827-1837.
- Shibl, R., Lawley, M., ve Debus, J., 2013. Factors influencing decision support system acceptance. Decision Support Systems, 54,2, 953-961.
- Shyu, L. Y., Wu, Y. H., ve Hu, W., 2004. Using wavelet transform and fuzzy neural network for VPC detection from the Holter ECG. IEEE Transactions on Biomedical Engineering, 51,7, 1269-1273.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., ... ve Dieleman, S., 2016. Mastering the game of Go with deep neural networks and tree search. Nature, 529,7587, 484.
- Snoek, J., Larochelle, H., ve Adams, R. P., 2012. Practical bayesian optimization of machine learning algorithms. In Advances in neural information processing systems, 2951-2959.
- Soleymani, M., Asghari-Esfeden, S., Pantic, M., ve Fu, Y., 2014. Continuous emotion detection using EEG signals and facial expressions. In Multimedia and Expo (ICME), 2014 IEEE International Conference, Temmuz, Endonezya, Bildiriler Kitabı: 1-6.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., ve Salakhutdinov, R., 2014. Dropout: a simple way to prevent neural networks from overfitting. The Journal of Machine Learning Research, 15,1, 1929-1958.

- Stober, S., Cameron, D. J., ve Grahn, J. A., 2014. Using Convolutional Neural Networks to Recognize Rhythm Stimuli from Electroencephalography Recordings. In *Advances in neural information processing systems*, 1449-1457.
- Stober, S., Sternin, A., Owen, A. M., ve Grahn, J. A., 2015. Deep feature learning for EEG recordings. arXiv preprint arXiv:1511.04306.
- Stockman, G. C., ve Kanal, L. N., 1983. Problem reduction representation for the linguistic analysis of waveforms. IEEE Transactions on Pattern Analysis and Machine Intelligence, 3, 287-298.
- Stork, D. G., ve Yom-Tov, E., 2004. Computer manual in MATLAB to accompany pattern classification. Wiley-Interscience.
- Suk, H. I., ve Shen, D., 2013. Deep learning-based feature representation for AD/MCI classification. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Eylül, Berlin, Bildiriler Kitabı: 583-590.
- Svozil, D., Kvasnicka, V., ve Pospichal, J., 1997. Introduction to multi-layer feed-forward neural networks. Chemometrics and Intelligent Laboratory Systems, 39,1, 43-62.
- Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I., ve Fergus, R., 2013. Intriguing properties of neural networks. arXiv preprint arXiv:1312.6199.
- Taji, B., Chan, A. D., ve Shirmohammadi, S., 2017. Classifying measured electrocardiogram signal quality using deep belief networks. In *Instrumentation and Measurement Technology Conference (I2MTC), 2017 IEEE*, Mayıs, İtalya, Bildiriler Kitabı: 1-6.
- Tomak, Ö., ve Kayıkçıoğlu, T., 2017. Comparison of different classification algorithms using easily calculated features. In *Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT), 2017, IEEE*, Nisan, İstanbul, Türkiye, Bildiriler Kitabı: 1-4.
- Tomak, Ö., ve Kayıkçıoğlu, T., 2018. Bagged tree classification of arrhythmia using wavelets for denoising, compression, and feature extraction. Turkish Journal of Electrical Engineering & Computer Sciences, 26,3, 1555-1571.
- Trahanias, P., ve Skordalakis, E., 1990. Syntactic pattern recognition of the ECG. IEEE Transactions on Pattern Analysis and Machine Intelligence, 12,7, 648-657.
- Turner, J. T., Page, A., Mohsenin, T., ve Oates, T., 2014. Deep belief networks used on high resolution multichannel electroencephalography data for seizure detection. In *2014 AAAI Spring Symposium Series*, Temmuz, Kanada, Bildiriler Kitabı: 1-4.
- Udupa, J. K., ve Murthy, I. S., 1980. Syntactic approach to ECG rhythm analysis. IEEE Transactions on Biomedical Engineering, 7, 370-375.
- URL-1, www.mathworks.com/help/stats/classificationlearner-app.html Classification Learner. 1 Aralık 2017.

- URL-2, www.mathworks.com/matlabcentral/mlc-downloads/downloads/submissions/29107/versions/2/previews/RealTime_Pacer/realtime_pacer_help.html RealTime Pacer. 1 Mayıs 2018.
- URL-3, www.embedded-vision.com/platinum-members/cadence/embedded-vision-training/documents/pages/neuralnetworksimagerecognition, Neural Networks Image Recognition, 1 Haziran 2018.
- URL-4, cs231n.stanford.edu/slides/2016/winter1516_lecture7.pdf Lecture Notes in Cs231n Convolutional Neural Networks for Visual Recognition, 24 Mayıs 2018.
- URL-5, www.electronicdesign.com/embedded-revolution/brainchip-enters-ai-territory-spiking-neural-network BrainChip Enters AI Territory with Spiking Neural Network, 1 Haziran 2018
- URL-6, ecglibrary.com/ ECG library, 1 Haziran 2018
- URL-7, thew-project.org/Arrhythmia_LibSys/cardiac_arrhythmia.htm Cardiac Arrhythmia, 1 Haziran 2018
- Valderrama, M., Alvarado, C., Nikolopoulos, S., Martinerie, J., Adam, C., Navarro, V., ve Le Van Quyen, M. (2012). Identifying an increased risk of epileptic seizures using a multi-feature EEG–ECG classification. Biomedical Signal Processing and Control, 7,3, 237-244.
- Wang, Z., Lyu, S., Schalk, G., ve Ji, Q., 2013. Deep Feature Learning Using Target Priors with Applications in ECoG Signal Decoding for BCI. In IJCAI, Ağustos, Çin, Bildiriler Kitabı: 1785-1791.
- Wen, C., Yeh, M. F., Chang, K. C., ve Lee, R. G., 2008. Real-time ECG telemonitoring system design with mobile phone platform. Measurement, 41,4, 463-470.
- Wu, Z., Ding, X., Zhang, G., Xu, X., Wang, X., Tao, Y., ve Ju, C., 2016. A novel features learning method for ECG arrhythmias using deep belief networks. In Digital Home (ICDH), 2016 6th International Conference IEEE, Kasım, Londra, Bildiriler Kitabı: 192-196.
- Wulsin, D. F., Gupta, J. R., Mani, R., Blanco, J. A., ve Litt, B., 2011. Modeling electroencephalography waveforms with semi-supervised deep belief nets: fast classification and anomaly measurement. Journal of Neural Engineering, 8,3, 036015.
- Xia, Y., Zhang, H., Xu, L., Gao, Z., Zhang, H., Liu, H., ve Li, S., 2018 . An automatic cardiac arrhythmia classification system with wearable electrocardiogram. IEEE Access, 6, 16529-16538.
- Xue, Q., ve Reddy, B. S., 1997. Late potential recognition by artificial neural networks. IEEE Transactions on Biomedical Engineering, 44,2, 132-143.

- Xue, Q., Hu, Y. H., ve Tompkins, W. J., 1992. Neural-network-based adaptive matched filtering for QRS detection. IEEE Transactions on Biomedical Engineering, 39,4, 317-329.
- Ye, C., Coimbra, M. T., ve Kumar, B. V., 2010. Arrhythmia detection and classification using morphological and dynamic features of ECG signals. In Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference IEEE, Ağustos, Arjantin, Bildiriler Kitabı: 1918-1921.
- Ye, C., Kumar, B. V., ve Coimbra, M. T. (2012). Heartbeat classification using morphological and dynamic features of ECG signals. IEEE Transactions on Biomedical Engineering, 59,10, 2930-2941.
- Yu, S. N., ve Chen, Y. H., 2007. Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network. Pattern Recognition Letters, 28,10, 1142-1150.
- Zeiler, M. D., ve Fergus, R., 2014. Visualizing and understanding convolutional networks. In European conference on computer vision Springer, Cham, Eylül, Zürich, Bildiriler Kitabı: 818-833.
- Zellmer, E., Shang, F., ve Zhang, H., 2009. Highly accurate ECG beat classification based on continuous wavelet transformation and multiple support vector machine classifiers. In Biomedical Engineering and Informatics, 2009. BMEI'09. 2nd International Conference IEEE, Ekim, Çin, Bildiriler Kitabı: 1-5.
- Zhao, Q., ve Zhang, L., 2005. ECG feature extraction and classification using wavelet transform and support vector machines. In Neural Networks and Brain, 2005. ICNNandB'05. International Conference IEEE, Ekim, Çin, Bildiriler Kitabı: 1089-1092.
- Zhao, Y., ve He, L., 2014, November. Deep learning in the EEG diagnosis of Alzheimer's disease. In Asian Conference on Computer Vision Springer, Cham, Kasım, Singapur, Bildiriler Kitabı: 340-353.

ÖZGEÇMİŞ

22.10.1977 tarihinde Ankara'da doğdu. Liseyi Konya Meram Anadolu Lisesi'nde tamamladı. 1995'de kazandığı Orta Doğu Teknik Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Bölümü'nün Lisans Programı'nı 2000 yılında tamamladı. 2000 yılında Orta Doğu Teknik Üniversitesinde Yüksek Lisans-Doktora çalışmalarına başladı. Doktora Yeterlilik aşamasında 2007 yılında Orta Doğu Teknik Üniversitesinden ayrıldı. Giresun Üniversitesinde Enerji Sistemleri Mühendisliği Ana Bilim Dalı'nda yüksek lisans eğitimi tamamladı. Karadeniz Teknik Üniversitesinde Doktora çalışmalarına 2012 yılında başladı. İngilizceyi iyi seviyede bilmektedir. 2007 yılında Giresun Üniversitesi'nde Öğretim Görevlisi olarak çalışmaya başladı. Halen Öğretim Görevlisi olarak görev yapmaktadır.

SCI/SCI-E indekslerine giren dergilerde yayınlanan makaleler

1. Tomak, Ö., ve Kayıkçıoğlu, T., 2018. Bagged tree classification of arrhythmia using wavelets for denoising, compression, and feature extraction, Turkish Journal of Electrical Engineering & Computer Sciences, 26, 3. 1555-1571.

Diğer indekslere giren dergilerde yayınlanan makaleler

1. Tomak, Ö., ve Kayıkçıoğlu, T., 2017. Gerçek Zamanlı Aritmi Tespitinde Farklı Sınıflandırma Yöntemlerinin Karşılaştırılması, Karadeniz Fen Bilimleri Dergisi, 7,2. 1-9.

Yerli/Yabancı hakemli sempozyumların bildiri kitaplarında yer alan yayınlar

1. Tomak, Ö., ve Kayıkçıoğlu, T., 2017. EKG Sinyalinde Dalgacık sıkıştırmasının Sınıflandırmaya Etkisi, 25th Signal Processing and Communication Application Conference (SIU 2017), IEEE. Antalya, Türkiye, 1657-1660. ISBN: 978-1-5090-1679-2.
2. Tomak, Ö., ve Kayıkçıoğlu, T., 2017. Comparison of different clasification algorithms using easily calculated features., Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT 2017), IEEE. İstanbul, Türkiye, 1-4. ISBN: 978-1-5386-0440-3.
3. Tomak, Ö., ve Kayıkçıoğlu, T., 2016. Hjorth Tanımlayıcılar Kullanarak Aritmi Tespitinde Farklı Sınıflandırma Yöntemlerinin Karşılaştırılması, 24th Signal Processing and Communication Application Conference (SIU 2016), IEEE. Zonguldak, Türkiye, 1-4. ISBN: 978-1-5090-1679-2.