

T.C.

SELÇUK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

**ÖZELLİK ÇIKARMA TEKNİKLERİ
VE YAPAY SİNİR AĞLARI KULLANARAK
BİR TELE-KARDİYOLOJİ SİSTEM TASARIMI**

Rahime CEYLAN

DOKTORA TEZİ

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
Konya, 2009**

T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ÖZELLİK ÇIKARMA TEKNİKLERİ VE YAPAY SİNİR AĞLARI
KULLANARAK BİR TELE-KARDİYOLOJİ SİSTEM TASARIMI**

Rahime CEYLAN

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Bu tez 07/05/2009 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

Prof. Dr. Osman Nuri UÇAN
(Üye)

Prof. Dr. Saadetdin HERDEM
(Üye)

Doç. Dr. Mehmet YAZICI
(Üye)

Doç. Dr. Yüksel ÖZBAY
(1.Danışman)

Doç. Dr. Salih GÜNEŞ
(Üye)

ÖZET

Doktora Tezi

ÖZELLİK ÇIKARMA TEKNİKLERİ VE YAPAY SİNİR AĞLARI KULLANARAK BİR TELE-KARDİYOLOJİ SİSTEM TASARIMI

Rahime CEYLAN

Selçuk Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

1. Danışman: Doç. Dr. Yüksel ÖZBAY
2. Danışman: Prof. Dr. Bekir KARLIK

2009, 187 sayfa

Jüri: Prof Dr. Osman Nuri UÇAN
Prof. Dr. Saadetdin HERDEM
Doç. Dr. Mehmet YAZICI
Doç. Dr. Yüksel ÖZBAY
Doç. Dr. Salih GÜNEŞ

Şehir merkezlerinden uzakta olan bölgelerde ve kırsal alanlarda yaşayan kişilere sağlık hizmetinin götürülmesinde problemlerle karşılaşmaktadır. Bu açıdan bakıldığında teletıp kaliteyi artıracak ve coğrafi yerleşimine bakılmaksızın sağlık hizmetini her türlü bölgeye ulaştıracak bir potansiyel sağlar. Teletıp sistemleri içerisinde kardiyoloji en fazla gereksinim duyulan uygulama olmuştur. Bir çok vakada, pratisyen hekimin uzman hekimlerle çabuk konsültasyon yapabilmesi hastanın durumu açısından kritik önem taşır. Eğer sağlık ocağına gelen hastanın klinik bulguları, hastada kalp krizi şüphesi doğuruyorsa, pratisyen hekim araştırma hastanesinde çalışan bir kardiyoloji uzmanından telekardiyoloji ile yardım almaya ihtiyaç duyacaktır.

Tez çalışmasında pratisyen hekime yorum kolaylığı sağlayan ve uzman hekim ile konsültasyon yapmasına imkan veren bir telekardiyoloji sistemi önerilmiştir. Gerçekleştirilen telekardiyoloji sistemi üç aşamadan oluşmaktadır. İlk aşama sinyal kaydının yapılması ve ön işlemenin gerçekleştirilmesidir. Sağlık ocağına gelen ve kalp rahatsızlığı şüphesi uyandıran bir hastanın elektrokardiyograf cihazı ile EKG' si çekilerek, sınıflandırma için ön işleme gerçekleştirilmektedir. İkinci aşama EKG sinyaline bir tanı konulmasını içermektedir. EKG sinyallerinin tanınması ve sınıflandırılması için dalgacık dönüşümü, temel bileşen analizi, tip-2 bulanık c-ortalamalar kümeleme algoritması ve yapay sinir ağları kullanılarak üç farklı sınıflandırma sistemi oluşturulmuştur. Sınıflandırma sistemlerinin eğitimi ve testi için MIT-BIH EKG aritmi veri tabanından alınan veriler kullanılmıştır. Eğitim ve

test verileri 12 EKG sinyal sınıfını içermektedir. Gerçekleştirilen sınıflandırma sistemleri ile test verileri üzerinde %99 sınıflandırma doğruluğu elde edilmiştir. Ayrıca Selçuk Üniversitesi Tıp Fakültesi Kardiyoloji Yoğun Bakımı Ünitesi'nde yatan hastalardan alınan verilerle de önerilen sınıflandırma sistemleri test edilmiştir. Üçüncü aşama sinyalin ve tanının araştırma hastanesine gönderilmesidir. Bu aşama web sayfası ve ftp yolu ile iki farklı şekilde gerçekleştirilmektedir. Hazırlanan www.telekardiyoloji.com web sitesi ile araştırma hastanesi ve sağlık ocağının karşılıklı görüş alışverişinde bulunmaları sağlanmaktadır. Ayrıca haberleşme file transfer protocol (ftp) yolu ile de sağlanmaktadır. Bununla beraber hazırlanan arayüzler ile pratisyen hekime ve uzman doktora sinyali değerlendirme olanağı sunulmuştur.

Anahtar Kelimeler: Telekardiyoloji, EKG, Tip-2 bulanık c-ortalamlar kümeleme algoritması, Yapay sinir ağları

ABSTRACT

PhD Thesis

A TELE-CARDIOLOGY SYSTEM DESIGN USING FEATURE EXTRACTION TECHNIQUES AND ARTIFICIAL NEURAL NETWORKS

Rahime CEYLAN

Selcuk University
Graduate School of Natural and Applied Sciences
Department of Electrical-Electronics Engineering

Supervisor: Assoc. Prof. Dr. Yüksel ÖZBAY
Co- Supervisor: Prof. Dr. Bekir KARLIK

2009, 187 pages

Jury: Prof Dr. Osman Nuri UÇAN
Prof. Dr. Saadetdin HERDEM
Assoc. Prof. Dr. Mehmet YAZICI
Assoc. Prof. Dr. Yüksel ÖZBAY
Assoc. Prof. Dr. Salih GÜNEŞ

Some problems are met in carrying health service to human lived in far regions from city center and rural fields. When look from this angle, telemedical provide a potantiel which transport health service to every kind of region whatever geographical settlement. Cardiology is most require application in telemedicine systems. In many occurrence, doing consultation quickly between practitioner and expert doctor carry weight for patient' s state. If clinic findings of patient came to village clinic misgive heart attack, practitioner need to take assistance from cardiology doctor worked in research hospital with telecardiology.

In thesis study, a telecardiology system which provide interpretation easiness to practitioner and enable to consultant with expert doctor was proposed. Realized telecardiology system was formed three phase. First phase was to record signal and to realize preprocessing. The ECG of a patient which came to village clinic and his clinic findings misgave heart attack was measured with electrocardiography device and preprocessing was done on ECG signal. Second phase was contained a diagnosis to ECG signal. Three different classification systems were constituted wavelet transform, principal component analysis, type-2 fuzzy c-means clustering algorithm and artificial neural networks for detection and classification of ECG signal. Data taken from MIT-BIH ECG arrhythmia database was used for training and testing of classification system. Training and testing data was included 12 ECG signal classes. Classification accuracy on test data was obtained as 99% with improved classification system. Furthermore, proposed classification systems were tested with

data taken from patients in Selcuk University Faculty of Medicine Intensive Care Unit. Third stage was to transport signal and diagnosis to research hospital. This stage was executed on two different style with ftp and web page. Prepared www.telekardiyoloji.com web site provided consultation between research hospital and village clinic. However communication was provided with file transfer protocol (ftp). Additionally, opportunity of signal's evaluation was presented to practitioner and expert doctor with prepared interfaces.

Keywords: Telecardiology, ECG, Type-2 fuzzy c-means clustering algorithm, Artificial neural networks.

TEŞEKKÜR

Doktora tez çalışmalarım boyunca değerli katkılarıyla beni yönlendiren Sayın Hocalarım Doç. Dr. Yüksel ÖZBAY ve Prof. Dr. Bekir KARLIK' a, Arş. Gör. Sabri ALTUNKAYA' ya ve bölümümüz öğretim elemanlarına, her türlü desteğini esirgemeyen eşime, kızıma ve aileme teşekkür ederim. Ayrıca EKG veri kayıtlarını almamıza yardımcı olan Doç. Dr. Mehmet YAZICI' ya ve Selçuk Üniversitesi Tıp Fakültesi Kardiyoloji Yoğun Bakım Ünitesi personeline teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	iii
TEŞEKKÜR.....	v
İÇİNDEKİLER.....	vi
SİMGELER VE KISALTMALAR.....	xi
ŞEKİLLER LİSTESİ.....	xiii
ÇİZELGELER LİSTESİ.....	xviii
 1. GİRİŞ.....	 1
1.1. Tez Konusunun Tanıtılması.....	2
1.2. Tez Çalışmasının Amacı ve Önemi.....	3
1.3. Bu Konuda Yapılan Çalışmaların Tarihsel Gelişimi.....	4
 2. SINIFLANDIRMA.....	 11
2.1. Yapay Sinir Ağları.....	11
2.1.1. Temel yapay nöron modelleri.....	11
2.1.2. Temel aktivasyon fonksiyonları.....	14
2.1.3. İleri beslemeli çok katmanlı yapay sinir ağları.....	20
2.1.4. Geriye yayılım öğrenme algoritması.....	22
2.1.4.1. İleri beslemeli ağlar için basit geriye yayılım algoritması.....	23
2.1.4.2. Çok katmanlı ağın yakınsama hızı.....	28
2.1.4.3. Momentum sabiti güncellemeli geriye yayılım öğrenme algoritması.....	28
2.1.4.4. Batch güncelleme.....	30
2.1.4.5. Ara-Yakınsa metodu (Search-Then-Converge Method).....	31
2.1.4.6. Değişken öğrenme oranlı batch güncelleme.....	32
2.2. Bulanık C-Ortalamlar Kümeleme Algoritması.....	33
2.3. Tip-2 Bulanık C-Ortalamlar Kümeleme Algoritması.....	35

2.3.1. Maliyet fonksiyonu tabanlı bulanık kümeleme algoritmaları ile ilgili belirsizlikler	36
2.3.2. BCO algoritmasında m bulanıklık sabitindeki belirsizlik	37
2.3.3. Aralık tip-2 bulanık setlerine genişleme	39
2.3.4. Maliyet fonksiyon tabanlı aralık tip-2 bulanık kümeleme	41
 3. ÖZELLİK ÇIKARMA	 45
3.1. Temel Bileşen Analizi (Principal Component Analysis)	45
3.2. Dalgacık Dönüşümü (Wavelet Transform)	49
3.2.1. Sürekli dalgacık dönüşümü	50
3.2.2. Ayırık dalgacık dönüşümü	53
 4. ELEKTROKARDİYOĞRAFI	 57
4.1. Elektrokardiyografi Derivasyonlar ve Derivasyon Eksen Kavramı	59
4.2. Normal Elektrokardiyogram	63
4.2.1. P dalgası	66
4.2.2. PR aralığı	66
4.2.3. QRS bileşimi	67
4.2.4. ST bölümü	68
4.2.5. T dalgası	68
4.2.6. U dalgası	69
4.2.7. QT aralığı	69
4.3. Tez Çalışmasında Kullanılan Aritmiler	69
4.3.1. Normal sinüs ritmi	69
4.3.2. Sinüs bradikardisi	70
4.3.3. Ventriküler taşikardi	71
4.3.4. Sinüs aritmisi	71
4.3.5. Atrial prematüre kasılması	72
4.3.6. Yapay vuru	73
4.3.7. Sağ dal bloku	73
4.3.8. Sol dal bloku	74
4.3.9. Atrial fibrilasyon	75

4.3.10. Atrial flutter.....	75
4.3.11. Atrial couplet.....	76
4.3.12. Ventrikül trigeminy.....	77
 5. TELEKARDİYOLOJİ SİSTEMİ.....	 78
5.1. Sinyal Kaydı ve İşlenmesi Bloğu.....	80
5.1.1. Elektrokardiyograf.....	80
5.1.2. Veri toplama kartı.....	82
5.1.2.1. Analog giriş kanal sayısı.....	82
5.1.2.2. Giriş aralığı ve polaritesi.....	83
5.1.2.3. Örnekleme hızı.....	83
5.1.2.4. Kuantizasyon.....	84
5.1.3. QRS dedeksiyonu.....	85
5.2. Sinyal Tanı Bloğu.....	87
5.3. Haberleşme Bloğu.....	88
5.3.1. Web sayfası kullanılarak hazırlanan haberleşme bloğu.....	89
5.3.2. Ftp kullanılarak hazırlanan haberleşme bloğu.....	95
 6. QRS DEDEKSİYON ALGORİTMALARI VE ELDE EDİLEN SONUÇLAR.....	 98
6.1. Menard' ın birinci türev tabanlı QRS dedeksiyon algoritması.....	98
6.2. Ahlstrom ve Tompkins' in birinci ve ikinci türev tabanlı QRS dedeksiyon algoritması.....	98
6.3. QRS dedeksiyon algoritmaları ile elde edilen sonuçlar.....	99
6.3.1. Normal sinüs ritmi ile elde edilen QRS dedeksiyon sonuçları.....	100
6.3.2. Sinüs bradikardisi ile elde edilen QRS dedeksiyon sonuçları.....	101
6.3.3. Ventriküler taşikardi ile elde edilen QRS dedeksiyon sonuçları.....	102
6.3.4. Sinüs aritmisi ile elde edilen QRS dedeksiyon sonuçları.....	103
6.3.5. Atrial prematüre kasılması ile elde edilen QRS ded. Sonuçları.....	105
6.3.6. Yapay Vuru ile elde edilen QRS dedeksiyon sonuçları.....	106
6.3.7. Sağ Dal Bloku ile elde edilen QRS dedeksiyon sonuçları.....	107
6.3.8. Sol Dal Bloku ile elde edilen QRS dedeksiyon sonuçları.....	109

6.3.9. Atrial Fibrilasyon ile elde edilen QRS dedeksiyon sonuçları.....	110
6.3.10. Atrial Flutter ile elde edilen QRS dedeksiyon sonuçları.....	111
6.3.11. Atrial couplet ile elde edilen QRS dedeksiyon sonuçları.....	112
6.3.12. Ventriküler trigeminy ile elde edilen QRS dedeksiyon sonuçları.....	113
 7. GELİŞTİRİLEN ELEKTROKARDİYOGRAM SINIFLANDIRMA SİSTEMLERİ VE UYGULAMA SONUÇLARI.....	115
7.1. Tip-2 Bulanık Kümeleme Sinir Ağı.....	116
7.2. Tip-2 Bulanık Kümeleme Dalgacık Sinir Ağı.....	120
7.3. Tip-2 Bulanık Kümeleme-Temel Bileşen Analizi-Yapay Sinir Ağı.....	121
7.4. Eğitim ve Test Verisinin Özellikleri.....	122
7.5. Eğitim ve Test Hatalarının Hesaplanması.....	124
7.6. Elektrokardiyografi Sınıflandırma Sistemleri Uygulama Sonuçları.....	125
7.6.1. T2BKSA yapısı ile elde edilen uygulama sonuçları.....	127
7.6.2. T2BKDSA yapısı ile elde edilen uygulama sonuçları.....	131
7.6.3. Tip-2 Bulanık Kümeleme-Temel Bileşen Analizi-Yapay Sinir Ağı...	141
7.7. Gerçekleştirilen Hasta Kayıtlarının Sınıflandırma Sonuçları.....	146
7.8. Tez Çalışmasında Önerilen Yapıların Yapay Sinir Ağları ve Geleneksel Bulanık Kümeleme ile Gerçekleştirilen Yapılarla Karşılaştırılması.....	148
 8. TARTIŞMA.....	150
 9. SONUÇLAR VE ÖNERİLER.....	152
9.1. Sonuçlar.....	152
9.2. Öneriler.....	156
 10. KAYNAKLAR.....	158
 EKLER.....	163
EK1: Tip-2 Bulanık C-Ortalamalar Kümeleme Algoritması Matlab Kodları.....	164

EK2: Tip-2 Bulanık Kümeleme Sinir Ağının Matlab Kodları.....	167
EK3: Tip-2 Bulanık Kümeleme Dalgacık Sinir Ağının Matlab Kodları	168
EK4: Tip-2 Bulanık Kümeleme-Temel Bileşen Analizi-Sinir Ağının Matlab Kodları.....	170
EK5: Telekardiyoloji Sistemi Arayüzlerinin Kodları.....	173
EK6: USB-1408FS veri toplama kartının teknik özellikleri.....	184
EK 7: Duyarlılık, Belirlilik ve Ortalama Tanıma Oranı Parametrelerinin Hesaplanması ve tez çalışmasında elde edilen sonuçların bu parametreler ile yorumlanması	187

SİMGELER VE KISALTMALAR

EKG: Elektrokardiyogram

BCO: Bulanık c-ortalamalar kümeleme algoritması

TBA: Temel bileşen analizi

DSA: Dalgacık sinir ağı

DD: Dalgacık dönüşümü

W: Ağırlık matrisi

Δw_{ji} : Ağırlık matrisindeki değişim miktarı

E_q : Yapay sinir ağı çıkış katmanı hatası

α : Momentum sabiti

μ : Öğrenme oranı

μ_0 : Başlangıç öğrenme oranı

μ_{eff} : Etkin öğrenme oranı

u_{ij} : Üyelik derecesi

$J(U, c_1, \dots, c_c)$: Maliyet fonksiyonu

c_i : Küme merkezleri

T2BCO: Tip-2 bulanık c-ortalamalar kümeleme algoritması

m : Bulanıklık derecesi

EVD: Eigen value decomposition (Özdeğer ayrışımı)

C_x : Kovaryans matrisi

SA düğümü: Sinoatrial düğümü

T2BKSA: Tip-2 bulanık kümeleme sinir ağı

T2BKDSA: Tip-2 bulanık kümeleme dalgacık sinir ağı

T2BK-TB-YSA: Tip-2 bulanık kümeleme-Temel bileşen analizi-Yapay sinir ağı

N: Normal sinüs ritmi

SB: Sinüs bradikardisi

VT: Ventriküler taşikardi

SA: Sinüs aritmisi

APC: Atrial prematüre kasılması

PB: Yapay vuru

RBB: Sağ dal bloku

LBB: Sol dal bloku

AFib: Atrial fibrilasyon

AFlut: Atrial flutter

ACoup: Atrial couplet

VTri: Ventriküler Trigeminy

E.H.: Eğitim hatası

T.H.: Test hatası

GUI: Graphical user interface

GSM: Global system for mobile communications

GPRS: General packet radio service

CDMA: Code division multiple access

ISDN: Integrated services digital network

PID: Proportional–integral–derivative controller

FTP: File transfer protocol

YS: Yanlış sınıflanan set sayısı

?: Sınıflandırılmayan set sayısı

ŞEKİLLER LİSTESİ

Şekil 2.1 Bir yapay nöron için nonlinear model.....	12
Şekil 2.2 Farklı nonlinear bir model.....	14
Şekil 2.3 Lineer (birim) aktivasyon fonksiyonu.....	15
Şekil 2.4 Keskin sınırlayıcı aktivasyon fonksiyonu.....	16
Şekil 2.5 Simetrik keskin sınırlayıcı aktivasyon fonksiyonu.....	16
Şekil 2.6 Saturasyon lineer fonksiyonu.....	17
Şekil 2.7 Simetrik saturasyon lineer fonksiyonu.....	17
Şekil 2.8 Üç farklı eğim değeri için binary sigmoid aktivasyon fonksiyonu.....	18
Şekil 2.9 Binary sigmoid fonksiyonunun iki farklı eğim değeri için türevi.....	19
Şekil 2.10 Üç farklı eğim değeri için hiperbolik tanjant sigmoid aktivasyon fonksiyonu.....	19
Şekil 2.11 İleri beslemeli dört katmanlı yapay sinir ağı yapısı.....	22
Şekil 2.12 Geriye yayılım algoritması ile eğitilen ileri beslemeli dört katmanlı yapay sinir ağı yapısı.....	27
Şekil 2.13 Farklı hacim ve yoğunlukta iki karesel görüntü seti için sınıflandırma sonuçları (a) $m=2.0$ kullanılarak (b) $m=1.1$ kullanılarak.....	35
Şekil 2.14 Aynı hacme sahip iki küme için maksimum bulanıklık alanı (a) Küçük m değeri için (b) Büyük m değeri için.....	36
Şekil 2.15 Farklı hacme sahip iki küme için maksimum bulanıklık alanı (a) Küçük m değeri için (b) Büyük m değeri için.....	38
Şekil 2.16 Arzu edilen maksimum bulanık alan.....	38
Şekil 2.17 İki bulanıklık sabiti için belirsiz maksimum bulanık alan.....	39
Şekil 2.18 (a) Aralık tip-2 bulanık seti (b) x' örneğinin dikey izdüşümü.....	40
Şekil 2.19 BCO için aralık tip-2 bulanık setlerindeki belirsizlik alanı.....	41
Şekil 2.20 Kesin kümeye ve aralık tip-2 bulanık kümeye örnek.....	43

Şekil 2.21 X örüntü seti için tip azaltma prosedürü.....	44
Şekil 3.1 İki seviye ayrıştırılmalı ayırık dalgacık dönüşümü.....	56
Şekil 4.1. Miyokard hücresinin membran potansiyelinin belli başlı evreleri, membran potansiyelinin temel iyon devinimleri ile ilgisi. Şekil iyon pompası etkinliğine bağlı devinimleri içermemektedir.....	58
Şekil 4.2. Özetlenmiş “eksitasyon-kontraksiyon eşlenmesi”. HD=Hücre dışı, HI=Hücre içi.....	59
Şekil 4.3. Bipolar taraf derivasyonları. RA=sığ kol, LA=sol kol, LF=sol bacak	60
Şekil 4.4. Wilson’ un unipolar taraf derivasyonları.....	61
Şekil 4.5. Goldberger’ in unipolar taraf derivasyonları.....	62
Şekil 4.6. Göğüs derivasyonları.....	62
Şekil 4.7. (a) Üç bipolar taraf derivasyonu eksenî tarafından oluşturulan Einthoven üçgeni, (b) Aralarında 60° lik açılar bulunan üç eksenli referans sisteminin gösterimi.....	63
Şekil 4.8. Elektrokardiyogramdaki dikey ve yatay aralıklara ilişkin değerler ile standartlaşmayı sağlayan 1 mV’ luk test dalgası.....	64
Şekil 4.9. Normal elektrokardiyogram bileşigi.....	64
Şekil 4.10. Elektrokardiyogramda yer alan dalgaların ve aralıkların kalbin elektriksel etkinliğine ilişkin karşılıkları.....	65
Şekil 4.11. P ve T dalgalarına ilişkin ölçümlerde izlenecek yöntem.....	66
Şekil 4.12. PR aralığının ölçümünde izlenecek yöntem.....	67
Şekil 4.13. QRS bileşigini oluşturan değişik dalgalara ilişkin ölçümlerde izlenecek yöntem.....	67
Şekil 4.14. ST bölümüne ilişkin çökme ya da yükselme türünden kaymaların ölçümünde izlenecek yöntem.....	68
Şekil 4.15. Normal sinüs ritmi (103 nolu kayıt)	70
Şekil 4.16. Sinüs bradikardisi (202 nolu kayıt)	70
Şekil 4.17. Ventriküler taşikardi (200 nolu kayıt)	71
Şekil 4.18. Sinüs aritmisi (113 nolu kayıt)	72

Şekil 4.19. Atrial prematüre kasılması (202 nolu kayıt)	72
Şekil 4.20. Yapay vuru (107 nolu kayıt).....	73
Şekil 4.21. Sağ dal bloku (118 nolu kayıt).....	74
Şekil 4.22. Sol dal bloku (109 nolu kayıt)	74
Şekil 4.23. Atrial fibrilasyon (202 nolu kayıt)	75
Şekil 4.24. Atrial flutter (202 nolu kayıt)	76
Şekil 4.25. Atrial couplet (220 nolu kayıt).....	76
Şekil 4.26. Ventrikül trigeminy (119 nolu kayıt)	77
Şekil 5.1 Önerilen telekardiyoloji sistemi.....	79
Şekil 5.2. Nihon Kohden ECG-9022K Cihazı.....	81
Şekil 5.3 Veri toplama kartı.....	82
Şekil 5.4 EKG sinyallerinin frekans bandı.....	83
Şekil 5.5 Tarama tipi örnekleme (USB-1408FS)	84
Şekil 5.6 (a) 0.09 Hz kesim frekansına sahip yüksek geçiren filtre karakteristiği, (b) 30 Hz kesim frekansına sahip alçak geçiren filtre karakteristiği.....	86
Şekil 5.7 Site Haritası - www.telekardiyoloji.com	89
Şekil 5.8 www.telekardiyoloji.com – ilk sayfa görüntüsü.....	90
Şekil 5.9 Araştırma hastanesi giriş sayfası.....	90
Şekil 5.10 Ortak iletişim sayfası.....	91
Şekil 5.11 Araştırma hastanesinden görülen sağlık ocakları mesaj sayfası.....	91
Şekil 5.12 Sağlık ocakları giriş sayfası.....	92
Şekil 5.13 1. Sağlık Ocağı mesaj sayfası.....	93
Şekil 5.14 Sağlık ocağı arayüzü - web sayfası ile haberleşme.....	94
Şekil 5.15 Araştırma hastanesi arayüzü - web sayfası ile haberleşme.....	95

Şekil 5.16 Sağlık ocağı arayüzü - ftp ile haberleşme.....	96
Şekil 5.17 Araştırma hastanesi arayüzü – ftp ile haberleşme.....	97
Şekil 6.1 Normal sinüs ritmine ait filtreleme ve QRS dedeksiyon sonuçları.....	101
Şekil 6.2 Sinüs bradikardisine ait filtreleme ve QRS dedeksiyon sonuçları.....	102
Şekil 6.3 Ventriküler taşikardiye ait filtreleme ve QRS dedeksiyon sonuçları...	103
Şekil 6.4 Sinüs aritmisine ait filtreleme ve QRS dedeksiyon sonuçları.....	104
Şekil 6.5 Atrial prematüre kasılmasına ait filtreleme ve QRS dedeksiyon sonuçları.....	106
Şekil 6.6 Yapay vuruya ait filtreleme ve QRS dedeksiyon sonuçları.....	107
Şekil 6.7 Sağ dal blokuna ait filtreleme ve QRS dedeksiyon sonuçları.....	108
Şekil 6.8 Sol dal blokuna ait filtreleme ve QRS dedeksiyon sonuçları.....	109
Şekil 6.9 Atrial fibrilasyona ait filtreleme ve QRS dedeksiyon sonuçları.....	110
Şekil 6.10 Atrial fluttere ait filtreleme ve QRS dedeksiyon sonuçları.....	111
Şekil 6.11 Atrial coupleta ait filtreleme ve QRS dedeksiyon sonuçları.....	113
Şekil 6.12 Ventriküler trigeminye ait filtreleme ve QRS dedeksiyon sonuçları..	114
Şekil 7.1 Tip-2 Bulanık Kümeleme Sinir Ağı.....	116
Şekil 7.2 Tip-2 Bulanık C-Ortalamalar Kümeleme Algoritması.....	117
Şekil 7.3 T2BKSA yapısında bulunan danışmanlı yapay sinir ağı algoritması akış diyagramı.....	119
Şekil 7.4 Tip-2 Bulanık Kümeleme Dalgacık Sinir Ağı.....	120
Şekil 7.5 Tip-2 Bulanık Kümeleme-Temel Bileşen Analizi-Yapay Sinir Ağı....	122
Şekil 7.6 Eğitim verisine göre hedef verisinin oluşturulması.....	124
Şekil 7.7 T2BKSA ile EKG verilerinin sınıflandırılması.....	127
Şekil 7.8 T2BKDSA ile EKG verilerinin sınıflandırılması.....	131

Şekil 7.9 (a) Normal sinüs ritmi-orijinal sinyal, (b)Normal sinüs ritmi- dalgacık dönüşümü ile elde edilen 101 örneklik sinyal, (c)Sinüs bradikardisi- orijinal sinyal, (d) Sinüs bradikardisi- dalgacık dönüşümü ile elde edilen 101 örneklik sinyal.....	133
Şekil 7.10 (a)Normal sinüs ritmi-orijinal sinyal, (b)Normal sinüs ritmi- dalgacık dönüşümü ile elde edilen 52 örneklik sinyal, (c)Sinüs bradikardisi- orijinal sinyal, (d) Sinüs bradikardisi- dalgacık dönüşümü ile elde edilen 52 örneklik sinyal.....	136
Şekil 7.11 (a)Normal sinüs ritmi-orijinal sinyal, (b)Normal sinüs ritmi- dalgacık dönüşümü ile elde edilen 27 örneklik sinyal, (c)Sinüs bradikardisi- orijinal sinyal, (d) Sinüs bradikardisi- dalgacık dönüşümü ile elde edilen 27 örneklik sinyal.....	138
Şekil 7.12 T2BK-TB-YSA ile EKG verilerinin sınıflandırılması.....	141

ÇİZELGELER LİSTESİ

Çizelge 1.1. Tez konusunun veri tabanı istatistikleri.....	10
Çizelge 6.1 Normal sinüs ritmine ait QRS dedeksiyon algoritması sonuçları....	101
Çizelge 6.2 Sinüs bradikardisine ait QRS dedeksiyon algoritması sonuçları.....	102
Çizelge 6.3 Ventriküler taşikardiye ait QRS dedeksiyon algoritması sonuçları..	103
Çizelge 6.4 Sinüs aritmisine ait QRS dedeksiyon algoritması sonuçları.....	104
Çizelge 6.5 Atrial prematüre kasılmasına ait QRS dedeksiyon algoritması sonuçları.....	106
Çizelge 6.6 Yapay vuruya ait QRS dedeksiyon algoritması sonuçları.....	107
Çizelge 6.7 Sağ dal blokuna ait QRS dedeksiyon algoritması sonuçları.....	108
Çizelge 6.8 Sol dal blokuna ait QRS dedeksiyon algoritması sonuçları.....	109
Çizelge 6.9 Atrial fibrilasyona ait QRS dedeksiyon algoritması sonuçları.....	111
Çizelge 6.10 Atrial fluttere ait QRS dedeksiyon algoritması sonuçları.....	112
Çizelge 6.11 Atrial coupleta ait QRS dedeksiyon algoritması sonuçları.....	113
Çizelge 6.12 Ventriküler trigeminye ait QRS dedeksiyon algoritması sonuçları.	114
Çizelge 7.1 Eğitim ve test verisinin özellikleri.....	123
Çizelge 7.2 Optimum bulanıklık sabitinin bulunması.....	126
Çizelge 7.3 Optimum öğrenme oranının belirlenmesi (Gizli düğüm sayısı=50, momentum sabiti=0.9).....	127
Çizelge 7.4 Optimum momentum sabitinin belirlenmesi (Gizli düğüm sayısı=50, Öğrenme oranı=2.0).....	127
Çizelge 7.5 Tip-2 bulanık c-ortalamalar kümeleme ile elde edilen eğitim verilerinde toplam örüntü sayısının aritmi sınıflarına göre dağılımı.....	128
Çizelge 7.6 T2BKSA yapısı için optimum gizli düğüm sayısının bulunması (84 setlik eğitim verisi ile elde edilen sonuçlar).....	129

Çizelge 7.7 T2BKSA yapısı için test verisi sınıflandırma sonuçları (84 setlik eğitim verisi ile eğitilen sistemde).....	129
Çizelge 7.8 T2BKSA yapısı için optimum gizli düğüm sayısının bulunması (100 setlik eğitim verisi ile elde edilen sonuçlar).....	130
Çizelge 7.9 T2BKSA yapısı için test verisi sınıflandırma sonuçları (100 setlik eğitim verisi ile eğitilen sistemde).....	130
Çizelge 7.10 T2BKDSA-1 yapısı için optimum gizli düğüm sayısının bulunması (84 setlik eğitim verisi ile elde edilen sonuçlar).....	133
Çizelge 7.11 T2BKDSA-1 yapısı için test verisi sınıflandırma sonuçları (84 setlik eğitim verisi ile eğitilen sistemde).....	133
Çizelge 7.12 T2BKDSA-1 yapısı için optimum gizli düğüm sayısının bulunması (100 setlik eğitim verisi ile elde edilen sonuçlar).....	134
Çizelge 7.13 T2BKDSA-1 yapısı için test verisi sınıflandırma sonuçları (100 setlik eğitim verisi ile eğitilen sistemde).....	134
Çizelge 7.14 T2BKDSA-2 yapısı için optimum gizli düğüm sayısının bulunması (84 setlik eğitim verisi ile elde edilen sonuçlar).....	136
Çizelge 7.15 T2BKDSA-2 yapısı için test verisi sınıflandırma sonuçları (84 setlik eğitim verisi ile eğitilen sistemde).....	137
Çizelge 7.16 T2BKDSA-2 yapısı için optimum gizli düğüm sayısının bulunması (100 setlik eğitim verisi ile elde edilen sonuçlar).....	137
Çizelge 7.17 T2BKDSA-2 yapısı için test verisi sınıflandırma sonuçları (100 setlik eğitim verisi ile eğitilen sistemde).....	137
Çizelge 7.18 T2BKDSA-3 yapısı için optimum gizli düğüm sayısının bulunması (84 setlik eğitim verisi ile elde edilen sonuçlar).....	139
Çizelge 7.19 T2BKDSA-3 yapısı için test verisi sınıflandırma sonuçları (84 setlik eğitim verisi ile eğitilen sistemde).....	139
Çizelge 7.20 T2BKDSA-3 yapısı için optimum gizli düğüm sayısının bulunması (100 setlik eğitim verisi ile elde edilen sonuçlar).....	140
Çizelge 7.21 T2BKDSA-3 yapısı için test verisi sınıflandırma sonuçları (100 setlik eğitim verisi ile eğitilen sistemde).....	140
Çizelge 7.22 T2BK-TB-YSA-1 yapısı için optimum gizli düğüm sayısının bulunması (84 setlik eğitim verisi ile elde edilen sonuçlar).....	142

Çizelge 7.23 T2BK-TB-YSA-1 yapısı için test verisi sınıflandırma sonuçları (84 setlik eğitim verisi ile eğitilen sistemde).....	142
Çizelge 7.24 T2BK-TB-YSA-2 yapısı için optimum gizli düğüm sayısının bulunması (84 setlik eğitim verisi ile elde edilen sonuçlar).....	143
Çizelge 7.25 T2BK-TB-YSA-2 yapısı için test verisi sınıflandırma sonuçları (84 setlik eğitim verisi ile eğitilen sistemde).....	143
Çizelge 7.26 T2BK-TB-YSA-3 yapısı için optimum gizli düğüm sayısının bulunması (84 setlik eğitim verisi ile elde edilen sonuçlar).....	144
Çizelge 7.27 T2BK-TB-YSA-3 yapısı için test verisi sınıflandırma sonuçları (84 setlik eğitim verisi ile eğitilen sistemde).....	144
Çizelge 7.28 T2BK-TB-YSA-4 yapısı için optimum gizli düğüm sayısının bulunması (84 setlik eğitim verisi ile elde edilen sonuçlar).....	144
Çizelge 7.29 T2BK-TB-YSA-4 yapısı için test verisi sınıflandırma sonuçları (84 setlik eğitim verisi ile eğitilen sistemde).....	145
Çizelge 7.30 Hasta kayıtlarının sınıflandırma sonuçları.....	146
Çizelge 7.31 Yapılarla elde edilen hata sonuçlarının karşılaştırılması (84 setlik eğitim verisi ile elde edilen sonuçlar).....	149
Çizelge 7.32 BKSA ile elde edilen sınıflandırma sonuçları.....	149
Çizelge 8.1 T2BKSA ile elde edilen optimum sonuçlar.....	153
Çizelge 8.2 T2BKDSA ile elde edilen optimum sonuçlar.....	154
Çizelge 8.3 T2BK-TB-YSA ile elde edilen optimum sonuçlar.....	155
Çizelge 8.4 Tez çalışmasında elde edilen sonuçların literatürle karşılaştırılması	156

1. GİRİŞ

Kalp krizi geçirmekte olan bir hastaya erken teşhis ve müdahalenin yapılması hayati önem taşımaktadır. Bu nedenle son yıllarda telekardiyoloji uygulamalarında artış görülmektedir. Bir telekardiyoloji uygulamasında iki önemli nokta vardır. Birincisi, hastaya erken teşhisin yapılması için hastanın durumunun, EKG sinyalleri ile doğru ve hızlı bir şekilde belirlenmesi ve aritmi teşhisinin sağlanmasıdır. Literatürde teletıp (telemedicine) veya telekardiyoloji üzerine yapılan son çalışmalarda, tanıma sisteminin oluşturulmasında yapay zekâ yöntemlerinden faydalanılmaktadır. İkinci önemli nokta ise; hastadan alınan EKG verilerinin en yakın araştırma hastanesine hızlı bir şekilde ulaştırılması ve araştırma hastanesinden gelecek yoruma göre hastaya müdahale edilmesidir.

Bu tez çalışmasında, özellik çıkarma teknikleri ve Yapay Sinir Ağları (YSA) kullanılarak gerçekleştirilen bir telekardiyoloji sistemi sunulmaktadır. Önerilen sistemin yapısı, EKG sinyallerinin hızlı ve doğru bir şekilde yorumlanmasını sağlayan bir sinir ağını ve sinyallerin ulaştırılmasını sağlayan haberleşme bloğunu içermektedir. Tez çalışması dokuz ana bölümden oluşmaktadır.

Birinci bölümde, tez konusu tanıtılmış, tezin amacı ve önemi üzerinde durulmuştur. Ayrıca bu alanda yapılmış çalışmaların tarihsel gelişimine yer verilmiştir. İkinci bölümde, tez çalışmasında kullanılan sınıflandırma algoritmalarına değinilmiştir. Bu bölümde, yapay sinir ağları, bulanık c-ortalamlar kümeleme algoritması ve tip-2 bulanık c-ortalamlar kümeleme algoritması detaylı olarak incelenmiştir. Üçüncü bölümde, tez çalışmasında kullanılan temel bileşen analizi ve dalgacık transformu gibi özellik çıkarma teknikleri anlatılmıştır. Dördüncü bölümde elektrokardiyografi kaydı ve derivasyonlar incelenmiştir. Ayrıca bu bölümde tez çalışmasında sınıflandırılan 12 EKG sinyal sınıfına ayrı ayrı değinilmiştir.

Beşinci bölümde tez çalışmasında gerçekleştirilen telekardiyoloji sistemine genel bir bakış verilmiştir. Önerilen telekardiyoloji sistemini oluşturan bloklar ve gerçekleştirmede kullanılan programlar ve cihazlar detaylı bir şekilde anlatılmıştır.

Altıncı bölümde, tez çalışmasında EKG sinyallerinin yorumlanması için önerilen tip-2 bulanık kümeleme sinir ağı yapısı (T2BKSA) detaylı olarak

anlatılmıştır. Ayrıca dalgacık dönüşümü ve temel bileşen analizi gibi özellik çıkarma algoritmaları kullanılarak gerçekleştirilen iki farklı T2BKSA yapısı önerilmiştir. Tez çalışması kapsamında önerilen üç sinir ağı yapısının 12 EKG sinyal sınıfı üzerindeki tanıma performansları tablolarla karşılaştırmalı olarak incelenmiştir.

Yedinci bölümde, tez çalışmasında sunulan telekardiyoloji sisteminin avantajları ve dezavantajları üzerinde tartışılmıştır. Sunulan telekardiyoloji sisteminin literatürde bugüne kadar önerilen sistemlere göre üstünlüklerine değinilmiştir.

Sekizinci bölümde, gerçekleştirilen teorik ve uygulama çalışmalarının sonuçları incelenmiş ve bazı ileriye yönelik çalışmalar için önerilerde bulunulmuştur.

Dokuzuncu bölümde, bu çalışmada yararlanılan bilimsel çalışmaların listesi sunulmuştur.

1.1. Tez Konusunun Tanıtılması

Gerçekleştirilen tez çalışmasında amaç, göğüs ağrısı, kolda uyuşma veya terleme gibi kalp krizi şüphesi uyandırabilecek şikâyetler ile sağlık ocağına gelen bir hastanın telekardiyoloji sistemi vasıtasıyla kalp ile ilgili bir rahatsızlığı olup olmadığını belirlemektir. Bu maksatla önerilen çalışmada, yapay sinir ağları ve farklı özellik çıkarma teknikleri kullanılarak gerçek-zamanlı bir EKG tanılama yazılımı gerçekleştirilmiştir. Böylece acil müdahale gerektiren kalp krizi gibi bir rahatsızlığın varlığı kolaylıkla erken teşhis edilecektir. Aynı zamanda gerçekleştirilen yazılımla, EKG işaretlerinin en hızlı ve en doğru şekilde sınıflandırılması sağlanarak sağlık ocağındaki pratisyen hekime ve araştırma hastanesindeki uzman doktora doğru ve hızlı teşhis imkânı sunulmuştur.

Tez çalışmasında EKG sınıflandırma sistemi için tip-2 bulanık c-ortalamlar kümeleme algoritması ve iki özellik çıkarma algoritması kullanılarak üç farklı yapı sunulmuştur. Burada örüntü seçme işlemi için kullanılan tip-2 bulanık c-ortalamlar kümeleme algoritması daha önce biyomedikal verilere uygulanmamıştır. Ayrıca yapıların gerçekleştirilmesinde kullanılan özellik çıkarma metotları, dalgacık dönüşümü ve temel bileşen analizidir.

1.2. Tez Çalışmasının Amacı ve Önemi

Bir ülke nüfusunun sağlık düzeyi, ekonomik gelişmeyi doğrudan etkileyen önemli bir belirleyicidir. Nüfus artışı ve yeni sağlık problemlerinin aciliyeti sağlık hizmetlerine olan talebi artırmıştır. Türkiye gibi birçok gelişmekte olan ülkede sağlık hizmetlerinin karşılanamaz duruma geldiği sağlık bakanlığı tarafından yayınlanan yıllık istatistiklerde, doktor başına düşen hasta sayısı veya yatak başına düşen hasta sayısı gibi verilerden anlaşılabilmektedir. Sağlık Bakanlığı verilerine göre 2002 yılında doktor başına düşen hasta sayısı 1893 iken, 2005 yılında 2738' e ulaşmıştır. Yatak başına düşen hasta sayısı 2002' de 1110 iken 2005' de 1587' e yükselmiştir. Ayrıca Sağlık Bakanlığı' nın 2007 yılı verilerine göre, birinci basamak sağlık kuruluşlarında hekim başına düşen günlük muayene sayısı 42 ve sağlık bakanlığına bağlı hastanelerde uzman hekim başına düşen günlük muayene sayısı 58' dir. OECD' e göre bin kişiye düşen doktor sayısı ortalaması 3,1 iken, Türkiye' de bu oran 1,6' dır. Dünya Sağlık Örgütü' nün 2009 yılı itibariyle yayınladığı raporda, Türkiye hekim başına düşen nüfus açısından 53 ülkenin bulunduğu Avrupa Bölgesi listesinde 52. sırada, hemşire başına düşen nüfus açısından ise son sırada yer almaktadır. Bunun sonucu olarak, şehir merkezlerinden uzakta olan bölgeler ve kırsal alanlarda yaşayan kişilere sağlık hizmeti götürmek ve bu kişileri sağlık hizmetlerinin verildiği bölgelere ulaştırmak için büyük problemlerle karşılaşılabilir. Sağlık Bakanlığı 2002' den bu yana kırsal bölgelere ulaşmak için "Gezici Sağlık Hizmetleri" adı altında bir uygulama yapmaktadır. Ancak bu uygulamada acil durumlar için bir çözüm sağlamamaktadır.

Teletıp, kaliteyi artıracak ve coğrafi yerleşimine bakılmaksızın sağlık hizmetini her türlü bölgeye ulaştıracak potansiyeldedir. Teletıp acil müdahalelerde gerekli olan tıbbi desteğe, uzak konsültasyonlara, yönetim ve lojistik, sağlık görevlilerinin eğitimi ve öğretimine çözüm olarak önerilmektedir. Ülkenin ekonomik durumu ve kaynakların kısıtlı olmasından dolayı, büyük şehirlerdeki tıp merkezlerinden uzakta olan sağlık ocaklarına, ileri teşhis ekipmanının ve kardiyoloji uzmanlarının götürülmesi oldukça zordur, hatta imkânsızdır. Bu kişilere ileri düzeyde sağlık hizmeti ulaştırmak zor olduğundan farklı alternatifler üretilmelidir. Kırsal alanda

yaşayan hastaların bu problemine, tele-tıp dallarından biri olan tele-kardiyoloji ile çözüm bulunabilir.

Teletıp sistemleri içerisinde kardiyoloji en fazla istenilen uygulama olmuştur. Bir çok vakada, pratisyen hekimin uzman hekimlerle ile çabuk konsültasyon yapabilmesi, hasta için kritiktir. Bu tip vakalardan biri de akut miyokardial enfarktüstür (kalp krizi). Erken müdahale hastanın durumunu iyi yönde etkiler. Akut miyokardial enfarktüs geçiren bir hastaya yapılacak erken thrombolysis'in (kan pıhtısını eritme) faydaları oldukça fazladır. Uzman kardiyologlar tarafından kırsal bölgelerdeki birinci basamak sağlık kuruluşlarına başvuran hastalarda tele-kardiyoloji sistemi kullanımı ile thrombolysis tedavisinde kararın erken verilmesinin önemli olduğu ortadadır. Eğer sağlık kliniğine gelen hastanın klinik bulguları, hastada miyokardial enfarktüs şüphesi doğuruyorsa, pratisyen hekim merkezi bir hastanede çalışan bir kardiyoloji uzmanından telekardiyoloji konsültasyonu ile yardım almaya ihtiyaç duyacaktır. Bu durumda pratisyen hekim, hastanın EKG'si ile birlikte konsültasyon yapma istemini tez kapsamında gerçekleştirilen www.telekardiyoloji.com web sayfası üzerinden veya ftp yoluyla iletecektir. Hastane ortamındaki kardiyolog, konsültasyon istemini klinik bulgular ile birlikte değerlendirerek pratisyenle hekimle iletişim kuracaktır. Böylece hastanın rahatsızlığının erken teşhisi yapılarak tedavisine katkı sağlanmış olacaktır.

1.3. Bu Konuda Yapılan Çalışmaların Tarihsel Gelişimi

Teletıp (telemedicine) incelendiğinde literatürde birçok yeni çalışmanın yapıldığı bir konu olduğu görülmektedir. Dutt ve ark. 2003' de teletıp uygulamalarında kullanılmak üzere bir sinyal sıkıştırma sistemi önermişlerdir. Çalışmada EKG sinyalleri sıkıştırılarak ve sıkıştırılmadan radyo modem (MOBITEX) ile iletmeye çalışılmıştır. Sinyal sıkıştırma işlemi için sinir ağı kullanılmıştır. Optimizasyon algoritması olarak Levenberg-Marquart algoritması kullanılmıştır. Sıkıştırılmadan gönderilen sinyallerle sıkıştırılarak gönderilen sinyallerin gönderim süreleri oldukça farklı elde edilmiştir. Normal EKG sinyalinin

gönderim süresi 2912 s iken sıkıştırılmış sinyal için bu süre 58.82 s olarak bulunmuştur. Aynı çalışmanın bir benzeri Chen ve ark. (2004) tarafından gerçekleştirilmiştir. Bu çalışmada da teletıp uygulamaları için EKG sinyalleri üzerinde sıkıştırma işlemi gerçekleştirilmiştir.

Park ve Yi 2003' de gerçekleştirdikleri çalışmada hastadan ölçülen EKG sinyalleri kablosuz haberleşme kullanılarak ev sunucusuna (server) aktarılmıştır. Bu sunucuda toplanan ve işlenen veriler hastanedeki merkezi servera yüksek hızlı internet yoluyla gönderilmiştir. Bu çalışmada dataların sınıflandırılma işlevi ev sunucusunda yapılmaktadır. Ayrıca çalışmada, verilere öncelikle dalgacık dönüşümü uygulanmaktadır, sonra temel bileşen analizi uygulanarak sinir ağı ile sınıflama yapılmaktadır. Gerçekleştirilen uygulama sonucu % 96.5 doğruluğa ulaşılmıştır.

Teletıp alt yapısını oluşturmak amacıyla gerçekleştirilen ilk çalışmalar daha sonra hastaların günlük hayatlarını kolaylaştıracak sistemlerin uygulamasına yönelmiştir. Tura ve Badanai (2003)' nin çalışmaları buna örnek gösterilebilir. Bu çalışmada tıbbi takılabilir araç Avrupa Birliği tarafından desteklenen bir proje kapsamında geliştirilmiştir. Bu projenin amacı, beyin fonksiyonlarında problem olan çocukların ev aktivitelerinin yönetimi için bir ağ oluşturmaktır. Cihaz, kan oksijen yoğunluğu, kalp hızı, solunum hızı ve hastanın hareket kalitesi gibi parametreleri ölçmektedir. Ölçülen parametreler bir multimedia kartta toplanmaktadır. Bluetooth kablosuz radyo haberleşmesi ile önceden tanımlanan zaman aralıklarında PC' ye gönderilmektedir. PC' den alınan datalar internet yoluyla "Servis Merkezi" ne gönderilmektedir.

2005' de Rodriguez ve ark., EKG sinyallerinin bir PDA (Personel Digital Assistant - Elektronik Ajanda) üzerinde gerçekleştirilen yazılımla sınıflandırılması üzerine çalışmışlardır. Çalışmada öncelikle piyasada bulunan EKG ve teletıp donanımları ve yazılımlarına değinilmiş ve özellikleri hakkında bilgi verilmiştir. Eğitim ve test verileri için Physionet veri tabanından (www.physionet.org) alınan MIT-BIH EKG verileri kullanılmıştır. Veriler rasgele seçilerek, %66' sı eğitim ve %33' ü test için ayrılmıştır. Weka ve Answer Tree olmak üzere iki farklı makine öğrenme algoritması kütüphanesi kullanılmıştır. Bu kütüphanelerdeki algoritma ve metot seçiminde tüm metotlar ve algoritmalar için validasyon datası ile elde edilen

sonular karřılařtırılmıřtır. En iyi sonu % 92.7 olarak ‘‘C4.5 karar aęacı’’ algoritması ile elde edilmiřtir.

Dong ve Xu (2005) gerekleřtirdikleri alıřmada hastanın zerinde tařıyabildięi bir EKG tanıma ve gzleme sistemi tasarlamıřlardır. Burada da sistem hastadan alınan bilgileri (holter cihazı ile) monitre gndermektedir. Bilgiler monitrden bluetooth vasıtasıyla bir palm de kaydedilir ve istenirse grntlenebilir. Daha sonra bilgiler palmdan GSM/GPRS/CDMA yada internet yoluyla hastanedeki servera gnderilir. Bylece hastanın acil durumlar dâhilinde gzlemelenmesi kolaylařtırılmıř olur. alıřmada yapay zekâ algoritmaları yerine, sınıflandırma farklı bir algoritma ile gerekleřtirilmiřtir. Sonu olarak 8 farklı aritmi zerinde yapılan uygulamalarda en yksek %99.73 sensitivity, %100 specificity parametrelerine ulařılmıřtır.

Buraya kadar anlatılan teletıp ya da telekardiyoloji alıřmalarının tm kalp rahatsızlıęı kanıtlanmış hastaların gnlk yařamlarını kolaylařtırmak adına yapılan donanımları ve yazılımları iermektedir. Karlık ve ark. tarafından 2006’ da gerekleřtirilen alıřmada ise saęlık ocaklarına kurulacak bir sistem ile kalp rahatsızlıęı belirtisi gsteren herhangi bir kiřinin daha kısa srede tedavi alabilmesinin saęlanması amalanmaktadır. alıřmada ama kolda uyuřma, gęs aęrısı veya terleme gibi kalp rahatsızlıęı řphesi uyandırabilecek řikayetler ile saęlık ocaęına gelen bir hastanın tele-kardiyoloji sistemi vasıtasıyla kalp ile ilgili bir rahatsızlıęı olup olmadıęını belirlemektir. Burada saęlık ocaęına kurulan tele-kardiyoloji odasında hastanın EKG si alınacak elde edilen veriler hem saęlık ocaęında bulunan bilgisayar ve yazılım vasıtasıyla izdirilerek sınıflandırılacak, hem de hastanede uzman tarafından verilerin izimi aynı anda grlebilecek ve sınıflandırma sonucu uzmanın bilgisayarına da yklenmiř aynı yazılım sayesinde hemen alınabilecektir. alıřmada yalnızca saę dal bloku ve sol dal bloku aritmilerinin teřhis edilmesi amalanmıřtır. Gerekleřtirilen sistemle, bir hastaneye 50-100 km. uzaklıkta bulunan ve acil yardım gerektiren kalp krizi vakalarında hastanın durumunun hastaneden daha yakın bir saęlık ocaęında teřhis edilmesi ve uzman desteęi gelinceye kadar hastane ile irtibat halinde olunması aısından olduka nemlidir. Sistemde verilerin saęlık ocaęındaki bilgisayardan hastanedeki uzman bilgisayarına gnderilmesi iřlevi ISDN ile saęlanmıřtır.

Tip-2 bulanık c- ortalamalar kümeleme algoritması ilk olarak 1998 ve 2000’ de John ve ark. tarafından gerçekleştirilmiştir. Çalışmada, radyografik kavalkemiği görüntülerinin incelenmesinde, veriler bulanık sinir ağı ile kümelenmeden önce tip-2 bulanık mantık kullanılarak ön işleme yapılmıştır. Aynı zamanda tip-2 bulanık setleri ile geleneksel (tip-1) bulanık setlerinin performansları karşılaştırılmıştır. Sonuçlar tip-2 bulanık setlerinin kullanılmasının uzmanlar tarafından sınıflandırılması zor olan görüntüleri sınıflandırmada oldukça başarılı olduğunu göstermiştir.

Rhee ve Hwang (2001) gerçekleştirdikleri çalışmada tip-2 bulanık c- ortalamalar kümeleme algoritmasının matematiksel modelini oluşturmuşlardır. Önerilen kümeleme algoritması kümeleme deneyine ve segmentasyon problemine uygulanmış ve sonuçlar tip-1 bulanık c-ortalamalar kümeleme algoritması ile elde edilen sonuçlarla karşılaştırılmıştır. Elde edilen sonuçlara göre tip-2 bulanık c- ortalamalar kümeleme algoritması, tip-1 bulanık c-ortalamalar kümeleme algoritmasına göre daha başarılı bulunmuştur. Ayrıca çalışmada gerçekleştirilen matematiksel düzenlemeler ile tip-1 bulanık c-ortalamalar kümeleme algoritmasındaki dezavantajlar elimine edilmiştir.

Mendel ve John, tip-2 bulanık setlerinin probleme uygulanmasındaki zorluğu azaltmak amacıyla 2002’ de teoriye dayalı bir çalışma gerçekleştirmişlerdir. Çalışmada tip-2 bulanık setleri basit bir şekilde anlatılmaya çalışılmıştır.

2004’ de yapay sinir ağı ile tip-2 bulanık mantık ilk kez aynı çalışma içerisinde kullanılmıştır. Karaköse ve Akın, çok katmanlı sinir ağında tip-2 bulanık aktivasyon fonksiyonunun kullanıldığı yeni bir yapı önermişlerdir. Önerilen yapı geleneksel XOR problemi ve sensörsüz hız kontrolü problemine uygulanmıştır. Tip-2 aktivasyon fonksiyonlu sinir ağı yapısı her iki problemin çözümünde de başarılı bulunmuştur.

Yapay sinir ağı ve tip-2 bulanık mantığın yer aldığı ikinci çalışma yine 2004’ de Carliso ve Melin tarafından gerçekleştirilmiştir. Carliso ve Melin, adaptif gürültü eliminasyonunda ölçülebilir gürültü kaynağı ile ölçülemeyen girişim (inference) arasında olması gereken filtreyi tip-2 bulanık mantık kullanarak tasarlamışlardır. Çalışmada önerilen filtre, performansının ölçülmesi açısından tip-1 bulanık mantık ile gerçekleştirilen bir başka filtre ile karşılaştırılmıştır. Bu amaçla gerçekleştirilen iki deneyde de tip-2 bulanık mantık ile gerçekleştirilen filtre ile alınan sonuçların

daha başarılı olduğu görülmüştür. Ancak çalışmada sonuçlar tartışılırken önemli bir nokta da vurgulanmıştır. Tip-2 bulanık mantık kullanılması durumunda, tip-1 bulanık mantık kullanılması durumuna göre 4 kat daha fazla süre harcanmaktadır.

Wang ve ark. (2004) tip-2 bulanık sinir ağı için dinamik optimum bir eğitim gerçekleştirmiştir. Çalışmada, tip-2 bulanık katmanı ile kurallar belirlenmektedir. Bu kurallar sinir ağı katmanının giriş örüntüleri olarak ele alınmaktadır. Ayrıca sinir ağı katmanının eğitiminde öğrenme kuralları dinamik olarak belirlenmektedir. Sistem bir kontrol problemine ve nonlinear sistem tanımlama problemine uygulanmıştır. Çalışmada tip-2 bulanık sinir ağı, tip-1 bulanık sinir ağından daha iyi bir performans göstermiştir.

Tip-1 bulanık sinir ağı literatürde kontrol alanında da oldukça çok kullanılmıştır. Abiyev tarafından 2004’ de gerçekleştirilen çalışmada bulanık mantık sistemine ve dalgacık sinir ağına giriş örüntüleri aynı anda verilerek iki sistemin çıkışları tek katmanlı bir sinir ağına giriş olarak verilmektedir. Çalışmada önerilen yapı ile bir PID kontrol sistemi tasarlanmış ve sonuçlar başka sistemlerle karşılaştırılarak elde edilen performansın yüksekliği gösterilmiştir. Lin ve Chin 2004 yılında gerçekleştirdikleri çalışmada bulanık mantık sistemi ve dinamik dalgacık sinir ağını hibrit kullanmışlardır. Kurulan yapıda bulanık sinir ağı ile elde edilen sonuçlar ile dalgacık sinir ağı ile elde edilen sonuçlar bir katmana giriş olarak alt alta sunulmuş ve elde edilen çıkışlar yorumlanmıştır.

Bulanık sinir ağları üzerine gerçekleştirilen çalışmalardan bazıları sistem parametrelerinin optimizasyonu üzerinedir. Er ve Deng (2004) bulanık sistemin parametrelerinin online ayarlanmasında “dinamik bulanık Q-öğrenme metodu” adı verilen yeni bir metot önermişlerdir.

Jiang ve Adeli 2005’ de önerdikleri yapıda, ilk olarak giriş örüntülerinde dalgacık dönüşümü ile dalgacık katsayıları hesaplanmaktadır. Elde edilen katsayılara bulanık c-ortalamalar algoritması uygulanarak bulanık dalgacıklar oluşturulmuştur. Sınıflandırma yapay sinir ağı ile gerçekleştirilmiştir. Oluşturulan yapı nonlinear sistem tanımlama problemine uygulanmıştır. Maksimum %1.95 hata ile arzu edilen değerlere ulaşılmıştır.

Ayrıca literatürde bulanık sinir ağı EKG vuru tanıma problemine de uygulanmıştır. Osowski ve Linh (2001) tarafından gerçekleştirilen çalışma bu

konuda önemli sonuçlar içermektedir. Bu çalışmada EKG sınıflandırma için bulanık sinir ağı yapısı oluşturulmuştur. Bu yapıda öncelikle bulanık c-ortalamalar kümeleme algoritması kullanılarak EKG sinyalleri kümelenerek elde edilen küme merkezleri yapay sinir ağına verilmiştir. Önerilen ağ yapısı ile 6 aritmi çeşidi sınıflandırılmıştır. Önerilen yapıda EKG verileri sisteme verilmeden önce özellik çıkarma gerçekleştirilerek sinyalle birlikte ikinci ve üçüncü dereceden türevleri de sisteme giriş olarak sunulmuştur. 6 farklı aritmi için gerçekleştirilen çalışmada, ortalama sınıflandırma hatası eğitim için %2.55, test için ise %3.94 olarak bulunmuştur.

Addison' un 2005 yılında gerçekleştirdiği çalışmada EKG sinyallerinin dalgacık dönüşümü kullanılarak incelenmesi üzerinde durulmuştur.

Özbay ve ark. 2006' da önerdikleri bulanık kümeleme sinir ağı yapısı ile 10 EKG sinyal sınıfı üzerinde % 97 sınıflandırma başarısına ulaşmışlardır. Çalışmada gerçekleştirilen yapıda bulanık c-ortalamalar kümeleme algoritması kullanılarak eğitim setindeki aritmi sınıfları içerisinde söz konusu aritmiyi en iyi temsil edebilecek örüntüler seçilmiştir. Elde edilen yeni örüntülerden oluşan veri seti sinir ağına sunulmuştur. Kurulan sistemde amaç daha az veri ile çalışarak hem eğitim hatasını azaltmak hem de işlem süresini kısaltmaktır. Çalışmada sonuçlar sadece elde edilen verilerle değil aynı zamanda 92 hasta verisi ile de test yapılarak elde edilmiştir. Sinir ağına göre hem daha düşük eğitim ve test hatasına hem de daha az işlem süresine ulaşılmıştır.

EKG sinyallerinin sınıflandırılmasında performansı yükseltmek için özellik çıkarma algoritmaları da kullanılmaktadır. Ceylan ve Özbay (2007) gerçekleştirdikleri çalışmada, EKG sinyallerinin sınıflandırılmasında, temel bileşen analizi (TBA), bulanık c-ortalamalar (BCO) algoritması ve dalgacık dönüşümü (DD) gibi özellik çıkarma algoritmalarının performansları değerlendirilmiştir. Çalışmada en düşük test hatası dalgacık sinir ağı (DSA) yapısı ile elde edildiği halde en düşük işlem süresi bulanık c-ortalamalar kümeleme algoritması, temel bileşen analizi ve sinir ağının kaskat kullanıldığı yapı ile elde edilmiştir.

Tez çalışmasında gerçekleştirilen telekardiyoloji sistemi ve bu sistemi oluşturan yapılar ile ilgili veri tabanı istatistikleri Çizelge 1.1' de sunulmuştur. Çizelge literatürde en önemli üç veri tabanında yapılan aramalardan oluşturulmuştur. Çizelgeden de görüleceği gibi, literatürde bugüne kadar telekardiyoloji sisteminde

yapay sinir ağlarının ve bulanık kümelemenin kullanıldığı herhangi bir çalışma yapılmamıştır. Ayrıca literatürde tez çalışmasında önerilen tip-2 bulanık c-ortalamlar kümeleme algoritmasının elektrokardiyografi verilerinde kullanıldığı tek çalışma tarafımızdan yapılan yayındır (“Ceylan ve ark 2009” yayını). Aynı şekilde, son 2 yılda tip-2 bulanık c-ortalamlar kümeleme algoritması ve yapay sinir ağlarının birlikte kullanıldığı iki çalışmadan biri tarafımıza aittir. Çizelge 1.1’ den de görüleceği gibi tez konusu içinde önerilen tip-2 bulanık kümeleme sinir ağı yapısı literatürde daha önce gerçekleştirilmemiştir. Bunun yanında önerilen böyle bir EKG sınıflandırma yapısının telekardiyoloji sistemi içerisinde gerçekleştirilmesi üzerine literatürde daha önce yapılmış bir çalışma yoktur.

Çizelge 1.1. Tez konusunun veri tabanı istatistikleri

Aranan kelime	IEEE		ESD		Web of Science	
	Toplam	Son 2 yıl	Toplam	Son 2 yıl	Toplam	Son 2 yıl
Telemedicine	508	113	692	144	2112	394
Telemedicine+ECG	9	1	16	3	4	2
Telemedicine+ECG+NN	3	3	1	0	0	0
Telemedicine+ECG+FC	0	0	0	0	0	0
Telecardiology	16	6	11	4	53	10
Telecardiology+NN	1	0	0	0	0	0
Telecardiology+FC	0	0	0	0	0	0
Type-2 fuzzy c-means	2	1	26	8	1	1
Type-2 fuzzy clustering	1	1	60	14	2	1
Type-2 fuzzy c-means+NN	0	0	26	1+1*	0	0
Type-2 fuzzy c-means+ECG	0	0	1	1*	0	0

NN:Neural network, FC: Fuzzy Clustering, ECG: Electrocardiography, *:Ceylan ve ark. 2009

2. SINIFLANDIRMA

2.1. Yapay Sinir Ağları

Biyolojik sinir ağları beynimizde bulunan birçok sayıda sinir hücresinin bir koleksiyonudur. Bir sinir ağı milyarlarca sinir hücresinin bir araya gelmesi ile oluşmaktadır. Sinir hücreleri birbirleri ile bağlanarak fonksiyonlarını yerine getirirler. İnsan beyni çok hızlı çalışabilen mükemmel bir bilgisayar gibi görülebilir. Örneğin, insan beyni bir grup insan resmi içinden tanıdık bir resmi 100-200 ms gibi kısa bir sürede fark edebilir. Halbuki geleneksel bilgisayarların böyle bir tanıma işlemini yapması çok daha uzun zaman alır. Biyolojik sinir ağlarının performansları küçümsenemeyecek kadar yüksek ve karmaşık olayları işleyebilecek yetenektedir (Öztemel 2003). Yapay sinir ağları temelinde bu yeteneğin bilgisayara kazandırılması fikrinden ortaya çıkmıştır. Bu nedenle yapay sinir ağları biyolojik sinir hücrelerine benzetilerek modellenmeye çalışılır.

2.1.1. Temel yapay nöron modelleri


Bir yapay nöron bir işlem elemanı, düğüm yada bir eşik lojik birimi olarak düşünülebilir ve genel olarak “nöron” şeklinde adlandırılır. Bir nöron biyolojik kopyasına benzeyen bir bilgi işlem birimidir. Şekil 2.1’ de bir yapay nöron modeli gösterilmiştir. Nöron modelinin dört temel bileşeni vardır (Ham ve Kostanic 2001).

- Sinaptik ağırlıklarla bağlantıyı sağlayan sinapsisler giriş düğümleridir. Şekil 2.1’ de gösterildiği gibi sinapsislere sürekli değerli giriş $x \in \mathcal{R}^{n \times 1}$ vektör sinyalidir. Burada, x_j giriş vektörüdür ve $j = 1, 2, \dots, n$ ise $x = [x_1, x_2, \dots, x_n]^T$ olarak ifade edilir. Bu nedenle her x_j vektör bileşeni j . sinapsa giriştir ve w_{qj} sinaptik ağırlığıyla q nöronuna bağlanır. x_j ile w_{qj} sinaptik ağırlığı çarpılır. Buradaki notasyonlarda ilk indis sinapsisin bağlandığı nöronu, ikinci indis

sinaptik ağırlığın çarpılacağı nöronu göstermektedir. Bu notasyon sinir ağı yapıları için geneldir.

- Toplama elemanı toplayıcıya gelen bütün sinyalleri toplar. Her giriş önce ilgili sinaptik ağırlıkla çarpılır ve sonra toplanır. Toplayıcı çıkışı u_q sinapslarla girişlerin lineer kombinasyonunu ifade eder.
- Aktivasyon fonksiyonu (sıkıştırma fonksiyonu) $f(\cdot)$ nonlinear bir fonksiyondur ve y_q çıkış fonksiyonu genliğini sınırlar. Aktivasyon fonksiyonu binary, sürekli değerli, bipolar olabilir veya bazı durumlarda lineer olabilir. Aktivasyon fonksiyonu nonlinear ise sonlu sınırlar genel olarak $[0,1]$ aralığında (binary) yada $[-1,1]$ aralığında (bipolar) normalize edilir. Nonlineerlik; ağıın sınıflandırmasının, yaklaşımının ve gürültü eliminasyon yeteneğinin artmasına hizmet eder.
- θ_q eşik genellikle dıştan uygulanır ve aktivasyon toplamının toplam girişini düşürür. Bu sebepten θ_q aktivasyon fonksiyonu uygulanmadan lineer birleştirici çıkışı u_q ' dan çıkarılır. θ_q değeri bias olarak alındığında değeri u_q ' nın üzerine ekleneceğinden aktivasyon fonksiyonuna giriş artacaktır. θ_q eşik olarak alınırsa aktivasyon potansiyeli veya aktivite seviyesi şu şekilde olur:

$$v_q = u_q - \theta_q \quad (2.1)$$



Şekil 2.1 Bir yapay nöron için nonlinear model

q nöronunun lineer birleştirici çıkışı u_q , θ_q eşik değerinin pozitif yada negatif olmasına bağlıdır. Eşik, lineer birleştirici çıkışına “affine transformasyon” uygulanması olarak düşünülebilir (Ham ve Kostanic 2001).

Matematiksel olarak, Şekil 2.1’ deki yapay nöronun işlemini aşağıdaki eşitliği yazarak tanımlayabiliriz. Lineer birleştirici çıkışı aşağıdaki eşitlikle verilebilir:

$$u_q = \sum_{j=1}^n w_{qj}x_j = w_q^T x = x^T w_q \quad (2.2)$$

Burada x yukarıdaki gibi tanımlanır, $w_q = [w_{q1}, w_{q2}, \dots, w_{qn}]^T \in \mathcal{R}^{n \times 1}$ şeklindedir, aktivasyon fonksiyonu çıkışı

$$y_q = f(v_q) = f(u_q - \theta_q) \quad (2.3)$$

şeklinde ifade edilebilir. (2.2) ve (2.3) kullanılarak nöronun çıkışı aşağıdaki gibi verilebilir.

$$y_q = f(\sum_{j=1}^n w_{qj}x_j - \theta_q) \quad (2.4)$$


Şekil 2.2’ de farklı bir yapay nöron modeli gösterilmiştir. Bu modelde eşik (veya bias) q nöronu için sinaptik ağırlık vektörü w_q ($w_q \in \mathcal{R}^{n+1 \times 1}$) ve giriş vektörü ($x \in \mathcal{R}^{n+1 \times 1}$) birleştirilmektedir. Efektif dahili aktivasyon potansiyeli (2.5) eşitliğindeki gibidir.

$$v_q = \sum_{j=0}^n w_{qj}x_j \quad (2.5)$$

q nöronu çıkışı aşağıdaki gibi yazılabilir:

$$y_q = f(v_q) \quad (2.6)$$

Bu sebepten (2.5)' de Şekil 2.2' den hareketle yeni bir sinaps eklenmiştir. Burada eşik veya bias olmasına bağlı olarak sinaps için giriş $x_0 = -1$ yada $x_0 = 1$ olacaktır. Bağlantılı sinaptik ağırlık harici eşik için $w_{q0} = \theta_q$ ve harici bias için $w_{q0} = \beta_q$ olacaktır (Ham ve Kostanic 2001).



Şekil 2.2 Farklı nonlinear bir model


2.1.2. Temel aktivasyon fonksiyonları

Şekil 2.1' de veya Şekil 2.2' de blok olarak gösterilen aktivasyon fonksiyonu (transfer fonksiyonu) lineer yada nonlinear bir fonksiyon olabilir. Aktivasyon fonksiyonlarının birçok farklı tipi vardır. Bu tipler arasından biri veya diğerinin seçimi problemin çözümünü sağlamasına bağlıdır. Burada birçok farklı tipte aktivasyon fonksiyonundan dört tanesi sunulmuştur. Aktivasyon fonksiyonlarının sunumu için temel referans model Şekil 2.2' de gösterilmiştir. Başka türlü bir gösterim istenmedikçe eşik (yada bias) "0" a ayarlanmalıdır (Ham ve Kostanic 2001).

İlk tip sürekli değerli "lineer (yada birim) fonksiyon" dur. Matematiksel olarak q nöronundaki lineer aktivasyon fonksiyonunun çıkışı şu şekildedir:

$$y_q = f_{lin}(v_q) = v_q \quad (2.7)$$

Burada v_q (efektif dahili aktivasyon potansiyeli) Şekil 2.2’ de gösterildiği gibi lineer birleştiricinin çıkışıdır ve aktivasyon fonksiyonu $f(\cdot)$ ’ nin girişidir. Birim fonksiyonun çıkışı nöron çıkışı y_q ’ dur ve v_q ’ ya eşittir. Şekil 2.3’ de lineer bir aktivasyon fonksiyonu verilmiştir. Lineer ağlarda bu fonksiyon oldukça kullanışlıdır.



Şekil 2.3 Lineer (linear) aktivasyon fonksiyonu

İkinci tip aktivasyon fonksiyonu “keskin sınırlayıcı (hard limiter)” olarak isimlendirilen fonksiyondur (Ham ve Kostanic 2001). Bu fonksiyon, girişi 0’ a veya 1’ e sınırladığı için *ikili (binary)* olarak da adlandırılır. Fonksiyonun bipolar tipi kullanılırsa giriş -1’ e yada 1’ e sınırlanır. Binary keskin sınırlayıcı bazen eşik fonksiyonu olarak isimlendirilir, aynı şekilde bipolar olanı da simetrik keskin sınırlayıcı olarak adlandırılır. Binary keskin sınırlayıcının çıkışı (2.8)’ deki gibi yazılabilir:


$$y_q = f_{h1}(v_q) = \begin{cases} 0, & v_q < 0 \\ 1, & v_q \geq 0 \end{cases} \quad (2.8)$$

Simetrik keskin sınırlayıcı için q nöron çıkışı aşağıdaki gibidir:


$$y_q = f_{sh1}(v_q) = \begin{cases} -1, & v_q < 0 \\ 0, & v_q = 0 \\ 1, & v_q > 0 \end{cases} \quad (2.9)$$

Bu fonksiyon bazı zamanlarda “*signum* (yada *sign*)” fonksiyonu olarak anılır ve $f(\cdot) = \text{sgn}(\cdot)$ şeklinde yazılır. Şekil 2.4 ve Şekil 2.5 keskin sınırlayıcı ve

simetrik keskin sınırlayıcı karakteristiklerini gösterir. Keskin sınırlayıcı aktivasyon fonksiyonlu yapay nöron McCulloch-Pitts modelini anımsatır (Ham ve Kostanic 2001).



Şekil 2.4 Keskin sınırlayıcı aktivasyon fonksiyonu



Şekil 2.5 Simetrik keskin sınırlayıcı aktivasyon fonksiyonu


Üçüncü tip temel aktivasyon fonksiyonu “doyurulmuş lineer fonksiyon (saturating linear function)” ya da “parçalı lineer fonksiyon (piecewise linear function)” dur. Fonksiyonun bu tipi çıkışın saturasyon limitleri için ya binary yada bipolar aralığa sahip olabilir. Bipolar saturasyon lineer fonksiyonu “simetrik saturasyon lineer fonksiyonu” olarak anılır. Saturasyon lineer fonksiyonu için q nöron çıkışı (2.10) eşitliği ile verilebilir.

$$y_q = f_{s1}(v_q) = \begin{cases} 0, & v_q < -\frac{1}{2} \\ v_q + \frac{1}{2}, & -\frac{1}{2} \leq v_q \leq \frac{1}{2} \\ 1, & v_q > \frac{1}{2} \end{cases} \quad (2.10)$$


Simetrik saturasyon lineer fonksiyonu için çıkış (2.11) ile ifade edilebilir:

$$y_q = f_{s1}(v_q) = \begin{cases} -1, & v_q < -1 \\ v_q, & -1 \leq v_q \leq 1 \\ 1, & v_q > 1 \end{cases} \quad (2.11)$$

Şekil 2.6 ve Şekil 2.7’ de saturasyon lineer fonksiyonu ve simetrik saturasyon lineer fonksiyonu gösterilmiştir.




Şekil 2.6 Saturasyon lineer fonksiyonu



Şekil 2.7 Simetrik saturasyon lineer fonksiyonu

Temel aktivasyon tiplerinin dördüncüsü “sigmoid” fonksiyonudur ve iki tiptir. Nonlinear sigmoid fonksiyonu yapay sinir ağlarının oluşturulmasında kullanılan en genel aktivasyon fonksiyonudur. Sigmoid fonksiyonun ilk tipi “*binary sigmoid fonksiyonu*” dur. Bu fonksiyonun saturasyon çıkış değeri bir binary aralığa sahiptir ve matematiksel olarak q nöron çıkışı (2.12) eşitliği ile yazılabilir (Ham ve Kostanic 2001).

$$y_q = f_{bs}(v_q) = \frac{1}{1+e^{-\alpha v_q}} \quad (2.12)$$




Şekil 2.8 Üç farklı eğim değeri için binary sigmoid aktivasyon fonksiyonu

Burada α binary sigmoid fonksiyonunun eğim parametresidir. Bu parametre değiştirilerek Şekil 2.8’ de gösterildiği gibi fonksiyonun farklı tipleri elde edilebilir.

Orijinde türeve sahip olmayan keskin sınırlayıcıya benzememekle birlikte binary sigmoid fonksiyonu sürekli ve türevlenebilir bir fonksiyondur. Bir aktivasyon fonksiyonunun türevlenebilir olması yapay sinir ağı proseslerinde önemli rol oynar. Lineer birleştiricinin çıkışına göre binary sigmoid fonksiyonunun türevi şu şekilde yazılabilir:

$$g_{bs}(v_q) = \frac{df_{bs}(v_q)}{d(v_q)} = \frac{\alpha e^{-\alpha v_q}}{(1+e^{-\alpha v_q})^2} = \alpha f_{bs}(v_q)[1 - f_{bs}(v_q)] \quad (2.13)$$

Orijinde binary sigmoid fonksiyonunun eğimi $\alpha/4$ ile verilebilir. Eşitlik (2.13)’ de $v_q = 0$ yazılırsa bu eğim kolaylıkla elde edilir. Bu nedenle α arttıkça binary sigmoid fonksiyonu keskin sınırlayıcıya yaklaşır. Şekil 2.9’ da binary sigmoid fonksiyonunun $\alpha = 1$ ve $\alpha = 0.5$ gibi iki farklı eğim değeri için türevi gösterilmektedir (Ham ve Kostanic 2001).




Şekil 2.9 Binary sigmoid fonksiyonunun iki farklı eğim değeri için türevi

Sigmoid fonksiyonunun bipolar tipi “*hiperbolik tanjant sigmoid fonksiyonu*” olarak adlandırılır. Bu fonksiyonun saturasyon limitleri bipolar aralığa sahiptir ve q nöron çıkışı (2.14) eşitliği ile yazılabilir.

$$y_q = f_{hts}(v_q) = \tanh(\alpha v_q) = \frac{e^{\alpha v_q} - e^{-\alpha v_q}}{e^{\alpha v_q} + e^{-\alpha v_q}} = \frac{1 - e^{-2\alpha v_q}}{1 + e^{-2\alpha v_q}} \quad (2.14)$$

Burada α eğim parametresidir. Hiperbolik tanjant sigmoid fonksiyonu eğim parametresinin üç farklı değeri için Şekil 2.10’ da gösterilmiştir (Ham ve Kostanic 2001).



Şekil 2.10 Üç farklı eğim değeri için hiperbolik tanjant sigmoid aktivasyon fonksiyonu

Hiperbolik tanjant sigmoid fonksiyonunun v_q ’ ya göre türevi aşağıdaki gibidir.

$$g_{hts}(v_q) = \frac{df_{hts}(v_q)}{dv_q} = \alpha[1 + f_{hts}(v_q)][1 - f_{hts}(v_q)] \quad (2.15)$$

2.1.3. İleri beslemeli çok katmanlı yapay sinir ağları

Şekil 2.11’ de dört katmandan oluşmuş bir standart ileri beslemeli çok katmanlı ağ yapısı görülmektedir. Yapının bu tipi kaskat bağlanmış katmanlardan oluşan ileri beslemeli ağların geniş sınıfından bir kısmını temsil eder. Bu sınıftaki sinir ağı yapıları, “herhangi bir katmandaki bütün nöronlar komşu katmandaki diğer nöronlara tek yönlü ağlarla bağlı olma” ortak özelliğine sahiptirler. Bağlantılar tek yönde yani ileri yönde iletim bilgisine sahiptirler. Bu bağlantılar tanımlanan öğrenme kuralı kullanılarak sinaptik ağırlıklarla yapılır. İleri beslemeli ağlarda katmandaki nöronlar arasında herhangi bir bağlantı söz konusu değildir. Her nöronda lineer birleştirici çıkışı nöronun cevabıdır ve girişi nöron aktivite seviyesi v_q olan bir nonlineer aktivasyon fonksiyonu ($f(\cdot)$)’ nun çıkışıdır. Ağdaki nöronlar tipik olarak $[-1,1]$ arasında bir aktivite seviyesine sahiptir. Bazı uygulamalarda bu aralık $[0,1]$ olarak kullanılır. Şekil 2.11’ deki ağ yapısı 4 katmandan oluşmaktadır. Bu katanlar giriş katmanı, iki gizli katman ve çıkış katmanı olarak sıralanabilir. Giriş katmanındaki veri ilk gizli katmana verilir. Notasyonlarda numaralandırma kullanılırken giriş katmanına “0” numarası verilmiştir. İlk gizli katmanın çıkışları ikinci gizli katmanın girişleridir. İkinci gizli katman çıkışları ise çıkış katmanı için giriş bilgisidir. Çıkış katmanı çıkışları ağ cevap vektörüdür. Bu ağ nonlineer giriş/çıkış haritalamasını ($\Omega: \mathcal{R}^{n \times 1} \rightarrow \mathcal{R}^{m \times 1}$) gerçekleştirir. Genel olarak, yapıda farklı sayıda gizli katmanlar olabilir, fakat pratikte bir yada iki gizli katman kullanılır. Yeterli nöron sayısına sahip tek gizli katmanlı bir ağ nonlineer bir haritalamada oldukça başarılı olabilir (Ham ve Kostanic 2001).

Şekil 2.11’ de her katman önceki katman ile sonraki katman arasında W^l ($l = 1,2,3$) şeklinde bir sinaptik ağırlık matrisine sahiptir. Giriş katmanı ile ilk

gizli katman arasındaki ağırlık matrisi $W^{(1)} = [w_{ji}^{(1)}] \in \mathcal{R}^{h \times n}$ şeklindedir. İlk gizli katman ile ikinci gizli katman arasındaki ağırlık matrisi $W^{(2)} = [w_{rj}^{(2)}] \in \mathcal{R}^{p \times h}$ ve ikinci gizli katman ile çıkış katmanı arasındaki ağırlık matrisi $W^{(3)} = [w_{sr}^{(3)}] \in \mathcal{R}^{m \times p}$ dir ($i = 1, 2, \dots, n; j = 1, 2, \dots, h; r = 1, 2, \dots, p; s = 1, 2, \dots, m$). Nonlineer giriş-çıkış haritalaması ($\Omega: \mathcal{R}^{n \times 1} \rightarrow \mathcal{R}^{m \times 1}$ Şekil 2.11' deki gibi doğrudan tanımlanabilir. Diagonal nonlineer işleme matrisi aşağıdaki şekilde tanımlanabilir:

$$f^{(l)}[\cdot] \triangleq \text{diag} [f^{(l)}[\cdot], f^{(l)}[\cdot], \dots, f^{(l)}[\cdot]] \quad (2.16)$$

Bu matrisin boyutu l ' ye bağlıdır. $l = 1$ olduğunda, $f^{(1)}[\cdot]$ $h \times h$ boyutunda bir matristir; $l = 2$ için $f^{(2)}[\cdot]$, $p \times p$ boyutundadır; $l = 3$ için $f^{(3)}[\cdot]$; $m \times m$ boyutundadır. Verilen ağırlık giriş vektörü $x \in \mathcal{R}^{n \times 1}$ kullanılarak ilk katmanın çıkışı $x_{out1} \in \mathcal{R}^{h \times 1}$ (2.17) eşitliği kullanılarak yazılabilir (Ham ve Kostanic 2001).

$$x_{out1} = f^{(1)}[v^{(1)}] = f^{(1)}[W^{(1)}x] \quad (2.17)$$

(2.17) de yer alan ifade ikinci katmanın girişidir. İkinci katmanın çıkışı ise $x_{out2} \in \mathcal{R}^{p \times 1}$ şu şekildedir:


$$x_{out2} = f^{(2)}[v^{(2)}] = f^{(2)}[W^{(2)}x_{out1}] \quad (2.18)$$

Bu üçüncü katmanın yani çıkış katmanının girişidir. Üçüncü katmanın çıkışı $y = x_{out3} \in \mathcal{R}^{m \times 1}$ ağırlık cevabını verir

$$y = x_{out3} = f^{(3)}[v^{(3)}] = f^{(3)}[W^{(3)}x_{out2}] \quad (2.19)$$

(2.17) eşitliğindeki ifadeyi (2.18)' de yerine koyarsak ve elde edilen ifade (2.19) eşitliğinde yerine konulursa aşağıdaki ağ cevabı elde edilir:

$$y = f^{(3)} \left[W^{(3)} f^{(2)} \left[W^{(2)} f^{(1)} [W^{(1)} x] \right] \right] = \Omega[x] \quad (2.20)$$



Şekil 2.11 İleri beslemeli dört katmanlı yapay sinir ağı yapısı

(2.20) eşitliğindeki nonlinear haritalamada sinaptik ağırlıklar sabittir. Ancak örneğin bir örüntü sınıflandırma probleminin çözümünde arzu edilen haritalamayı gerçekleştirmek için ağırlıkların güncellenmesini sağlayacak bir eğitim prosesine ihtiyaç vardır.

2.1.4. Geriye yayılım öğrenme algoritması

Çok katmanlı ağların eğitimi için geriye yayılım algoritması yada genelleştirilmiş delta kuralı kullanılır. Geriye yayılım literatürde geniş olarak kullanım alanı bulan bir eğitim algoritmasıdır. İlk kez Werbos¹ tarafından 1974' de geliştirilmiştir. 1982' de Parker, 1985' de LeCun ve 1986' da Rumelhart² tarafından yeniden geliştirilmiştir.

¹P.J.Werbos, "Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences", PhD Thesis, Cambridge, MA: Harvard University, 1974.

²D.E. Rumelhart, G.E. Hinton, R.J. Williams, "Learning Internal Representations by Error propagation" in Parallel Distributed Processing, vol.1, chap.8, eds. D.E. Rumelhart and J.L. McClelland, Cambridge MA:MIT Press 1986, pp.318-62.

Mühendislik alanı için algoritmanın Rumelhart tarafından sunulan şekli uygundur. Geriye yayılım algoritmaları ile eğitilen çok katmanlı ağlar nonlinear haritalamada yada çağrışım problemlerinde iyi sonuçlar verir. İki setlik datalar yada verilen giriş/çıkış çiftleri arasında özel bir haritalama gerçekleştirmek için geriye yayılım algoritması ile ağın sinaptik ağırlıkları güncellenir. Eğitim prosesinden sonra sabit ağırlıklı çok katmanlı ağ sınıflandırma, örüntü tanıma, teşhis vb. uygulamalar için çağrışım görevini gerçekleştirir. Çok katmanlı ağın eğitime aşamasında, sinaptik ağırlıklar ağın çıkışı ve arzu edilen hedef arasındaki farka göre bütün giriş örüntüleri (öğrenme örnekleri) için aynı şekilde minimize edilir.

2.1.4.1. İleri beslemeli ağlar için basit geriye yayılım algoritması

Bu bölümde çıkış katmanı ve iki gizli katman olmak üzere ağırlıklı üç katmana sahip çok katmanlı bir sinir ağı için geriye yayılım öğrenme kuralı incelenmiştir. Literatürdeki çalışmalarda da genel olarak bir yada iki gizli katmana sahip ağlar kullanılır. Bu tip bir sinir ağı Şekil 2.12' de verilmiştir. Ağ ikiden fazla gizli katmana sahip ise bu durumda türevler genel durum için genişletilir.

Çok katmanlı ağın eğitimi için standart geriye yayılım algoritması, anlık hata değerlerini gösteren enerji fonksiyonunu minimize etmek için uygulanan en hızlı azalan eğim yaklaşımını (steepest descent gradient approach) temel alır.

Bir başka deyişle, öğrenme algoritmasında aşağıdaki eşitlikle tanımlanan fonksiyonun minimize edilmesi amaçlanır (Ham ve Kostanic 2001):

$$E_q = \frac{1}{2} \left(d_q - x_{out}^{(3)} \right)^T \left(d_q - x_{out}^{(3)} \right) = \frac{1}{2} \sum_{h=1}^{n_3} \left(d_{qh} - x_{out,h}^{(3)} \right)^2 \quad (2.21)$$

Burada d_q , q . giriş örüntüsü için arzu edilen ağ çıkışını gösterir ve Şekil 3.4' de gösterilen çok katmanlı ağ için $x_{out}^{(3)} = y_q$ gerçek çıkıştır. (2.21) eşitliğinin minimize edilmesinden türeyen ağırlıkların güncellenmesi için kullanılan bu metot genel olarak çevrimiçi (online) metot olarak isimlendirilir ve minimum hafıza ihtiyacı olan algoritmalarından biridir.

En hızlı azalan eğim yaklaşımı kullanılarak, herhangi bir ağ katmanındaki ağ ağırlıkları için öğrenme kuralı (2.22) eşitliği ile verilir.

$$\Delta w_{ji}^{(s)} = -\mu^{(s)} \frac{\partial E_q}{\partial w_{ji}^{(s)}} \quad (2.22)$$

Burada $s = 1, 2, 3$ şeklinde ifade edilir ve ağ katmanı numarasıdır. Probleme uygun öğrenme oranı parametresi $\mu^{(s)} > 0$ ' dır. Çok katmanlı sinir ağının gizli katmanlarında ve çıkış katmanında ağırlıklar için ayrı öğrenme kuralı türetilir. İlk olarak ağın çıkış katmanı incelenir. Çıkış katmanındaki ağırlıklar (2.23) eşitliğine göre güncellenebilir.

$$\Delta w_{ji}^{(3)} = -\mu^{(3)} \frac{\partial E_q}{\partial w_{ji}^{(3)}} \quad (2.23)$$

Kısmi türevler için zincir kuralı kullanılarak, (2.23) eşitliği yeniden yazılabilir.

$$\Delta w_{ji}^{(3)} = -\mu^{(3)} \frac{\partial E_q}{\partial v_j^{(3)}} \frac{\partial v_j^{(3)}}{\partial w_{ji}^{(3)}} \quad (2.24)$$

(2.24)' deki ayrılmış terimler şu şekilde düzenlenebilir:

$$\frac{\partial v_j^{(3)}}{\partial w_{ji}^{(3)}} = \frac{\partial}{\partial w_{ji}^{(3)}} \left(\sum_{h=1}^{n_2} w_{ji}^{(3)} x_{out,h}^{(2)} \right) = x_{out,i}^{(2)} \quad (2.25)$$

$$\frac{\partial E_q}{\partial v_j^{(3)}} = \frac{\partial}{\partial v_j^{(3)}} \left\{ \frac{1}{2} \sum_{h=1}^{n_3} [d_{qh} - f(v_h^{(3)})]^2 \right\} = -[d_{qj} - f(v_j^{(3)})] g(v_j^{(3)}) \quad (2.26)$$

yada

$$\frac{\partial E_q}{\partial v_j^{(3)}} = -(d_{qj} - x_{out,j}^{(3)}) g(v_j^{(3)}) \triangleq -\delta_j^{(3)} \quad (2.27)$$

Burada $g(\cdot)$, nonlinear aktivasyon fonksiyonu $f(\cdot)$ ' nin ilk türevidir. (2.27)' de tanımlanan ifade lokal hatayı gösterir.

(2.24), (2.25) ve (2.27) eşitlikleri birleştirilerek, ağın çıkış katmanında ağırlıklar için öğrenme kuralı eşitliği aşağıdaki gibi yazılabilir (Ham ve Kostanic 2001).

$$\Delta w_{ji}^{(3)} = \mu^{(3)} \delta_j^{(3)} x_{out,i}^{(2)} \quad (2.28)$$

yada

$$w_{ji}^{(3)}(k+1) = w_{ji}^{(3)}(k) + \mu^{(3)} \delta_j^{(3)} x_{out,i}^{(2)} \quad (2.29)$$

Ağın gizli katmanlarında ağırlıklar için güncelleme eşitlikleri temel olarak aynı şekilde türevlenebilir. En hızlı azalan eğim yaklaşımı uygulanarak (2.30) eşitliği elde edilir.

$$\Delta w_{ji}^{(2)} = -\mu^{(2)} \frac{\partial E_q}{\partial w_{ji}^{(2)}} = -\mu^{(2)} \frac{\partial E_q}{\partial v_j^{(2)}} \frac{\partial v_j^{(2)}}{\partial w_{ji}^{(2)}} \quad (2.30)$$

(2.30) eşitliğinin sağ tarafındaki ikinci kısmi türev aşağıdaki gibi açılabilir:

$$\frac{\partial v_j^{(2)}}{\partial w_{ji}^{(2)}} = \frac{\partial}{\partial w_{ji}^{(2)}} \left(\sum_{h=1}^{n_1} w_{jh}^{(2)} x_{out,h}^{(1)} \right) = x_{out,i}^{(1)} \quad (2.31)$$

(2.30)' daki birinci kısmi türevde ağın çıkış katmanı üzerinde $v_j^{(2)}$, nin değişimi incelendiğinden oldukça karmaşıktır ve tüm ağ çıkışını etkiler. Bu kısmi türev ifadesi aşağıdaki gibi açılabilir (Ham ve Kostanic 2001):

$$\frac{\partial E_q}{\partial v_j^{(2)}} = \frac{\partial}{\partial x_{out,j}^{(2)}} \left\{ \frac{1}{2} \sum_{h=1}^{n_3} \left[d_{qh} - f \left(\sum_{p=1}^{n_2} w_{hp}^{(3)} x_{out,p}^{(2)} \right) \right]^2 \right\} \frac{\partial x_{out,j}^{(2)}}{\partial v_j^{(2)}} \quad (2.32)$$

yada

$$\frac{\partial E_q}{\partial v_j^{(2)}} = - \left[\sum_{h=1}^{n_3} (d_{qh} - x_{out,h}^{(3)}) g(v_h^{(3)}) w_{hj}^{(3)} \right] g(v_j^{(2)}) \quad (2.33)$$

$$= - \left(\sum_{h=1}^{n_3} \delta_h^{(3)} w_{hj}^{(3)} \right) g(v_j^{(2)}) \triangleq -\delta_j^{(2)}$$

(2.30), (2.31) ve (2.33) eşitlikleri birleştirilirse aşağıdaki ifade elde edilir:

$$\Delta w_{ji}^{(2)} = \mu^{(2)} \delta_j^{(2)} x_{out,i}^{(2)} \quad (2.34)$$

yada

$$w_{ji}^{(2)}(k+1) = w_{ji}^{(2)}(k) + \mu^{(2)} \delta_j^{(2)} x_{out,i}^{(2)} \quad (2.35)$$

(2.29) ve (2.35) eşitlikleri çıkış katmanı ve gizli katmandaki ağırlıklar için güncelleme eşitlikleridir. Farklı geriye yayılım algoritmaları arasındaki fark sadece lokal hata ifadesidir. Çıkış katmanı için, lokal hata arzu edilen çıkış ile gerçek ağ çıkışı arasındaki farkla orantılıdır. Gizli katmandaki çıkışlar için de aynı konsept genişletilerek, gizli katmandaki bir nöron için lokal hata, söz konusu nöronun arzu edilen çıkışı ile gerçek çıkışı arasındaki farkla orantılı olarak görülebilir. Ancak eğitim işlemi sırasında, gizli katmandaki nöronların arzu edilen çıkışları bilinmez ve bu sebepten lokal hatalar bütün bağlantılı nöronların hata sinyallerindeki terimler tekrarlanarak bulunur. (2.35) eşitliği çok katmanlı bir ağın gizli katmanları için genelleştirilebilir.

$$w_{ji}^{(s)}(k+1) = w_{ji}^{(s)}(k) + \mu^{(s)} \delta_j^{(s)} x_{out,i}^{(s)} \quad (2.36)$$


burada çıkış katmanı için

$$\delta_j^{(s)} = (d_{qh} - x_{out,j}^{(s)}) g(v_j^{(s)}) \quad (2.37)$$

olur. Gizli katmanlar için ise;

$$\delta_j^{(s)} = \left(\sum_{h=1}^{n_{s+1}} \delta_h^{(s+1)} w_{hj}^{(s+1)} \right) g(v_j^{(s)}) \quad (2.38)$$

olur.



Şekil 2.12 Geriye yayılım algoritması ile eğitilen ileri beslemeli dört katmanlı yapay sinir ağı yapısı

Standart geriye yayılım algoritmasının özeti

Standart geriye yayılım algoritması kullanılarak çok katmanlı ağı eğitimi aşağıdaki algoritma adımlarına göre gerçekleştirilir (Ham ve Kostanic 2001):

- Adım 1.* Ağın sinaptik ağırlıklarını küçük rastgele değerlerden başlat.
- Adım 2.* Giriş/çıkış çiftlerinden oluşan eğitim setinden, giriş örüntüleri ağı sunulur ve ağı cevapı hesaplanır.
- Adım 3.* Arzu edilen ağ cevabı ağı gerçek çıkışı ile karşılaştırılır ve (2.37) ve (2.38) kullanılarak bütün lokal hatalar hesaplanır.
- Adım 4.* Ağı ağırlıkları (2.36) 'a göre güncellenir.
- Adım 5.* Bütün eğitim örüntüleri için yeterli cevabın üretilmesinde, ağ önceden belirlenen doğruluk seviyesine erişinceye kadar, 2' den 4' e adımlar tekrarlanır.

Bu algoritma incelenirse klasik geriye yayılım algoritmasının iki bağımsız işlevi gerçekleştirdiği söylenebilir. İlk görev çıkış katmanındaki düğümlerden gizli katmandaki düğümlere hatanın geri yayılımıdır. İkincisi ise her katmandaki ağırlıkların en küçük kareler ortalaması metodu kullanılarak güncellenmesidir.

2.1.4.2. Çok katmanlı ağıın yakınsama hızı

Ağıın yakınsamasını garanti etmek ve eğitim sırasındaki osilasyonu önlemek için, öğrenme oranı parametresi göreceli olarak küçük bir değer alınmalıdır. Öğrenme oranı parametresinin küçük değerde olması ağıın ağırlıklarının değişimin sınırlayacağından, algoritmanın hızını etkileyecektir. Ayrıca, ağıın eğitiminin başlangıç noktası global minimumdan (toplam ağı hatasının en küçük olduğu nokta) çok uzaksa, nöronların bazıları saturasyonda işlem görebilir. Sayılan bu işlemler gerçekleştiğinde aktivasyon fonksiyonunun türevi küçük olur. Ağırlık değişimlerinin büyüklüğü doğrudan aktivasyon fonksiyonunun türevinin büyüklüğüne bağlı olduğu için, ağı hata yüzeyinin düz platosunda bir noktaya sabitlenebilir ve yakınsamaya erişmeden önce daha fazla iterasyona ihtiyaç duyar. Daha kompleks olan gerçek dünya problemleri için ağıın eğitimi saatler hatta günler sürebilir.

Geriye yayılım algoritmasının yavaş yakınsaması çok katmanlı sinir ağlarının eğitimi için alternatif (hızlı) algoritmaların araştırılmasına sebep olmuştur. Hızlı algoritmalar üzerindeki araştırmalar kabaca iki ana kategoriye ayrılabilir. İlk kategori standart geriye yayılım algoritmasına çeşitli bulgusal (heuristic) geliştirmeleri içerir. Kullanılabilir ve birçok durumda kolay anlaşılabilir olmasına rağmen, bulgusal algoritmalar her durum için özeldir ve performans karakteristikleri kolay tespit edilemez. İkinci kategori standart nümerik optimizasyon tekniklerinin kullanımını içerir. Bu kategorideki algoritmaların pek çoğu, ağıın hesapsal kompleksliğini artırma dezavantajına rağmen, ağıın yakınsama hızında belirli bir gelişme sağlar.

Geriye yayılım öğrenme algoritmasındaki iyileştirmelere ilave olarak, giriş verisinde önışleme ve azaltma performansın gelişmesini ve eğitimin hızlanmasını sağlar (Ham ve Kostanic 2001).

2.1.4.3. Momentum sabiti güncellemeli geriye yayılım öğrenme algoritması

Momentum güncellemeli geriye yayılım algoritması, standart algoritmanın en bilinen modifiye edilmiş şeklidir. Bu algoritmanın amacı, anlık hata yüzeyi ve eğitimin bir önceki adımında elde edilen hata yüzeyinin o anki eğiminin lineer kombinasyonu olan yönde ağırlıkların güncellenmesidir. Başka bir deyişle, ağırlıkların güncellemesi aşağıdaki eşitliğe göre yapılır (Ham ve Kostanic 2001).

$$\Delta w_{ji}^{(s)}(k+1) = \mu^{(s)} \delta_j^{(s)}(k) x_{out,i}^{(s)}(k) + \alpha \Delta w_{ji}^{(s)}(k-1) \quad (2.39)$$

yada

$$w_{ji}^{(s)}(k+1) = w_{ji}^{(s)}(k) + \mu^{(s)} \left[\mu^{(s)} \delta_j^{(s)}(k) x_{out,i}^{(s)}(k) + \alpha \delta_j^{(s)}(k-1) x_{out,i}^{(s)}(k-1) \right] \quad (2.40)$$

Burada α , hatırlatma faktörü (forgetting factor) olarak adlandırılır ve genel olarak (0,1) aralığında seçilir. (2.39)'daki ikinci terim momentum terimi olarak adlandırılır. Momentum terimi, ağırlık değişiminde kararlılığı sağlayarak standart geriye yayılım algoritmasının yakınsama hızını geliştirir. (2.39)'a göre sezgisel olarak, ağırlıklar önceki adımdaki gibi aynı yönde değişirse, değişim oranı artar. Alternatif olarak, o andaki değişim önceki adımdaki ile aynı yönde olmaz ise, değişim oranı azalır. Bu tip öğrenme, standart geriye yayılım algoritmasının yetersiz kaldığı bazı önemli durumlarda yakınsamayı belirgin olarak geliştirir. İlk olarak eğitim örüntüleri örneğin gürültü gibi bazı belirsiz elemanları içeriyorsa, momentumun güncellenmesi ağırlık güncellenmesi yönündeki hızlı değişimleri önleyerek bir tip alçak geçiren filtreleme sağlar. İkinci olarak, momentum teriminin bu özelliği aykırı ya da yanlış eğitim çiftlerinin varlığına karşı eğitimi sağlar. İlave olarak, eğer ağ düz hata yüzeyi platosunda işlem yapıyorsa, momentumun varlığı ağırlık değişiminin oranını artıracaktır ve yakınsama hızını artıracaktır. Buna uygun olarak ağırlık güncelleme eşitliği gözden geçirilerek (2.41) eşitliği elde edilir:

$$\Delta w_{ji}^{(s)}(k+1) = -\mu^{(s)} \frac{\partial E_q}{\partial w_{ji}^{(s)}} + \alpha \Delta w_{ji}^{(s)}(k-1) \quad (2.41)$$

Eğer ağ hata yüzeyinin düz alanında işlem yapıyorsa, eğimin değeri adımdan adıma büyük ölçüde değişmez. Bu sebepten (2.41) aşağıdaki eşitliğe yaklaşır:

$$\begin{aligned} \Delta w_{ji}^{(s)}(k+1) &\approx -\mu^{(s)} \frac{\partial E_q}{\partial w_{ji}^{(s)}} - \alpha \mu^{(s)} \frac{\partial E_q}{\partial w_{ji}^{(s)}} - \alpha^2 \mu^{(s)} \frac{\partial E_q}{\partial w_{ji}^{(s)}} + \dots \\ &= -\mu^{(s)} (1 + \alpha + \alpha^2 + \dots) \frac{\partial E_q}{\partial w_{ji}^{(s)}} \\ &\approx -\frac{\mu^{(s)}}{1-\alpha} \frac{\partial E_q}{\partial w_{ji}^{(s)}} \end{aligned} \quad (2.42)$$

Hatırlatma faktörü α her zaman 1' den küçük olduğu için, momentumun güncellenmesi etkin öğrenme oranını aşağıdaki eşitlikte görüldüğü gibi artırır.

$$\mu_{eff}^{(s)} = \frac{\mu^{(s)}}{1-\alpha} \quad (2.43)$$

2.1.4.4. Batch güncelleme

Standart geriye yayılım algoritmasında ağırlıklar her giriş/çıkış eğitim çifti için güncellenir. Batch güncellemeli yaklaşım, güncelleme gerçekleşmeden önce, birkaç eğitim örüntüsü üzerinde ağırlık düzeltmeleri toplar. Güncelleme genellikle her özel giriş/çıkış çifti için düzeltmelerin ortalaması olur (Ham ve Kostanic 2001).

Batch güncelleme yaklaşım aşağıdaki avantajlara sahiptir:

1. Birkaç eğitim çifti kullanılarak (mümkünse tümü) hata yüzeyinin standart geriye yayılımdan daha iyi bir tahminini verir.
2. Düzeltmelerin ortalaması işlemi sırasında, batch güncelleme prosedürü eğitim verisi üzerinde alçak geçiren filtreleme sağlar. Eğitim verisinin gürültü ile bozulmuş olduğu durumlarda bu bir avantajdır.
3. Batch algoritması, Newton metodu ya da birleştirilmiş eğimler metodu (conjugate gradient method) gibi daha karmaşık optimizasyon prosedürleri için uygundur.

Yukarıda listelenen avantajlar bazı faktörlerin varlığında elde edilir. Bu faktörler şu şekilde sıralanabilir:

1. Batch güncelleme hafıza gereksinimi açısından daha fazla boyuta ihtiyaç duyar. Ağırlıklar güncellenmeden önce ağırlık düzeltmeleri için ekstra bir hafıza gereksinimi olur. Özellikle çok sayıda ağırlığa sahip ağların kullanıldığı durumlarda hafıza gereksinimi kritik boyutlara ulaşır.
2. Ağırlık düzeltmelerinin ortalaması algoritmaya ekstra hesaplama yükü ekler.
3. Batch olmayan eğitim modu için (standart geriye yayılım gibi), eğitim çiftlerinde gürültü varlığı hata yüzeyinde lokal minimum noktasının ağır eğitimi sırasında kaçırılmasına neden olur. Batch güncellemenin yumuşatma

etkisi lokal minimuma yaklaşılmaması için öğrenme algoritmasını daha eğimli hale getirir.

Genel olarak, batch güncellemeli geriye yayılım algoritmasının performansı duruma bağlıdır. Batch güncelleme ile standart geriye yayılım arasındaki ortak nokta, ağırlıklar güncellenmeden önce bütün eğitim çiftleri üzerindeki değişikliklerin toplanmasıdır. Bu durum hata yüzeyinde daha iyi bir tahmin yapılmasına imkan verir.

2.1.4.5. Ara-Yakınsa metodu (Search-Then-Converge Method)

Ara-Yakınsa metodu geriye yayılım öğrenme algoritmasını hızlandırmak için Darken³ tarafından önerilen basit bir bulgusal metottur. Bu stratejiye göre çok katmanlı sinir ağlarında geriye yayılım algoritması iki safhaya ayrılır. İlk safhada, ağ global minimumdan uzaktır. Bu faz, *arama (search) fazı* olarak adlandırılır. Arama fazı sırasında öğrenme oranı yeterli büyüklükte ve sabit tutulur. Böylece ağ performans yüzeyinin minimumuna doğru hızlı bir azalma gerçekleştirir. İkinci faz *yakınsama (converge) fazı* olarak adlandırılır ve ağ global minimuma yaklaşırken başlar. Yakınsama fazında, öğrenme oranı daha iyi ayarlanmış ağırlıkları gerçekleştirecek ağı oluşturmak için her iterasyonda azalır. Pratikte ağın global minimumdan ne kadar uzaklıkta olduğunu söylemek imkansızdır ve bu sebepten ağın eğitimi başlamadan önce, öğrenme oranının azaltılması için bir strateji geliştirilmesi zorunludur. Sıkça rastlanan iki öğrenme oranı azaltma stratejisi (2.44) ve (2.45) eşitliklerinde sunulmuştur (Ham ve Kostanic 2001).

$$\mu(k) = \mu_0 \frac{1}{1+k/k_0} \quad (2.44)$$

$$\mu(k) = \mu_0 \frac{1+(c/\mu_0)(k/k_0)}{1+(c/\mu_0)(k/k_0)+k_0(k/k_0)^2} \quad (2.45)$$

³C. Darken, J. Moody, "Towards faster stochastic gradient search", Advances in Neural Information Processing Systems, vol.4, San Mateo, CA: Morgan Kaufmann, 1991, pp. 1009-16.

Burada $\mu_0 > 0$, başlangıç öğrenme oranını göstermektedir. c ve k_0 uygun olarak seçilen sabitlerdir. Tipik olarak, $1 < c/\mu_0 < 100$ ve $100 < k_0 < 500$ ' dir. (2.44) ve (2.45) eşitliklerinde $k \ll k_0$ olduğu zaman, öğrenme oranı sabittir ve yaklaşık olarak μ_0 ' a eşittir. Bu durum arama fazında gerçekleşir. $k \gg k_0$ olduğu zaman, öğrenme oranı (2.44)' de $1/k$ ile, (2.45)' de $1/k^2$ ile orantılı olarak azalır. Bu durum uygun c ve k_0 sabitlerinin seçildiğini gösterir. Böylece geriye yayılım algoritmasının hızı artırılmış olur.

2.1.4.6. Değişken öğrenme oranlı batch güncelleme

Değişken öğrenme oranlı batch güncelleme, geriye yayılım algoritmasının yakınsama hızının artırılması için basit bulgusal bir strateji önerir. Bu yaklaşımın arkasındaki fikir, bir önceki adımdaki öğrenme toplam hata fonksiyonunu azaltıyorsa, öğrenme oranının büyüklüğünün artırılmasıdır. Tersine, eğer hata fonksiyonu arttıysa, öğrenme oranının azaltılması gerekir. Algoritma aşağıdaki gibi özetlenebilir:

1. Eğer hata fonksiyonu bütün eğitim seti üzerinde azalıyorsa, öğrenme oranı $\eta > 1$ ($\eta = 1.05$) sayısı ile çarpılarak artar.
2. Eğer öğrenme oranı bazı setlerde ξ yüzdesinden (küçük bir değerdir) fazla artarsa, öğrenme oranı $\chi < 1$ ($\chi = 0.7$) sayısı ile çarpılarak azaltılır.
3. Eğer öğrenme oranı bazı setlerde ξ yüzdesinden az artarsa, öğrenme oranı değiştirilmez.

Değişken öğrenme oranının batch güncellemeye uygulanması hata fonksiyonunun eğiminin az olduğu ve yavaş azaldığı durumlarda yakınsamayı hızlandırabilir. Bununla beraber hata yüzeyinin minimum noktasının kolaylıkla kaçırılmasına sebep olabilir. Bunu önlemek için öğrenme oranının belli bir μ_{min} değerinin altına düşmesine izin verilmez (Ham ve Kostanic 2001).

2.2. Bulanık C-Ortalamlar Kümeleme Algoritması

Bulanık c-ortalamlar (BCO, fuzzy c-means) kümeleme algoritması bulanık ISODATA olarak da bilinir ve her datanın üyelik fonksiyonu ile belirlenmiş bir dereceye ve bir kümeye ait olduğu bir kümeleme algoritmasıdır. Bezdek tarafından önerilen bu algoritma hard c-means kümeleme algoritmasının geliştirilmiş halidir.

BCO, n - boyutlu x_i , $i = 1, 2, \dots, n$, vektörünü c sayıda bulanık gruba böler ve her grup için maliyet fonksiyonunu minimize eden bir küme merkezi bulur. BCO ile hard c-means arasındaki en önemli fark verilen veri noktasının 0 ile 1 arasındaki üyelik dereceleri ile belirlenmiş sahiplik dereceli çeşitli gruplara ait olabilmesini sağlayan bulanık bölünmeyi BCO' nun sağlamasıdır. Bulanık kümelemede başlangıçta U üyelik fonksiyonu her eleman için 0 ile 1 arasında değerlerden oluşur. Bununla beraber normalizasyon şartının sağlanması açısından bir veri kümesinin sahiplik derecelerinin toplamı her zaman 1' e eşit olmalıdır (Jang, 1997).

$$\sum_{i=1}^c u_{ij} = 1, \quad \forall j = 1, 2, \dots, n \quad (2.46)$$

BCO için maliyet fonksiyonu (objective function) (2.47) eşitliğindeki gibidir (Jang, 1997).

$$J(U, c_1, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \cdot d_{ij}^2 \quad (2.47)$$

Burada u_{ij} , 0 ile 1 arasındadır. c_i , i . bulanık grubun küme merkezi ve $d_{ij} = \|c_i - x_j\|$ j . veri noktası ile i . küme merkezi arasındaki öklit mesafesidir ve $m \in [1, \infty)$ bulanıklık sabitidir.

(2.47) eşitliğinin minimuma erişmesi için gerekli şartlar aşağıdaki gibi yeni bir $\bar{J}$ maliyet fonksiyonu şekillendirerek sağlanabilir (Jang, 1997):

$$\bar{J}(U, c_1, \dots, c_c, \lambda_1, \dots, \lambda_n) = J(U, c_1, \dots, c_c) + \sum_{j=1}^n \lambda_j \left(\sum_{i=1}^c u_{ij} - 1 \right) \quad (2.48.a)$$

$$\bar{J}(U, c_1, \dots, c_c, \lambda_1, \dots, \lambda_n) = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \cdot d_{ij}^2 + \sum_{j=1}^n \lambda_j \left(\sum_{i=1}^c u_{ij} - 1 \right) \quad (2.48.b)$$

Burada λ_j , $j = 1, 2, \dots, n$, (2.46) eşitliğindeki n durum için Lagrange çarpanıdır. Bütün giriş parametrelerine göre (2.47) eşitliğinin adım adım minimuma erişmesi için küme merkezi ve üyelik fonksiyonları aşağıdaki gibi belirlenir (Jang, 1997):

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (2.49)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{kj}} \right)^{\frac{2}{m-1}}} \quad (2.50)$$

Batch modda, BCO c_i küme merkezlerini ve U üyelik matrisini aşağıdaki adımlarla belirler (Jang, 1997):


- U üyelik matrisi 0 ile 1 arasındaki rasgele değerlerle başlar, başlangıç için alınan üyelik matrisinin (2.46) eşitliğini sağlaması gerekir.
- (2.49) eşitliğini kullanarak $c_i, i = 1, 2, \dots, c$, bulanık küme merkezlerini hesapla.
- (2.47) eşitliğine göre maliyet fonksiyonunu hesapla. Eğer birbirini izleyen iki iterasyon arasındaki hata değeri durdurma kriterinin altında ise durdur, değilse devam et.
- Yeni U üyelik fonksiyonunu (2.50) eşitliğine göre hesapla. 2. adıma dön.

BCO' nun optimum çözüme her zaman yaklaşabileceği garanti edilemez. BCO' nun performansı başlangıç küme merkezlerinin değerlerine bağlıdır.

2.3. Tip-2 Bulanık C-Ortalamalar Kümeleme Algoritması

Birçok örüntü tanıma uygulamasında, örüntü setinin ayrılması, küme prototiplerini örüntü setindeki bilgidan tahmin edebilen kümeleme algoritmalarının bir sonucudur. Birçok durumda, verilen örüntü setinden bilginin tam olarak çıkarılması mümkün değildir. Tam olmayan bilgiler herhangi bir kümeleme algoritmasında mükemmel olmayan gösterimler oluşturabilir. Bulanık kümeleme ile karşılaştırıldığı zaman, üyelik tasarımı belirsiz küme üyelikleri gibi çeşitli belirsizlikleri içerir (sebebi uzaklık ölçümü, bulanıklık, prototip ve prototip parametrelerinin başlangıcı gibi) (Rhee, 2007).

Şekil 2.13' den de görüleceği gibi bulanıklık sabiti m nin seçimine bağlı olarak, çok ayırık iki karesel örüntü seti için bile farklı sınıflandırma sonuçları elde edilebilir.




Şekil 2.13 Farklı hacim ve yoğunlukta iki karesel görüntü seti için sınıflandırma sonuçları (a) $m=2.0$ kullanılarak (b) $m=1.1$ kullanılarak

Ayrıca uzaklık ölçümü de yanlış sınıflandırmalara neden olabilir. Farklı kümeleme algoritmaları performansı kontrol eden çeşitli belirsizlikler içerir. Kullanılan bu parametrelerin belirsizliklerinin yönetimi, başarılı bir kümeleme algoritmasının geliştirilmesini sağlar.

2.3.1. Maliyet fonksiyonu tabanlı bulanık kümeleme algoritmaları ile ilgili belirsizlikler

Genel olarak maliyet fonksiyonu tabanlı kümeleme metotları bir örüntü ile küme prototipi arasındaki uzaklığı minimize etmeyi hedefler. Amaç, örüntü setini en iyi gösteren prototip parametresini belirlemektir. Bu yaklaşımlarda, örneğin c -ortalamalar gibi örüntü setini c bölüme ayıran iteratif algoritmalar sözkonusudur. Eğer örüntü seti “kompakt” kümeler olarak şekillenmişse ve her küme bir diğerinden ayrılabilir ise, arzu edilen kümeleme sonuçları c -ortalamalar kullanılarak elde edilebilir. Gerçek dünya uygulamalarında böyle örüntü setleri bulmak zordur. Örneğin pek çok pratik uygulamada, örüntü setinde prototip olamayacak uzaklıktaki örüntüler (nonprototypical), “zayıf (poor)” küme bölünmelerine sebep olabilir. Bu sebepten, bu örüntüler arzu edilmeyen kümeleme sonuçlarına neden olur. c -ortalamaların bu dezavantajının aşılması, BCO (FCM) tabanlı kümeleme algoritmalarında küme prototipi parametrelerini belirlemek için bir örüntünün katılım derecesini kontrol eden üyelik (ağırlık) değerlerinin incelenmesine bağlıdır. Yüksek ağırlıklı örüntüler diğerleri ile karşılaştırıldığı zaman küme prototipinin belirlenmesinde önemli bir rol oynayabilir. Bir başka deyişle, herhangi bir örüntünün rolü, yüksek ağırlıklı örüntü ile karşılaştırıldığı zaman küme merkezinden uzakta kalan örüntü için azalır (Rhee, 2007).

Şekil 2.14’ den de görüleceği, eğer bulanıklık sabiti m artırılırsa, maksimum bulanık sınır genişler, m azaltılırsa sınır daralır.



Şekil 2.14 Aynı hacme sahip iki küme için maksimum bulanıklık alanı

(a) Küçük m değeri için (b) Büyük m değeri için

BCO' nun performansı m bulanıklılığının seçimine bağlıdır. Bu yüzden iyi bir m seçimi, örüntü setindeki dağılım için önemlidir.

2.3.2. BCO algoritmasında m bulanıklık sabitindeki belirsizlik

Literatürde BCO algoritması maliyet fonksiyonu tabanlı iteratif bir algoritmadır. BCO algoritması herhangi bir örüntü seti için bulanık üyelikleri tahsis eder ve tahsis edilen üyeliklere göre küme prototip parametrelerini günceller. Tahsis edilen üyelikler ağırlık değeri gibi rol oynar. Bu üyelikler küme prototiplerinin tahmininde bir örüntünün katkı derecesini gösterir. Katkının miktarı m bulanıklık sabitinin seçimine bağlıdır.

BCO algoritması (2.51) eşitliği ile verilen maliyet fonksiyonunu minimize etmeyi amaçlar (Rhee, 2007):

$$J(U, V) = \sum_{j=1}^C \sum_{i=1}^N \left(u_j(x_i) \right)^m d_{ij}^2, \quad \sum_{j=1}^C u_{ji} = 1 \quad (2.51)$$


Burada $U = [u_j(x_i)]$ ifadesi bulanık c - bölünmeyi gösterir ve $V = (v_1, v_2, \dots, v_c)$ ifadesi küme prototiplerini verir. m bulanıklık (fuzzifier) sabitini gösterir.

$$u_j(x_i) = \frac{1}{\sum_{k=1}^C \left(\frac{d_{ji}}{d_{ki}} \right)^{2/(m-1)}} \quad (2.52)$$

$d_{ji}(d_{ki})$ uzaklığı, $v_j(v_k)$ küme prototipi ile x_i örüntüsü arasındaki mesafeyi gösterir.

$$d_{ji}^2 = (x_i - v_j)^T A_j (x_i - v_j) \quad (2.53)$$


Eğer örüntü setindeki kümelerin geometrisi benzer hacim ve yoğunlukta ise, m bulanıklık sabitindeki değişim BCO kümeleme sonucunu etkilemeyecektir (Şekil 2.14). Bununla beraber, eğer küme geometrileri arasında belirgin hacim ve yoğunluk farkı varsa, m ' nin değişimi tutarsız bir kümeleme sonucu verecektir. Şekil 2.15' de böyle bir örüntü setinde BCO algoritması ile elde edilen kümeleme sonucu verilmiştir (Rhee, 2007).




Şekil 2.15 Farklı hacme sahip iki küme için maksimum bulanıklık alanı

(a) Küçük m değeri için (b) Büyük m değeri için

Farklı geometrilere sahip iki küme içeren bir örüntü setinin kümelenmesi sonucu arzu edilen ideal sonuç Şekil 2.16’ da gösterildiği gibi olmalıdır. Şekilden de görüleceği gibi her küme için uygun bulanıklık (m) değeri seçilmiştir. Böylece arzu edilen maksimum bulanık sınır elde edilmiştir. Şekil 2.17’ de maksimum bulanık alana ait olan belirsizlik görülmektedir (Rhee, 2007).



Şekil 2.16 Arzu edilen maksimum bulanık alan



Şekil 2.17 İki bulanıklık sabiti için belirsiz maksimum bulanık alan


2.3.3. Aralık tip-2 bulanık setlerine genişleme

Bir örüntünün aralık tip-2 bulanık seti tanımlanmak istenirse; x_i örüntüsünün ilk üyeliği J_{x_i} ise, ilk üyeliğin “1” e eşit bütün ikinci dereceden üyelikleri kullanılarak, aşağıdaki ifade elde edilir (Rhee, 2007):

$$\tilde{A} = \{((x, u), \mu_{\tilde{A}}(x, u)) | \forall x \in A, \forall u \in J_x \subseteq [0,1], \mu_{\tilde{A}}(x, u) = 1\} \quad (2.54)$$

Şekil 2.18’ de bir boyutlu x' örneğinin üyeliği üst ($\overline{u}(x')$) ve alt ($\underline{u}(x')$) üyelikler arasındaki aralık (interval) kullanılarak gösterilmektedir. Böylece her x' bir $J_{x'} = [\underline{u}(x'), \overline{u}(x')]$ ilk üyelik mesafesine sahiptir. x' nün dikey dilimi Şekil 2.18’ de görülmektedir (Rhee, 2007).

Genel olarak, BCO’ daki bulanık üyelikler, (2.52) eşitliğinde olduğu gibi, küme prototipleri ve örüntüler arasındaki göreceli uzaklık kullanılarak hesaplanır. Tip-2 bulanık setlerinde, bir örüntünün ilk üyelik aralığını tanımlamak için, m' nin iki farklı değeri kullanılarak alt ve üst üyelik değerleri tanımlanmalıdır. Aralık tip-2 bulanık setleri ile x' örüntüsünü genişleten başlangıç üyelikleri (2.55) eşitliği kullanılarak bulunur.



Şekil 2.18 (a) Aralık tip-2 bulanık seti (b) x' örneğinin dikey izdüşümü


$$\overline{u}_j(x_i) = \begin{cases} \frac{1}{\sum_{k=1}^C (d_{ji}/d_{ki})^{2/(m_1-1)}}, & \text{eğer } \frac{1}{\sum_{k=1}^C (d_{ji}/d_{ki})^{2/(m_1-1)}} > \frac{1}{\sum_{k=1}^C (d_{ji}/d_{ki})^{2/(m_2-1)}} \\ \frac{1}{\sum_{k=1}^C (d_{ji}/d_{ki})^{2/(m_2-1)}}, & \text{diğer durumlarda} \end{cases}$$

$$\underline{u}_j(x_i) = \begin{cases} \frac{1}{\sum_{k=1}^C (d_{ji}/d_{ki})^{2/(m_1-1)}}, & \text{eğer } \frac{1}{\sum_{k=1}^C (d_{ji}/d_{ki})^{2/(m_1-1)}} \leq \frac{1}{\sum_{k=1}^C (d_{ji}/d_{ki})^{2/(m_2-1)}} \\ \frac{1}{\sum_{k=1}^C (d_{ji}/d_{ki})^{2/(m_2-1)}}, & \text{diğer durumlarda} \end{cases} \quad (2.55)$$

(2.55) eşitliğinde, m_1 ve m_2 farklı bulanıklık derecelerini gösteren bulanıklık sabitleridir. Bir örüntü için ilk üyelik aralığı tanımlanırken, aralığın en yüksek (üst) ve en düşük (alt) üyelikleri kullanılır. Farklı bulanıklık derecelerini gösteren bulanıklık sabitlerinin kullanımı BCO algoritmasında minimize edilecek farklı maliyet fonksiyonlarını verir (Rhee, 2007).

Şekil 2.14 (a)'daki iki kümeli durum için Şekil 2.19' de görüldüğü gibi $m_1 = 1.1$ ve $m_2 = 5.0$ ve $m_1 = 2.0$ ve $m_2 = 5.0$ olmak üzere iki farklı durum

önerilmiştir. Bulanık üyelikler arasındaki fark, taranmış gri alanlar olarak gösterilen belirsizlik alanını (footprint of uncertainty-FOU) belirler. Küme merkezlerinde yer alan örüntüler için üyelik değeri 1.0' a eşittir, aynı örüntülerin diğer kümeler için üyelik değeri örüntü setindeki bulanık derecesine bakılmaksızın 0' a eşittir. Bu örüntüler için bir belirsizlik alanı yoktur. İki küme merkezine de eşit uzaklığa sahip örüntüler için, üyelikler 0.5' e eşittir. Bu örüntüler için de belirsizlik alanı yoktur (Rhee, 2007).



Şekil 2.19 BCO için aralık tip-2 bulanık setlerindeki belirsizlik alanı

2.3.4. Maliyet fonksiyon tabanlı aralık tip-2 bulanık kümeleme

Burada iki aşama söz konusudur:

1. Küme prototiplerinin güncellenmesi aşaması
2. Final kümeleme kararında kesin-ayırma (hard-partitioning) aşaması

İlk olarak küme prototiplerinin güncellenmesi aşaması gerçekleştirileceğinden bu aşamada bulanık setlerin aralık tip-2' ye genişletilmesi gerekir. Aynı zamanda genişletilmiş bulanık setlerle kümeleme tamamlandıktan sonra “tip azaltma (type reduction)” ve “durulaştırma (defuzzification)” işlemlerinin yapılması gereklidir. Birçok tip azaltma işlemi arasında en çok kullanılanı “genelleştirilmiş merkez tip azaltma metodu” dur. Bu metot, prototip tabanlı kümeleme algoritmalarındaki merkez-güncelleme (center-update) metoduna benzer. Tip-1 bulanık setlerinin merkezleri (2.56) eşitliğindeki gibi hesaplanır (Rhee, 2007).

$$v_x = \frac{\sum_{i=1}^N x_i u(x_i)}{\sum_{i=1}^N u(x_i)} \quad (2.56)$$

Aralık tip-2 bulanık setleri incelenerek ve genişletme prensibi uygulanarak, merkez tip azaltma (centroid type reduction) ile tahmin edilen merkezler (2.57) eşitliğindeki aralıkla elde edilebilir (Rhee, 2007):

$$v_{\tilde{x}} = [v_L, v_R] = \sum_{u(x_1) \in J_{x_1}} \dots \sum_{u(x_N) \in J_{x_N}} 1 / \frac{\sum_{i=1}^N x_i u(x_i)^m}{\sum_{i=1}^N u(x_i)^m} \quad (2.57)$$

J_{x_i} , x_i örüntüsü için $\bar{u}(x_i)$ ve $\underline{u}(x_i)$ ile bulunur.

Genel olarak N örüntü içeren bir aralık tip-2 bulanık setinde 2^N adet gömülü (embedded) bulanık set vardır. Bu sayı (2.57) eşitliği ile gömülü bulanık setlerinden bulunan merkez aralıklarının sayısıdır. Gömülü bulanık setlerinden bulunan merkez aralıkları birleştirilerek tip-1 bulanık setleri bulunur (Rhee, 2007).

$$Y = \{1/v_1, 1/v_2, \dots, 1/v_N\} \\ = 1/[v_L, v_R] \quad v_L \leq \forall v_i \leq v_R \quad (2.58)$$


Bu yaklaşımla, bir aralık tip-2 bulanık setinden tipi azaltılmış bulanık seti elde edilebilir. Ancak bu yaklaşımda örüntü sayısı artarsa, hesaplama yükü de oldukça artar.

Bu sebepten iteratif bir yöntemin kullanılması tip azaltma prosedürünün gerçekleştirilmesi için daha uygun olacaktır. Bu metotta kesin kümeleme (2.59) eşitliği kullanılarak gerçekleştirilir (Rhee, 2007).

$$v_j = \frac{\sum_{v \in J_{Y_i}} (u(v))v}{\sum_{v \in J_{Y_i}} (u(v))} = \frac{v_L + v_R}{2} \quad (2.59)$$

Şekil 2.18' deki örnekte görüldüğü gibi yukarıdaki prosedür uygulandığı zaman, aralık tip-2 bulanık setinin merkezi Şekil 2.20' de görüldüğü gibi elde edilir. Buradaki v_L ve v_R değerleri iki farklı m değerine göre üyelik aralıkları hesaplanır. Kesin kümeleme (2.60) eşitliği ile özetlenebilir (Rhee, 2007):

Eğer $u_j(x_i) > u_k(x_i)$ $k = 1, \dots, C$ ve $j \neq k$ ise x_i örüntüsü j kümesine aittir
(2.60)



Şekil 2.20 Kesin kümeye ve aralık tip-2 bulanık kümeye örnek

Ancak bu eşitlik tip-2 FCM de tip azaltma prosedürü yapılmadan kullanılamaz. (2.59) eşitliğinde kullanılan v_L ve v_R değerlerinin hesaplanabilmesi için her örüntüye ait sağ $(u_j^R(x_i))$ ve sol $(u_j^L(x_i))$ üyeliklerin bulunması gerekir. $(u_j^R(x_i))$ ve $(u_j^L(x_i))$ değerleri (2.61) ve (2.62) eşitliklerine uygun olarak elde edilir (Rhee, 2007).

$$u_j^R(x_i) = \frac{\sum_{l=1}^M u_{jl}(x_i)}{M} \quad (2.61)$$

Burada

$$u_{jl}(x_i) = \begin{cases} \bar{u}_j(x_i) & \text{Eğer } x_{il}, v_j^R \text{ için } \bar{u}_j(x_i) \text{ kullanılıyorsa} \\ \underline{u}_j(x_i) & \text{diğer durumlarda} \end{cases}$$

olarak bulunur.

$$u_j^L(x_i) = \frac{\sum_{l=1}^M u_{jl}(x_i)}{M} \quad (2.62)$$


Burada

$$u_{jl}(x_i) = \begin{cases} \bar{u}_j(x_i) & \text{Eğer } x_{il}, v_j^L \text{ için } \bar{u}_j(x_i) \text{ kullanılıyorsa} \\ \underline{u}_j(x_i) & \text{diğer durumlarda} \end{cases}$$

olarak bulunur.

(2.61) ve (2.62) eşitliklerinde M , x_i örüntüsü için özellik sayısını göstermektedir. Şekil 2.21' de tip-azaltma prosedürü gösterilmektedir.

Tip-2 bulanık kümeleme de kullanılan m_1 ve m_2 , $m_1 = m_2$ olacak şekilde seçilirse tip-1 bulanık kümeleme gerçekleştirilmiş olur (Rhee, 2007).



Şekil 2.21 X örüntü seti için tip azaltma prosedürü

3. ÖZELLİK ÇIKARMA

3.1. Temel Bileşen Analizi

Temel bileşen analizi (TBA), dijital görüntü işlemede Hotelling transformu, haberleşme teorisinde Karhunen-Loeve transformasyonu olarak bilinir (Jang 1997). Mühendislikte TBA' nın uygulama alanlarını şu şekilde sıralayabiliriz: Data sıkıştırma ve kodlama (kod çözme), desen tanıma, görüntü işleme, adaptif ışın şekillendirme, azaltılmış sıralı kontrolör tasarımı ve yüksek çözünürlüklü spektral analiz (frekans tahmini için).

Genel olarak TBA, optimal lineer transformasyon matrisi W' yı belirleyen bir istatistiksel metottur. Örneğin, giriş vektörü $x \in R^{n \times 1}$ ise, optimal lineer transformasyon matrisi $W \in R^{m \times n}$ ($m < n$) olur. Burada x giriş vektörü sıfır-ortalamalı olmalıdır (Wenyu 2003, Vargas 2002). Böylece x vektöründeki data aşağıdaki formüle göre azaltılabilir (Jang 1997, Theodoridis ve Koutroumbas 2003):

$$y = Wx \quad (3.1)$$

Burada $y \in R^{m \times 1}$ dir. TBA, giriş datasını orijinal n -boyutlu vektör uzayını m -boyutlu çıkış uzayına yansıtır. Bu yansıtma işlemi W transformasyon matrisi ile sağlanır ve genel olarak $m < n$ dir (Petranek 1997). Böylece TBA ile boyut azaltımı gerçekleştirilmiş olur. y , x giriş vektöründeki en önemli bilgileri yani bileşenleri içerir. Bileşenler azalan varyanslara göre sıralanır (Ham ve Kostanic 2001).

x , $x = [x_1, x_2, \dots, x_n]^T$ şeklinde sıfır-ortalamalı bir giriş vektörü olsun. x e ait kovaryans matrisi $C_x = E[xx^T]$ olur ve $C_x \in R^{n \times n}$ dir. Bu kovaryans matris kullanılarak elde edilen özvektörler $[w_1, w_2, \dots, w_m]$ olarak seçilebilir, yani bu matrisin ilk m özvektörü seçilebilir (Patridge 1998). Bu vektörde $w_1 = [w_{11}, w_{12}, \dots, w_{1n}]^T$, C_x kovaryans matrisinin en büyük özdeğeridir (λ_1), aynı şekilde $w_2 = [w_{21}, w_{22}, \dots, w_{2n}]^T$, C_x kovaryans matrisinin en büyük 2. özdeğeridir (λ_2). Böylece standart özdeğer probleminden matris eşitliği şu şekilde yazılabilir:

$$C_x w_j = \lambda_j w_j \quad j = 1, 2, \dots, n \text{ için} \quad (3.2)$$

Bu eşitlik $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$ şartını sağlamalıdır. C_x ' in ilk m özvektörü $[w_1, w_2, \dots, w_m]$ temel özvektörler olarak göz önüne alınır. x giriş vektörü için y ' deki m temel bileşen (3.1)' de verilen dönüşüm ile tanımlanır, burada dönüşüm matrisi W şu şekilde ifade edilir:

$$W = [w_1, w_2, \dots, w_m]^T \quad (3.3)$$

Bir başka deyişle giriş data uzayının m -boyutlu temel bileşen alt uzayı, C_x giriş kovaryans matrisinin m temel özvektörü ile oluşturulmuş bir alt uzay olarak tanımlanır.

(3.2) her özdeğer ve özvektör için yazılırsa,

$$\begin{aligned} C_x[w_1, w_2, \dots, w_n] &= [\lambda_1 w_1, \lambda_2 w_2, \dots, \lambda_n w_n] \\ C_x W^T &= W^T \text{diag}[\lambda_1, \lambda_2, \dots, \lambda_n] = W^T \Lambda \end{aligned} \quad (3.4)$$

Böylece

$$C_x W^T = W^T \Lambda \quad (3.5)$$

olur ve (3.5)' in her iki tarafı W ile çarpılırsa (burada W ' nin satırları ortonormal olduğu için, $m \leq n$ durumunda $WW^T = I$ dir.), (3.6) eşitliği elde edilir.

$$\Lambda = WC_x W^T \quad (3.6)$$

(3.5)' in her iki tarafı soldan W ile çarpılırsa ($m=n$ için $W^T W = I$ olur), (3.7) eşitliği elde edilir.

$$C_x = W^T \Lambda W = \sum_{i=1}^n \lambda_i w_i w_i^T \quad (3.7)$$

Bu ifade C_x ' in özdeğer ayrışımı (EVD-eigenvalue decomposition)' dır. Bu yüzden, (3.6)' daki $\Lambda \in R^{m \times m}$, (3.1)' deki y çıkış vektörünün kovaryans matrisini gösterir. y çıkış vektörünün elementleri C_x kovaryans matrisinin özdeğerleri ile eşit varyanslara sahiptir.

Bu durum (3.1)' de verilen lineer transformasyon tekrar gözden geçirilerek daha iyi görülebilir. j . temel bileşenin y_j olduğu varsayılırsa, bütün temel bileşenler sıralandığı zaman ilk temel bileşen giriş datası içinde en büyük varyansa sahip bileşendir, aynı şekilde ikinci temel bileşen de ikinci en büyük varyansa sahip bileşendir. Bu yüzden y_j , x data giriş vektörünün elementlerinin lineer bir kombinasyonu olarak düşünülür ve

$$y_j = w_{1j}x_1 + w_{2j}x_2 + \dots + w_{jn}x_n = w_j^T x \quad (3.8)$$

ifadesi yazılabilir. Burada $w_j \in \mathbb{R}^{n \times 1}$, dir. x sıfır ortalamalı bir vektör olarak alındığına göre, y_j ' nin varyansı (3.9) eşitliği ile ifade edilir.

$$\sigma_{y_j}^2 = E[y_j^2] = E[w_j^T x x^T w_j] = w_j^T E[x x^T] w_j = w_j^T C_x w_j = \sum_{i=1}^n \sum_{h=1}^n w_{ij} w_{hj} C_{xxih} \quad (3.9)$$

(3.9) eşitliğinin sağlanması için $w_j^T w_j = 1$ olması gerekir. Bu şart sağlandığı zaman y_j ' nin varyansı maksimize edilmiş olur. Bu problem Lagrange çarpanı metodu kullanılarak formülize edilebilir.

$$L(w_j) = \sigma_{y_j}^2 - \lambda_j (w_j^T w_j - 1) \quad (3.10)$$

(3.10) eşitliğinin w_j ' ye göre kısmi türevi alınarak, sıfıra eşitlenirse yukarıda bahsedilen şartı sağlayan nokta bulunabilir.

$$\begin{aligned} \frac{\partial L(w_j)}{\partial w_j} &= \frac{\partial}{\partial w_j} [\sigma_{y_j}^2 - \lambda_j (w_j^T w_j - 1)] \\ &= \frac{\partial}{\partial w_j} [w_j^T C_x w_j - \lambda_j (w_j^T w_j - 1)] \\ &= 2C_x w_j - 2\lambda_j w_j = 0 \end{aligned} \quad (3.11)$$

yada

$$(C_x - \lambda_j I) w_j = 0 \quad (3.12)$$

Bu ifade (3.2)' de verilen orijinal özdeğer problemidir. (3.12) eşitliğinin tek çözümü aşağıdaki eşitlikte verilmiştir.

$$|C_x - \lambda_j I| = 0 \quad (3.13)$$

(3.13) eşitliğindeki λ_j ($j=1,2,\dots,n$) varyansları, C_x ' in özdeğerleridir. Ayrıca (3.12) eşitliğindeki w_j ($j=1,2,\dots,n$) ise ilgili özvektörlerdir. (3.12) eşitliğinin her iki w_j^T ile çarpılırsa (3.14) ve (3.15) eşitlikleri elde edilir:

$$w_j^T (C_x - \lambda_j I) w_j = w_j^T C_x w_j - \lambda_j w_j^T w_j = \sigma_{y_j}^2 - \lambda_j = 0 \quad (3.14)$$

yada

$$\lambda_j = \sigma_{y_j}^2 \quad (3.15)$$

$j=1$ için $\lambda_1 = \sigma_{y_1}^2$ olur ve bu varyans C_x kovaryans matrisinin en geniş özdeğeridir yada x ' deki giriş data vektör elementlerinin lineer kombinasyonunun en geniş varyansıdır. Ayrıca ilgili vektör w_1 , en geniş varyansın vektör uzay yönünü gösterir. C_x ' in ilk m özvektörü (3.3)' de verilen transformasyon matrisini şekillendirmek için tutulur ve sonra (3.1) eşitliğinden $y=Wx$ yazılır, y ' nin elementleri ilk m temel bileşendir. m dikkatli olarak seçilirse, x girişindeki en önemli bilgi içeriği y ' de bulunur. Bundan başka $\hat{x}$ ' in lineer en küçük karesel tahmini (3.16) eşitliği ile yazılabilir.

$$\hat{x} = C_x W^T (W C_x W^T)^{-1} y \quad (3.16)$$

Buradan ortalama karesel hata fonksiyonu türetilir:

$$J(x) = E (\hat{x} - x)^T (x - \hat{x}) \quad (3.17)$$

W ' nın satırları C_x ' in ilk m temel özvektörünü ayırıyorsa, (3.17) eşitliği x ' e göre minimize edilir. m temel özvektörler $[w_1, w_2, \dots, w_m]$ ile ifade edilmek istenirse aşağıdaki şekilde yazılabilir:

$$\begin{aligned} \hat{x} &= \sum_{h=1}^m (x^T w_h) w_h = \sum_{h=1}^m w_h (x^T w_h) = \sum_{h=1}^m w_h (w_h^T x) \\ &= (w_1 w_1^T + w_2 w_2^T + \dots + w_m w_m^T) x \\ &= ([w_1, w_2, \dots, w_m] [w_1, w_2, \dots, w_m]^T) x = W^T W x = W^T y \end{aligned} \quad (3.18)$$

Pratikte, C_x kovaryans matrisi genellikle yaklaşık aşağıdaki gibi hesaplanabilir:

$$C_x \approx \hat{C}_x = \frac{1}{N} \sum_{k=1}^N x(k)x^T(k) = \frac{1}{N} XX^T \quad (3.19)$$

3.2. Dalgacık Dönüşümü (Wavelet Transform)

Zaman ve frekans sinyal analiz metotları sinyalin hem zaman hem de frekans ekseninde yorumunu sağlar (Übeyli ve Güler 2003). Kesik yada süreksiz bileşenlerin bulunmasını sağlar. FFT gibi spektral metotlarla yalnızca bazı bileşenler anlaşılabilir. Zaman-frekans metotlarının bir kısmı şu şekilde sıralanabilir: Kısa Süreli Fourier Dönüşümü (Short-Time Fourier Transformation-STFT), Wigner-Ville Dönüşümü (WVT), Choi-Williams Dağılımı (CWD) ve Sürekli Dalgacık Dönüşümü (CWT).

Dalgacık dönüşümünün kullanılmasından önce yukarıda bahsedildiği gibi pek çok teknik kullanılmıştır (Semmlow 2004). Dalgacık dönüşümü analizi 1980' lerde sismik sinyalleri sorgulamak için geliştirilmiştir. Fakat daha sonra bir ilerleme kaydedilememiştir. 1990' ların başında bilim ve mühendislikte dalgacık dönüşümü uygulamaları ile tekrar çalışmalar başlamıştır. Son yüzyılın ortalarında bu konuda çalışan araştırmacıların sayısındaki hızlı artış, dalgacık analizi konusuna tekrar dikkatlerin toplanmasını sağlamıştır.

Literatürdeki çalışmalar incelenecek olursa, dalgacık dönüşümü iki sınıfa ayrılmaktadır (McAndrew 2004):

* Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform-CWT)

* Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform-DWT)

3.2.1. Sürekli dalgacık dönüşümü

Sürekli Dalgacık Dönüşümü (SDD), yüksek frekans sinyal özelliklerinde yüksek lokalizasyona izin vermesi ile geleneksel bir metot olan kısa süreli Fourier dönüşümünden ayrılan bir zaman-frekans analizi metodudur. Sürekli dalgacık dönüşümü bir değişebilir pencere genişliği sağlar. Bu genişlik incelemenin ölçeğine bağlıdır. Yüksek frekanslı özelliklerin izolasyonuna izin veren bir esnekliğe sahiptir. Kısa süreli Fourier dönüşümünden bir başka önemli farkı, SDD sinüzoidal analizli fonksiyonların kullanılmasında sınırlı değildir. Sürekli bir zaman sinyalinin ($x(t)$) dalgacık dönüşümü, şu şekilde tanımlanabilir (Semmlov 2004):

$$T_{a,b}(x) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (3.20)$$

Burada $\psi^*(t)$, analiz edilen dalgacık fonksiyonu $\psi(t)$ 'nin kompleks eşleniğidir. a , dalgacığın ölçek parametresi ve b , dalgacığın konum parametresidir. Bir dalgacığı sınıflandırmak için, fonksiyonu aşağıdaki matematiksel kriterleri sağlamalıdır. Bu matematiksel kriterler şu şekilde sıralanabilir:

1. Fonksiyon sonlu bir enerjiye sahip olmalı

$$E = \int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad (3.21)$$

2. Eğer $\hat{\psi}(f)$, $\psi(t)$ 'nin Fourier transformu ise;

$$\hat{\psi}(f) = \int_{-\infty}^{\infty} \psi(t) e^{-i 2\pi f t} dt \quad (3.22)$$

olmalı ve aşağıdaki şart sağlanmalıdır.

$$C_g = \int_0^{\infty} \frac{|\hat{\psi}(f)|^2}{f} df < \infty \quad (3.23)$$

Bu şart sıfır frekans bileşenine sahip olmayan bir dalgacık belirler.

Daha doğrusu dalgacık sıfır ortalamalıdır ($\hat{\psi}(0) = 0$). (3.23) eşitliği makul

(kabul olunabilir) şart olarak, C_g ' de kabul edilebilirlik sabiti (admissibility) olarak adlandırılır. C_g ' nin değeri seçilen dalgacığa bağlıdır.

3. Kompleks (yada analitik) dalgacıklar için, Fourier dönüşümü hem reel olmalıdır hem de negatif frekanslar için sıfır olmalıdır.

Özel bir a ölçeğinde ve b konumunda sinyal enerjisine katkı, scalogram (spectrogram-kısa süreli Fourier dönüşümü için) olarak bilinen 2 boyutlu dalgacık enerji yoğunluk fonksiyonu ile verilir.

$$E_{a,b} = |T_{a,b}|^2 \quad (3.24)$$

Pratikte, sabit bir çarpım faktörü ile $|T_{a,b}|^2$, den ayrılan bütün fonksiyonlar scalogram olarak isimlendirilir ($|T_{a,b}|^2 / C_g$, $|T_{a,b}|^2 / C_g \cdot f_c$ vb., Burada f_c dalgacık fonksiyonunun karakteristik frekansıdır). Scalogramın C_g sabiti kullanılarak sinyaldeki toplam enerjiyi bulmak için a ve b ' ye göre integrali alınabilir.

$$E = \frac{1}{C_g} \int_{-\infty}^{\infty} \int_0^{\infty} |T_{a,b}|^2 \frac{da}{a^2} db, \quad \left[= \int_{-\infty}^{\infty} x(t)^2 dt \right] \quad (3.25)$$

Özel bir a ölçeğine sahip sinyalin içerdiği toplam enerji için göreceli katkı, ölçek bağımlı enerji dağılımı ile verilir.

$$E_a = \frac{1}{C_g} \int_{-\infty}^{\infty} |T_{a,b}|^2 db \quad (3.26)$$

Sinyalin Fourier enerji spektrumu ile doğrudan karşılaştırma yapmak için sinyal ölçek bağımlı dalgacık enerji spektrumunu (E_a ' yı), sinyalin frekans bağımlı dalgacık enerji spektrumuna ($E_w(f)$ ' ye) dönüştürebiliriz. Bunu yapmak için, dalgacık a ölçeğini karakteristik dalgacık frekansına dönüştürmemiz gerekir (Spektral tepe frekansı, geçiş band merkezi, merkez frekansı gibi). Spektral

bileşenler ölçekleme ile ters orantılıdır. Rasgele seçilmiş bir a ölçekli dalgacıkla birleştirilmiş bu frekans aşağıdaki eşitlik ile verilebilir.

$$f = f_c / a \quad (3.27)$$

Burada f_c , ana dalgacığın ($a = 1$ ölçeğinde, $b = 0$ konumunda) karakteristik frekansı f ' de keyfi bir a değeri için frekansı gösterir.

Sonuç olarak, Fourier dönüşümü ile, orijinal sinyal ters dönüşüm kullanılarak yeniden oluşturulabilir.

$$x(t) = \frac{1}{C_g} \int_{-\infty}^{\infty} \int_0^{\infty} T(a,b) \psi_{a,b}(t) \frac{da db}{a^2} \quad (3.28)$$

Pratikte, CWT' nin iyi diskritizasyonu (ayrıklaştırılması) genellikle b konumu örnekleme süresinde ayrıklaştırılarak ve a ölçeği logaritmik olarak ayrıklaştırılarak yapılır.

(3.20) eşitliği ile verilen dalgacık dönüşümü dalgacık fonksiyonlu sinyalin konvolüsyonunu gösterdiğine göre, integrali Fourier uzayında bir çarpım olarak ifade etmek için konvolüsyon teoremini kullanırız.

$$T(a,b) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \hat{x}(w) \hat{\psi}_{a,b}^*(w) dw \quad (3.29)$$

Burada

$$\hat{\psi}_{a,b}^*(w) = \sqrt{a} \hat{\psi}^*(aw) e^{jwb} \quad (3.30)$$

ifadesi a ölçeğinde b konumunda analiz edilen dalgacığın Fourier spektrumunu göstermektedir. Bu yolla, pratikte Hızlı Fourier Dönüşümü (Fast Fourier Transform-FFT) algoritması dalgacık dönüşümünün hesaplanmasını hızlandırmak için kullanılabilir.

3.2.2. Ayırık dalgacık dönüşümü

En yaygın şekilde, DWT a ve b olarak iki ölçekli bir güç sağlar. Gerçekte dönüşümün integrali DWT için süreklidir, fakat yalnız ayrıklaştırılmış a, b uzayında belirlenir. Çoklu çözünürlük (multiresolution) algoritması kullanılarak, dalgacık dönüşümü ve ters dönüşüm hızlı ve sinyal bilgisinde kayıp olmaksızın ayırık olarak hesaplanabilir. Bir tip dalgacık ayrıklaştırılması aşağıdaki şekildedir:

$$\psi_{m,n} t = \frac{1}{\sqrt{a_0^m}} \psi \left(\frac{t - n.b_0.a_0^m}{a_0^m} \right) \quad (3.31)$$

Burada m ve n sırasıyla dalgacık ölçeklemesini ve dönüşümünü kontrol eder. a_0 ölçekleme adım parametresidir, belirli bir sabittir ve değeri 1' den büyük olarak seçilmelidir. b_0 konum parametresidir, 0' dan büyük olmalıdır. Ayırık dalgacık parametreleri a_0 ve b_0 sırasıyla 2 ve 1 olarak seçilebilir. Hem ölçekleme ve hem de dönüşüm adımlarının yani iki logaritmik ölçeğin gücü diyadik (dyadic:sadece iki işleyeni olan bir işleç) bir ızgara düzeni olarak bilinir. Diyadik ızgara en basit ve verimli ayrıklaştırma biçimidir. (3.31) eşitliğinde $a_0 = 2$ ve $b_0 = 1$ yerine yazılırsa

$$\psi_{m,n} t = 2^{-m/2} \psi(2^{-m}t - n) \quad (3.32)$$

olur. (3.31) eşitliği ile verilen genel ayırık dalgacık ifadesi ile (3.32) eşitliği aynı notasyona sahiptir. Buradan, $\psi_{m,n} t$ sadece $a_0 = 2$ ve $b_0 = 1$ ile ölçeklenmiş diyadik ızgarayı göstermek için kullanılacaktır. Ayırık diyadik ızgara dalgacıkları genellikle ortonormal olmak için seçilir. Bu dalgacıklar aynı zamanda hem ortogonaldır hem de birim enerjiye sahip olması için normalize edilir. Bu aşağıdaki şekilde ifade edilir (Semmlov 2004):

$$\int_{-\infty}^{\infty} \psi_{m,n} t \psi_{m',n'} t dt = \begin{cases} 1 & \text{Eğer } m=m' \text{ ve } n=n' \\ 0 & \text{Diğer durumlarda} \end{cases} \quad (3.33)$$

Bu şu anlama gelir: Dalgacık dönüşümünden elde edilen $T_{m,n}$ dalgacık katsayısında depolanan bilgi başka yerde tekrar edilemez ve gereksizlik (fazlalık) olmaksızın orijinal sinyalin yeniden üretimini sağlar.

(3.33) eşitliğindeki diydik ızgara dalgacıđı kullanılarak ayrik dalgacık dönüşümü (DWT) yazılabilir:

$$T_{m,n} = \int_{-\infty}^{\infty} x(t) \psi_{m,n}(t) dt \quad (3.34)$$

Burada $T_{m,n}$, m, n konumlu ve ölçekli dalgacık katsayısı olarak bilinir.

Pratikte kullanılan CWT' nin ayrıklaştırılması ile DWT arasındaki temel fark konusunda açıklama getirmek gerekir. CWT' nin ayrıklaştırılması, a ve b ayrik uzayında hesaplanan dönüşüm integralinin (toplamının) ayrik bir yaklaşımını içerir. Ters sürekli dalgacık dönüşümü ayrik yaklaşım gibi hesaplanır. Orijinal sinyalin yeniden elde edilmesi kullanılan ayrıklaştırmanın çözünürlüğüne bağlıdır ve genellikle çok iyi bir yaklaşıklıkla yeniden elde edilebilir. Başka bir deyişle (4.34) eşitliğinde tanımlandığı gibi DWT için dönüşüm integrali sürekli kalır fakat yalnız a ve b parametreleri için belirlenir. Orijinal sinyale geri dönmek için, sonsuz m ve n üzerinde DWT katsayılarını toplayabiliriz.

Ortonormal diydik ayrik dalgacıklar “ölçekleme fonksiyonları” ve onların ölçekleme eşitlikleri ile çağrıştırılır. Ölçekleme fonksiyonu sinyalin yumuşatılması ile çağrışır ve dalgacık gibi aynı forma sahiptir.

$$\phi_{m,n}(t) = 2^{-m/2} \phi(2^{-m}t - n) \quad (3.35)$$

Bu dalgacıklar aşağıdaki eşitlik ile ifade edilen özelliklere sahiptirler:

$$\int_{-\infty}^{\infty} \phi_{0,0}(t) dt = 1 \quad (3.36)$$

Burada $\phi_{0,0}(t) = \phi(t)$ “baba dalgacık (father wavelet)” olarak isimlendirilir. Ölçekleme fonksiyonu yaklaşım katsayıları ile sinyalin çarpılarak konvolve edilebilir.

$$S_{m,n} = \int_{-\infty}^{\infty} x(t) \phi_{m,n}(t) dt \quad (3.37)$$

Yaklaşım (approximation) katsayıları sürekli sinyalin $2^{m/2}$ çarpanlı sürekli sinyalin ağırlıklandırılmış ortalamasıdır. Sabit m ölçeğinde yaklaşım katsayıları; sinyalin ayrik yaklaşımı olarak bilinir. m ölçeğinde sinyalin sürekli yaklaşımı bu ölçekte yaklaşım katsayısı ile çarpılan ölçekleme fonksiyonlarının dizisi toplanarak üretilebilir.

$$x_m(t) = \sum_{n=-\infty}^{\infty} S_{m,n} \phi_{m,n}(t) \quad (3.38)$$

Burada $x_m(t)$, ölçek indisi m 'de $x(t)$ sinyalinin ölçekleme bağımlı fonksiyonudur ve düzdür. Bu sürekli yaklaşım ile küçük ölçeklerde $m \rightarrow -\infty$ da $x(t)$ 'ye yaklaşır. $x(t)$ sinyali hem yaklaşım katsayıları hem de dalgacık detay katsayıları kullanarak kombine edilmiş (birleştirilmiş) bir seri açılımı ile gösterilebilir.

$$x(t) = \sum_{n=-\infty}^{\infty} S_{m_0,n} \phi_{m_0,n}(t) + \sum_{m=-\infty}^{m_0} \sum_{n=-\infty}^{\infty} T_{m,n} \psi_{m,n}(t) \quad (3.39)$$

Dalgacık sinyalinin detay katsayıları aşağıdaki şekilde tanımlanır:

$$d_m(t) = \sum_{n=-\infty}^{\infty} T_{m,n} \psi_{m,n}(t) \quad (3.40)$$

Buradan hareketle (3.38) eşitliğini şu şekilde yazabiliriz:

$$x(t) = x_{m_0}(t) + \sum_{m=-\infty}^{m_0} d_m(t) \quad (3.41)$$


Bu eşitlik kullanılarak aşağıdaki eşitliğin çıkarılması çok kolaydır:

$$x_{m-1}(t) = x_m(t) + d_m(t) \quad (3.42)$$

Bu gösterim “çoklu çözünürlük gösterimi (multiresolution representation)” olarak adlandırılır.

Buraya kadar teorisi formüllerle ifade edilmeye çalışılan ayrık dalgacık dönüşümünü pratikte Şekil 3.1' de görüldüğü gibi filtre bankaları kullanılarak gerçekleştirilir. Şekilden de görüleceği gibi $x(n)$ sinyalinin iki seviyeli dalgacık ayrıştırılması (decomposition) yapılmıştır. Ayrıştırılan sinyal özel tasarlanmış filtrelerle ve giriş sinyalinin konvolüsyonu (convolution) ve filtrelenmiş sinyalin aşağı örnekleme (downsampling) metodu ile örneklenmesi ile elde edilmiştir. Şekil

3.1’ de gösterildiği gibi bir yüksek geçiren filtre $g(\cdot)$ ve bir alçak geçiren filtre $h(\cdot)$ ile ayrıştırma prosesi gerçekleştirilir. “ $\downarrow 2$ ” sembolü filtrelenmiş sinyalin 2 ile aşağı örneklendiğini gösterir. D_1 detay (detail) ve A_1 yaklaştırma (approximation) parametreleri sırasıyla yüksek geçiren ve alçak geçiren filtre kullanılarak gerçekleştirilen ilk seviye ayrıştırma ve aşağı örnekleme prosedürlerinden sonraki sinyalleri gösterir. Birinci seviye ayrıklaştırmadan sonra A_1 yaklaştırma katsayısı aynı filtreler kullanılarak ikinci seviye için tekrar ayrıştırılır. Bu proses iki seviyeden daha fazla bir ayrıştırma istenirse aynı şekilde devam edebilir (Ceylan 2007, Güler 2005).



Şekil 3.1İki seviye ayrıştırmalı ayırık dalgacık dönüşümü

4. ELEKTROKARDİYOGRAFI

Kalp, birbirini izleyen safhalar boyunca hiç durmadan belirli bir elektriksel potansiyel üreten ve bu etkinliğin ardından kontraksiyon olarak adlandırılan mekanik işi yapan bir organdır. Bu nedenle kalbin bir elektromotor kuvvet kaynağı olduğundan söz edilebilir (Uçak 2005).

Miyokard, çok sayıda ince uzun hücreden oluşan bir dokudur. Yan uzantıların yardımı ile yer yer birleşen miyokard hücreleri, bir takım diskler aracılığı ile uç uca bağlanarak dizilirler. Hücrelerin içinde miyofibril adı verilen ve kontraksiyon işlevini üstlenen öğeler yer alırlar. Miyofibrillerin bir araya gelmesi ile kontraksiyon aygıtı olarak nitelendirilen birim oluşur. Hücreler, düşük dirençli diskler acılığı ile elektriksel dolayısı ile mekanik anlamlarda ilişki kurup süreklilik gösterdiklerinden kalbin işlevsel bir sinsityum olduğu söylenir.


Miyokardın kasılması için ön koşul, hücre membranının elektriksel anlamda uyarımı, öbür deyiş ile eksitasyonudur. Eksitasyonu kontraksiyonun izlemesi, eksitasyon-kontraksiyon eşlenmesi (excitation-contraction coupling) olarak adlandırılır. Eksitasyonu kontraksiyona dönüştüren ara etmen Ca iyonudur.

Dinlenme durumundaki miyokard hücresinde belirli bir uyarım tarafından başlatılan elektrokimyasal içerikli etkinliğe aksiyon potansiyeli ya da elektriksel sistol adı verilir. Aksiyon potansiyeli depolarizasyon ve repolarizasyon aşamalarından oluşur. Hücrenin repolarizasyonu izleyerek başlangıç durumundaki özelliklerine dönmesi ile dinlenme potansiyeli öbür adı ile elektriksel diyastol gelişir (Şekil 4.1).


Depolarizasyon sırasında, membran dinlenme potansiyelinin -90 mV düzeyinden -40 mV dolayına ulaşması ile açılan ve bu nedenle “depolarizasyon aracılığı ile işleyen kanal (depolarization-operated channel)” ya da “voltaj aracılığı ile işleyen kanal (voltage-operated channel)” olarak nitelendirilen özel geçitlerden hücreye giren Ca, öncelikle biriktiği “hücre içi Ca deposu” ndan salıverilerek, aktin ve miyozin arasındaki etkileşimi baskılayan tropomiyozinin bu işlevini ortadan kaldırıp kontraksiyonu başlatır (Şekil 4.2).

Kalbin depolarizasyon ve repolarizasyon süreçleri sırasında çevresinde oluşturduğu elektriksel potansiyel değişikliklerinin, bedeninin iletken bir ortam gibi davranmasından ötürü deyiş ile bir tür volümlü iletken olmasından yararlanılarak zamana karşı çizdirilmesine *elektrokardiyografi*, bu yöntemle elde edilen çiziyeye *elektrokardiyogram*, elektrokardiyografi sırasında kullanılan ve temelde değiştirilip geliştirilmiş bir galvanometre olan aygıta ise *elektrokardiyograf* denir. Elektrokardiyogram üzerinde, kalbin elektriksel potansiyeline ilişkin yön, genlik ve zaman içinde değışim gibi bilgiler yer alırlar (Uçak 2005).

Kalp tarafından oluşturulan ve beden yüzeyine iletilen elektriksel potansiyel değışikliklerinin elektrokardiyografa aktarılabilmesi için kollara, bacaklara ve göğüs duvar üzerindeki belirli noktalara yerleştirilen metal parçacıklara *elektrot* denir. Elektrotların belirli bir düzene uyularak ve iletken tellerden yararlanılarak elektrokardiyografin ucuna bağlanmaları ile *derivasyonlar* elde edilir. Vücutta iki nokta arasındaki potansiyel farkı ölçülecek biçimde oluşturulan çift elektrotlu bağlantılar *bipolar derivasyonlar*, vücut yüzeyinin belirli bir noktasındaki potansiyeli ölçmek için düzenlenen tek elektrotlu bağlantılar ise *unipolar derivasyonlar* olarak nitelendirilir (Uçak 2005).



Şekil 4.1. Miyokard hücresinin membran potansiyelinin belli başlı evreleri, membran potansiyelinin temel iyon devinimleri ile ilgisi. Şekil iyon pompası etkinliğine bağlı devinimleri içermemektedir



Şekil 4.2. Özetlenmiş “eksitasyon-kontraksiyon eşlenmesi”. HD=Hücre dışı, HI=Hücre içi.

4.1. Elektrokardiyografi Derivasyonları ve Derivasyon Ekseni Kavramı

Normal olan yada olmayan elektrokardiyogram örneklerinin açıklanıp kavranmaları için elektrokardiyografiye derivasyon ekseni ve kalp vektörü kavramları temel alınarak yaklaşılmalıdır. Başka bir deyişle, belirli bir derivasyon ekseni ile kalbin elektriksel etkinliğini yansıtan vektörler bilinirse, o derivasyon tarafından çizilmesi gereken elektrokardiyogram kolayca bulunabilir (Uçak 2005).


Günlük elektrokardiyografi uygulamaları sırasında kullanılan 12 derivasyon, *taraf derivasyonları* ve *göğüs derivasyonları* başlıkları altında iki ana kümeye ayrılırlar. Taraf derivasyonları ya bipolar ya da unipolar olarak düzenlenirler. Standart derivasyonlar adı ile de bilinen bipolar taraf derivasyonları, I, II ve III olarak gösterilirler. Unipolar taraf derivasyonları ise aVR, aVL ve aVF olarak belirtilirler. Bu adlandırmada “V”, potansiyel daha doğrusu voltaj sözcüğünün karşılığı olarak kullanılır. Buna karşılık “R” harfi ile sağ kol (right arm), “L” harfi ile sol kol (left arm), “F” harfi ile ise sol bacak (left leg) anlatılmak istenir.

Elektrotların yerleştirildikleri yere göre değişmek üzere, bipolar taraf derivasyonlarının bedeninin iki noktası arasındaki potansiyel farkını saptamalarına karşılık unipolar taraf derivasyonları ile göğüs derivasyonları belirli bir noktadaki potansiyeli gösterirler (Uçak 2005).

Temelde voltmetre gibi kullanılan bir galvanometre olan elektrokardiyografi aygıtının negatif ucuna bağlı elektrotun sağ kola, pozitif ucuna bağlı elektrotun ise sol kola yerleştirilmesi ile elde edilen bipolar taraf derivasyonu *derivasyon I* dir. Bu derivasyon, iki kol arasındaki potansiyel farkını yansıtır

Elektrokardiyografin negatif ucuna bağlı elektrotun sağ kola, pozitif ucuna bağlı elektrotun ise sol bacağına yerleştirilmesi ile sağ kol ile sol bacak arasındaki potansiyel farkı yani *derivasyon II* ölçülmüş olur.


Derivasyon III ün ölçülmesi için, elektrokardiyografin negatif ucuna bağlı elektrotun sol kola, pozitif ucuna bağlı elektrotun ise sol bacağına konması gereklidir. Derivasyon III, sol kol ile sol bacak arasındaki potansiyel farkını veren bir düzenlemedir (Şekil 4.3).



Şekil 4.3. Bipolar taraf derivasyonları. RA=sag kol, LA=sol kol, LF=sol bacak

Sağ kola, sol kola ve sol bacağına yerleştirilen elektrotlara bağlı teller birleştirilirse Wilson' un santral terminali olarak bilinen ortak bir uç elde edilmiş olur (Uçak 2005). Kapalı bir devreyi oluşturan üç yük arasındaki farkların sıfır olacağını

bildiren Kirchhoff yasasına göre, bir kalp siklusunun alınabilecek tüm noktalarında, sağ koldaki, sol koldaki ve sol bacadaki potansiyel değerlerinin toplamının sıfır olması gerektiğinden, santral terminalinin kalp siklusu boyunca sıfır potansiyel ölçmesi beklenir. Bu niteliği ile duyarsız bir ortak elektrot gibi davranan santral terminal, elektrokardiyografin negatif ucuna bağlanır. Aygıtın pozitif ucuna bağlı bir araştırıcı elektrot sırası ile sağ kola, sol kola ve sol bacağa yerleştirilerek gezdirilirse, VR, VL ve VF unipolar derivasyonları ölçülmüş olur (Şekil 4.4).




Şekil 4.4. Wilson' un unipolar taraf derivasyonları


Wilson tarafından önerilen bu bağlantılarda unipolar taraf derivasyonlarında elde edilen genlikler çok küçüktür. Bu sebepten Goldberger tarafından, ölçülen unipolar potansiyel genliklerini 1.5 kat artıran yeni bir düzenleme önerilmiştir. Goldberger' in güçlendirdiği unipolar taraf derivasyonları için gerekli bağlantı şemaları Şekil 4.5' de gösterilmiştir (Uçak 2005).

Wilson' ın önerdiği şekilde, santral terminal elektrokardiyografin negatif ucu ile birleştirilir ve aygıtın pozitif ucuna bağlı bir araştırıcı elektrot bu kez prekordiyumun belirli noktalarında gezdirilirse unipolar göğüs derivasyonları, bir başka deyişle unipolar prekordiyum derivasyonları elde edilir (Şekil 4.6). Araştırıcı

elektrotun Şekil 4.6’ da gösterildiği şekilde yerleştirilmesi ile unipolar göğüs derivasyonları elde edilmiş olur (Uçak 2005).




Şekil 4.5. Goldberger' in unipolar taraf derivasyonları



Şekil 4.6. Göğüs derivasyonları

Bipolar taraf derivasyonlarına ilişkin elektrot çiftlerini birleştiren kavramsal düz çizgilere *derivasyon eksen*i adı verilir. Derivasyon ekseninin, pozitif elektrotun yer aldığı ucu “pozitif”, negatif elektrotun yer aldığı ucu ise “negatif” olarak belirtilir. Eksenin pozitif ve negatif uçlara eş uzaklıkta olan ortası “sıfır” noktasıdır.


Derivasyon ekseninin, sıfır noktası ile pozitif uç arasında kalan kesimi “pozitif yarım”, sıfır noktası ile negatif uç arasında kalan kesimi ise “negatif yarım” olarak nitelendirilebilir. Derivasyon I, II ve III’ e ilişkin eksenler çizildiğinde, Einthoven’ ın adı ile bilinen bir üçgen elde edilir (Şekil 4.7). Tam doğru olmayan bir takım varsayımlara dayanılarak, frontal düzlemde yer alan bu üçgenin eşkenarlı olduğu, köşelere eş uzaklıkta olan merkezin sıfır noktasını gösterdiği, üçgenin merkezinde kalbin anatomik merkezinin yer aldığı, kalbin elektriksel merkezi ile anatomik merkezinin çakıştığı öngörülür (Uçak 2005).




Şekil 4.7. (a) Üç bipolar taraf derivasyonu eksenini tarafından oluşturulan Einthoven üçgeni, (b) Aralarında 60° lik açılar bulunan üç eksenli referans sisteminin gösterimi

4.2. Normal Elektrokardiyogram

Elektrokardiyogramda yer alan dalgaların süreleri ve genlikleri, elektrokardiyografi kağıdı üzerindeki dikey ve yatay çizgilerin aralıklarından yararlanılarak ölçülebilir. İki ince dikey çizgi arası 0.04 sn, iki kalın dikey çizgi arası 0.20 (0.04×5) sn, iki ince yatay çizgi arası 1 mm, iki kalın yatay çizgi arası ise 5 (1×5) mm’ dir (Şekil 4.8). Elektrokardiyogram dalgalarının genlikleri, 1 mV’ luk potansiyelin karşılığı 10 mm olacak biçimde düzenlenir (Uçak 2005).




Şekil 4.8. Elektrokardiyogramdaki dikey ve yatay aralıklara ilişkin değerler ile standartlaşmayı sağlayan 1 mV' luk test dalgası



Şekil 4.9. Normal elektrokardiyogram bileşiği

Günlük uygulamalarda geçerli olan elektrokardiyografi çekim hızı, öbür deyiş ile elektrokardiyografi kağıdının akma hızı 25 mm/sn' dir. Buna göre 1500 (25×60) mm' lik kağıt uzunluğu 1 dakikalık sürenin karşılığı sayılır. Elektrokardiograma bakıp kalp hızını saptamak için 1500' ü mm olarak RR aralığına bölme işleminin temelinde bu yatar.


Normal elektrokardiyogram *baseline* adı ile bilinen *taban çizgisi* üzerinde sıralanan ve P, Q, R, S, T, U adları verilen dalgalardan oluşur (Şekil 4.9, Şekil 4.10). Boyları 5 mm' den küçük Q, R, S dalgaları ve q, r, s gibi küçük harflerle belirtilir. Dalgaların arasında kalan kesimlere *bölüm*, dalgaların arasındaki uzaklıklara ise *aralık* denir.



Şekil 4.10. Elektrokardiyogramda yer alan dalgaların ve aralıkların kalbin elektriksel etkinliğine ilişkin karşılıkları

4.2.1. P dalgası


Atriyumların depolarizasyonunu yansıtan P dalgasının tepesi yuvarlak, sivri ya da çentikli olabilir. Tepecikler arasındaki uzaklık 0.03 sn' yi aşmadıkça çentiklenme normal bir görünümdür. Erişkinlerde P dalgasının genişliği en çok 0.10 sn olup genişliği 2.5 mm' den küçüktür. En büyük P dalgasına genellikle derivasyon I ve II de rastlanır. Sinüs ritimli kişilerde P dalgası, derivasyon I, II ve aVF de pozitif; aVR de negatif; aVL de pozitif ya da negatif ya da iki fazlı, V_1 de ise genellikle iki fazlı ya da negatiftir. P dalgasına ilişkin ölçümler sırasında göz önünde bulundurulması gereken noktalar Şekil 4.11' de gösterilmiştir (Uçak 2005).



Şekil 4.11. P ve T dalgalarına ilişkin ölçümlerde izlenecek yöntem

4.2.2. PR aralığı

Sinüs-atriyum düğümünden çıkan uyarının ventriküllere ulaşabilmesi için geçen sürenin karşılığı olan PR aralığı, P dalgasının başlangıcından Q dalgasının başlangıcına, Q dalgasının görülmediği durumlarda ise R dalgasının başlangıcına kadar olan uzaklık olarak ölçülür (Şekil 4.12). PR aralığı bipolar ya da unipolar taraf derivasyonlarında saptanarak en büyük değer alınır. Kalp hızının 70-90 vuruş/dak arasında olması koşulu ile PR aralığının erişkinlerdeki normal değeri 0.12-0.20 sn dir (Uçak 2005).




Şekil 4.12. PR aralığının ölçümünde izlenecek yöntem

4.2.3. QRS bileşiği

Ventrikül depolarizasyonu anlamına gelen QRS bileşiğinin belli başlı öğeleri, Q ile gösterilen negatif bir dalga, R olarak adlandırılan pozitif bir dalga ve S adı ile bilinen ikinci bir negatif dalgadır (Şekil 4.9). QRS bileşiğine ilişkin ölçümler ile bu örneğin değişik görünüşleri Şekil 4.13 ve Şekil 4.14’ de gösterilmiştir. PR aralığı örneğinde olduğu gibi QRS bileşiği de taraf derivasyonlarında ölçülür ve en büyük değer alınır (Uçak 2005).

Erişkinler için geçerli bir değer olarak QRS bileşiğinin süresi, normal kişilerde 0.10 sn yi aşmaz. Bununla birlikte, 0.10-0.12 sn arasında değişen QRS sürelerinin de normal olabileceği yeri geldiğinde anımsanmalıdır. QRS bileşiğine ilişkin en büyük dalganın taraf derivasyonlarında 5 mm’ den, göğüs derivasyonlarında ise 10 mm den küçük olduğu durumlarda düşük QRS genliğinden söz edilir.

Q dalgası, normal olarak derivasyon I ve II de 0.03 sn’ den dar, 2 mm’ den ve izleyen R dalgasının %25’ inden daha az derindir (Uçak 2005).




Şekil 4.13. QRS bileşiğini oluşturan değişik dalgalara ilişkin ölçümlerde izlenecek yöntem

4.2.4. ST bölümü

QRS bileşiğinin sonlandığı nokta ile T dalgasının başlangıcını birleştiren aralık ST bölümü olarak adlandırılır (Şekil 4.9). QRS bileşiği ile ST bölümü arasındaki kavşak J harfi ile gösterilir.

ST bölümü, genellikle taban çizgisi üzerinde uzanır. ST bölümünün yukarıya ya da aşağıya kayma derecesini değerlendirmek amacı ile önceki ya da sonraki TP bölümü referans çizgisi olarak kullanılır (Şekil 4.14). TP çizgisinin seçilemediği ya da taban çizgisi üzerinde yer almadığı durumlarda PR bölümü referans alınır.

ST bölümünün taraf derivasyonlarında 1.0 mm yukarıya ya da 0.5 mm aşağıya kayması normal bir bulgudur. ST bölümünün daha çok göğüs derivasyonlarında kimi olgularda ise taraf derivasyonlarında 2.0 ya da 3.0 mm yukarıya kayması normal olup erken repolarizasyon olarak adlandırılır. Bu durumda ST bölümü açıklığının yukarıya baktığı, izleyen T dalgasının pozitif, yüksek ve geniş tabanlı olduğu görülür (Uçak 2005).



Şekil 4.14. ST bölümüne ilişkin çökme ya da yükselme türünden kaymaların ölçümünde izlenecek yöntem

4.2.5. T dalgası

Ventrikül repolarizasyonunu yansıtan T dalgasının (Şekil 4.9) erişkinlerdeki normal süresi 0.10-0.25 sn' dir. Derivasyon I, II, $V_2 - V_6$ da pozitif, aVR' de genellikle negatif, aVL ve aVF de pozitif, yassı, iki fazlı ya da negatiftir. Otuz yaşın üzerindeki erişkinlerde, derivasyon V_1 de negatif olabilen T dalgası, otuz yaşın altındaki gençlerde V_2 ve V_3 ' te bile negatif görünebilir. T dalgasının genliğinin üst sınırı derivasyon II' de 8 mm' dir (Uçak 2005).

4.2.6. U dalgası

T dalgasını izleyen ve nasıl oluştuğu kesin olarak bilinmeyen bir dalgadır (Şekil 4.9). Normal kişilerde de görülebilir. Genliği kendisinden önceki T dalgasının genliğinin % 25' ini geçmez. T dalgasının pozitif olduğu derivasyonlarda U dalgası da pozitifdir. U dalgasının ters yönlü ya da önceki T dalgasından daha büyük genlikli olması normal bir bulgu değildir (Uçak 2005).

4.2.7. QT aralığı

Ventriküllerin depolarizasyon ve repolarizasyonu için geçen toplam süreyi yansıtan QT aralığı, QRS bileşiğinin başlangıcından T dalgasının bitimine kadar olan uzaklığı kapsar (Şekil 4.9). Kalp hızı 60-100 vuruş/dak arasında kalmak koşulu ile erişkinlerde 0.35-0.44 sn arasında değişen QT aralığı, kalp hızı ile olan bağımlılığı nedeni ile düzeltilerek bildirilir¹. Düzeltilmiş QT aralığının üst sınırı 0.43' tür (Uçak 2005).

4.3. Tez Çalışmasında Kullanılan Aritmiler


Gerçekleştirilen tez çalışmasında, MIT-BIH ECG Arrhythmia Database' de bulunan normal sinüs ritmi ve 11 aritmi kullanılarak 12 sınıflı bir veri oluşturulmuştur. Çalışma kapsamında önerilen sistemlerin doğrulaması bu verilerden oluşturulan eğitim ve test seti ile yapılmıştır.

4.3.1. Normal sinüs ritmi

Tez çalışmasında kullanılan normal sinüs ritmi sinyali için Şekil 4.15' de örnek bir çizim verilmiştir. Çalışmada kullanılan sinyaller MIT-BIH ECG Arrhythmia Database² 'den alınmıştır.

¹ Düzeltme işlemi Bazett eşitliğine göre yapılır (Uçak 2005).


² MIT-BIH ECG Arrhythmia Database' e ait veriler Physionet web sayfasından elde edilmiştir. www.physionet.org



Şekil 4.15. Normal sinüs ritmi (103 nolu kayıt)

4.3.2. Sinüs bradikardisi


Sinüs bradikardisi, SA düğümünden kaynaklanan ve dakikada 60 vurudan daha az kalp hızına sahip ritimler için kullanılan bir tanımlamadır. Elektrokardiyografik bulgular normal bir P dalgası, normal QRS konfigürasyonu ve normal bir PR aralığını içerir, ancak PP ve RR aralığının süresi 1.00 sn den fazladır (Silverman 1983). Tez çalışmasında kullanılan sinüs bradikardisi verisi MIT-BIH ECG Arrhythmia Database' de bulunan 202 nolu kayıttan alınmıştır (Şekil 4.16).



Şekil 4.16. Sinüs bradikardisi (202 nolu kayıt)

4.3.3. Ventriküler taşikardi


Ventriküler taşikardi çok ciddi aritmilerden biridir. Bu aritmide kalp hızı genellikle 130-250 vuru/dak arasında değişir. Literatürde farklılık göstermesi ile birlikte en az üç ventrikül vurumunun 100 vuru/ dak sınırını aşacak sıklıkta art arda gelmesi ile oluşan ritm olarak tanımlanır (Silverman 1983). QRS bileşikleri, 0.12 sn ya da daha geniş ve bozuk biçimdedir. Şekil 4.17' de tez çalışmasında kullanılan ve MIT-BIH ECG Arrhythmia Database' deki 200 nolu kayıttan alınan veriye ait çizim verilmiştir.



Şekil 4.17. Ventriküler taşikardi (200 nolu kayıt)

4.3.4. Sinüs aritmisi


Sinüs aritmisi genellikle çocuklukta görülen ve yaşın ilerlemesi ile kaybolma eğilimi gösteren bir aritmidir, fakat normal erişkinlerde de görülebilir. Sinüs aritmisinin karakteristikleri normal sinüs kalp pili gibidir, sırası ile yavaşlar ve artar (Silverman 1983). SA düğümünden kaynaklanan bu ritm de kalp siklusu uzunluğu en az 0.16 sn ya da %10 değişir (Uçak 2005). Şekil 4.18' de tez çalışmasında kullanılan ve MIT-BIH ECG Arrhythmia Database' deki 113 nolu kayıttan alınan veriye ait çizim verilmiştir.



Şekil 4.18. Sinüs aritmisi (113 nolu kayıt)

4.3.5. Atrial prematüre kasılması


Atriyumların SA düğümü dışında kalan kesimlerinden kaynaklanan ve temel ritimdeki siklus uzunluğuna göre erken beliren ektopik kontraksiyona atrial prematüre kasılması (atriyum erken vurumu) denir. Atriyum erken vurumu elektrokardiyogram da beklenen sinüs kökenli P dalgasından daha erken beliren ve P' olarak nitelendirilen ektopik bir dalga aracılığı ile tanılanır. Atriyum erken vurumuna ilişkin $P'R$ aralığı, sinüs kökenli PR aralığından daha kısa, daha uzun ya da onun kadar olabilir. Bununla birlikte $P'R$ aralığı genellikle 0.12-0.20 sn sınırları içinde yer alır (Uçak 2005). Şekil 4.19' de MIT-BIH ECG Arrhythmia Database 202 nolu kayıttan alınan atrial prematüre kasılması verisinin çizimi gösterilmiştir.



Şekil 4.19. Atrial prematüre kasılması (202 nolu kayıt)

4.3.6. Yapay vuru


Yapay vuruda P dalgası nadiren görülmektedir. PR aralığı ölçülemez, QRS kompleksi yapay vurudan sonra görülür ve genellikle 0.12 sn' den uzundur (Özbay 1999). Şekil 4.20' de görülen veriler MIT-BIH ECG Arrhythmia Database' deki 107 nolu kayıttan alınmıştır.



Şekil 4.20. Yapay vuru (107 nolu kayıt)

4.3.7. Sağ dal bloku


Sağ dal bloku, kalpte uyarı iletim bozukluğundan kaynaklanan bir aritmidir. Uyarı iletiminin sağ dalda gecikmesi ya da kesintiye uğraması sağ dal bloku (right bundle branch block) olarak adlandırılır (Uçak 2005). Dal bloklarını tanıtan elektrokardiyografik bulgular içerisinde en önemlisi, QRS bileşiğinin taraf derivasyonlarında 0.12 sn ya da daha geniş olmasıdır. Farklı derivasyonlar için farklı teşhisi vardır. Sağ dal bloku gerçekleştiğinde, sağ ventrikül depolarizasyonu en az 0.04 sn gecikir (Silverman 1983). MIT-BIH ECG Arrhythmia Database' deki 118 nolu kayıttan alınan sağ dal bloku verileri Şekil 4.21' de görülmektedir.



Şekil 4.21. Sağ dal bloku (118 nolu kayıt)

4.3.8. Sol dal bloku


Uyarı iletiminin sol dalda gecikmesine ya da kesintiye uğramasına sol dal bloku (left bundle branch block) denir. Sol dal bloku olgularında ventriküler depolarizasyonun normal düzeni bozulmuştur. Aynı sağ dal blokunda bahsedildiği gibi, sol dal blokunda da taraf derivasyonlarında QRS bileşiği 0.12 sn' den geniştir (Uçak 2005). MIT-BIH ECG Arrhythmia Database' deki 109 nolu kayıttan alınan sol dal bloku verileri Şekil 4.22' de görülmektedir.



Şekil 4.22. Sol dal bloku (109 nolu kayıt)

4.3.9. Atrial fibrilasyon


Atrial fibrilasyonu kalpte oluşturan mekanizma tam olarak bilinmemektedir. Bunun için birçok teori önerilmiştir, fakat hiçbiri kesin olarak kanıtlanamamıştır. Atrial fibrilasyonun sebepleri arasında koroner arteri rahatsızlığı ve mitral kapakçık (valve) sorunu vardır (Silverman 1983). Atriyum düzeyinde oluşan çok hızlı ve gelişigüzel depolarizasyonların düzensiz olarak ventriküllere iletildiği koşullarda atrial fibrilasyondan söz edilir (Uçak 2005). MIT-BIH ECG Arrhythmia Database’ deki 202 nolu kayıttan alınan atrial fibrilasyon verilerine ait çizim Şekil 4.23’ de görülmektedir.



Şekil 4.23. Atrial fibrilasyon (202 nolu kayıt)

4.3.10. Atrial flutter


Atrial flutter, sinüs taşikardi yada paroksimal atrial taşikardi gibi düzenli bir aritmi olarak kategorize edilir. Atrial fibrilasyonun olduğu gibi atrial flutterın da tam oluşma mekanizması tartışmalıdır. Atrial flutterda atrial hızı dakikada 250-300 vuru arasında değişir (Silverman 1983). Ayrıca bu aritmide normal P dalgalarının yerini alan ve F dalgası olarak isimlendirilen, araları düzenli, biçimleri ve büyüklükleri eş salınımlardan söz edilir. MIT-BIH ECG Arrhythmia Database’ deki 202 nolu kayıttan alınan atrial flutter verileri Şekil 4.24’ de görülmektedir.



Şekil 4.24. Atrial flutter (202 nolu kayıt)

4.3.11. Atrial couplet


Atriyumların SA düğümü dışında kalan kesimlerinden kaynaklanan ve temel ritimdeki siklus uzunluğuna göre erken beliren ektopik kontraksiyona atriyum erken vurumu denir. Art arda gelen iki atrium erken vurumunun birleşmesi ile atrial couplet (atrial çifti) oluşur (Silverman 1983). MIT-BIH ECG Arrhythmia Database’ deki 220 nolu kayıttan alınan atrial couplet verileri Şekil 4.25’ de görülmektedir.



Şekil 4.25. Atrial couplet (220 nolu kayıt)

4.3.12.Ventrikül trigeminy

Ventriküllerde yerleşik odaklardan kaynaklanan ve temel ritmdeki siklus uzunluğuna göre erken beliren ektopik kontraksiyona ventrikül erken vurumu denir. Ventrikül erken vurumlarının düzenli olarak her üç vurumdan birini oluşturmalarına ventrikül trigemini denir (Silverman 1983). MIT-BIH ECG Arrhythmia Database’deki 119 nolu kayıttan alınan ventrikül trigeminy verileri Şekil 4.26’de görülmektedir.



Şekil 4.26. Ventrikül trigeminy (119 nolu kayıt)


5. TELEKARDİYOLOJİ SİSTEMİ

Kalp tarafından oluşturulan ve beden yüzeyine iletilen elektriksel potansiyel değişiklikleri *elektrokardiyogram* denilen sinyalin elde edilmesini sağlar. Elektrokardiyogramda (EKG) yer alan dalgaların süreleri ve genlikleri kalbin fiziksel durumu hakkında bilgi verir (Acharya ve ark. 2002, Foo ve ark. 2002, Engin ve Demirağ 2003,). EKG aritmilerinin varlığı durumunda hastaya erken teşhis ve müdahalenin yapılması açısından literatürde telekardiyoloji uygulamaları (Tura 2003, Rodriquez ve ark. 2005, Dong ve Xu 2005) ve bu uygulamaları kolaylaştıran veri sıkıştırma metotlarının önerildiği çalışmalar (Chen 2004) hız kazanmıştır. Gerçekleştirilen tez çalışmasında, özellik çıkarma teknikleri ve yapay sinir ağları kullanılarak EKG işaretlerini hızlı ve yüksek doğrulukla tanıyan bir telekardiyoloji sistemi önerilmektedir. Önerilen telekardiyoloji sisteminin amacı, bir muayene ortamı yaratarak hastalara uzaktan sağlık hizmeti vermektir. Telekardiyoloji sisteminin iki tane ana hedefi vardır. Bu hedeflerden ilki, göğüs ağrısı, kolda uyuşma veya terleme gibi kalp rahatsızlığı şüphesi uyandırabilecek şikâyetler ile sağlık ocağına gelen bir hastanın telekardiyoloji sistemi vasıtasıyla kalp ile ilgili bir rahatsızlığı olup olmadığını belirlemektir. Bu maksatla önerilen sistemde, yapay sinir ağları ve farklı özellik çıkarma teknikleri kullanılarak gerçek-zamanlı EKG tanılama yazılımı gerçekleştirilmiştir. Böylece acil müdahale gerektiren kalp krizi gibi bir rahatsızlığın varlığı kolaylıkla erken teşhis edilebilecektir. Tez çalışmasında, ikinci hedef ise, gerekli görülmesi durumunda acil müdahale için bünyesinde uzman kardiyolog bulunduran başka bir yerdeki araştırma hastanesine hastanın yönlendirilmesidir.

Tez çalışmasında gerçekleştirilen telekardiyoloji sistemine ait blok gösterim Şekil 5.1’ de yer almaktadır. Şekil 5.1’ den de görüleceği gibi önerilen sistem incelenecek olursa; başlıca 3 bloğun birlikte çalışmasından oluştuğu görülebilir. Bu bloklar; sinyal kaydı ve işlenmesi bloğu, sinyal tanı bloğu ve haberleşme bloğu şeklinde isimlendirilebilir. Sinyal kaydı ve işlenmesi bloğu ile sinyal tanı bloğu sağlık ocağında gerçekleştirilmektedir. Elde edilen sonuçların gönderilmesi için

kullanılacak haberleşme bloğu ise hem sağlık ocağı hem de araştırma hastanesini kapsamaktadır.

Sinyal kaydı ve işlenmesi bloğu, hastanın kaydının yapılmasını sağlayan bir elektrokardiyograf, elektrokardiyografıtan alınan verilerin bilgisayara gerçek-zamanlı aktarımını sağlayan veri toplama kartı ve QRS dedeksiyon algoritmasından oluşmaktadır. Hastadan elektrokardiyograf ve veri toplama kartı vasıtasıyla alınan sinyaller üzerinde işlem yapılabilmesi için, öncelikle sinyalin tanı bloğu için anlamlı parçalara ayrılması gerekir. Bilindiği gibi elektrokardiyografi sinyalleri belirli bir periyoda sahip sinyallerdir. Fakat bu periyodun süresi kişiden kişiye değişebileceği gibi aynı kişiye ait aynı kayıta bile farklılık gösterebilir. Bu sebepten literatürde var olan QRS dedeksiyon algoritmaları ile uygulamalar gerçekleştirilmiş ve en az hata ile R tepelerini tespit eden algoritma seçilmiştir. Bir RR aralığı sistem için bir periyodu yani bir örüntüyü temsil eder. Kayıt edilen sinyaldeki RR aralığı sayısı, sistemin tanı kısmı için kullanılacak örüntü sayısına eşittir.



Şekil 5.1 Önerilen telekardiyoloji sistemi

Kayıt edilen EKG sinyalleri RR aralıklarına bölünerek, sinyal tanı bloğu için örüntülerden oluşan bir veri elde edilmiş olur. Bu veri, tanı bloğu için bir test verisidir. Veri üzerinde öncelikle özellik çıkarma teknikleri kullanılarak hem sinyal içerisinde sınıflandırmayı etkileyen gereksiz örneklerin atılması sağlanmış olur, hem

de sinyal sıkıştırılmış olur. Sıkıştırılmış sinyallerden, başka bir deyişle sinyali daha iyi karakterize eden örneklerden oluşmuş örüntü seti, tez çalışmasında gerçekleştirilen tip-2 bulanık kümeleme sinir ağı (T2BKSA) ile sınıflandırılır. Sinyal tanı bloğu, özellik çıkarma algoritmaları ve yapay sinir ağından oluşmaktadır. Sinyal tanı bloğundaki T2BKSA önceden 12 sınıf EKG verisi ile eğitilmiş bir ağıdır.

Sinyal tanı bloğu ile elde edilen sınıflandırma sonuçlarının araştırma hastanesine gönderilmesi ve uzman doktorun incelenmesine sunulması haberleşme bloğu ile gerçekleştirilmektedir. Haberleşme bloğu tez çalışmasında iki farklı şekilde gerçekleştirilmiştir. Her iki haberleşme türü için de sağlık ocağında ve araştırma hastanesinde doktorların kullanımını kolaylaştıracak arayüzler hazırlanmıştır. Haberleşme bloğu ilk olarak, sadece tez çalışmasında kullanılmak üzere hazırlanmış bir web sayfası (www.telekardioloji.com) ile gerçekleştirilmiştir. Ayrıca ikinci haberleşme seçeneği olarak ftp yolu ile haberleşme prosesi gerçekleştirilmiştir. Bu iki haberleşme türünden birini seçmek kullanıcı isteğine bağlıdır.

5.1. Sinyal Kaydı ve İşlenmesi Bloğu

Sinyal kaydı ve işlenmesi bloğu, hastanın EKG' sinin çekilmesi için bir elektrokardiyograf, elektrokardiyograftan alınan verilerin bilgisayara gerçek zamanlı olarak aktarılabilmesi için bir veri toplama kartı ve aktarılan verilerin tanı için uygun hale getirilmesini sağlayan sinyal işleme aşamasından oluşmaktadır. Sinyal kaydı ve işlenmesi bloğunu oluşturan her cihaz ve aşama ilerleyen bölümlerde detaylı olarak verilmiştir.

5.1.1. Elektrokardiyograf

Tez çalışmasında hastanın EKG' sinin çekilmesi için kullanılan elektrokardiyograf Şekil 5.2' de görülmektedir. Nihon Kohden firmasının ürettiği cihaz ECG-9022K modelidir. Cihaz Selçuk Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından desteklenen doktora tez projesi¹ kapsamında alınmıştır. ECG-9022K' nın özellikleri şu şekildedir:

¹Proje no: 07101021

- 220 Volt 50/60 Hz.' da yada içerisinde bulunan şarj edilebilir bataryası ile çalışmaktadır.
- Cihaz, 12 EKG (I, II, III, aVR, aVL, aVF, V1, V2, V3, V4, V5, V6) derivasyonunu gösterebilmektedir ve 6 kanal olarak kayıt etmektedir.
- Periyodik EKG kaydı ve 1 dakikalık ritim (II.Derivasyon) kaydı özelliği mevcuttur.
- Yüksek hızda 25mm/sn ve 50mm/sn, düşük hızda 12.5 mm/sn ve 10mm/sn olmak üzere kayıt yapabilmektedir.
- Cihazda, hastada çeşitli kas kasılmalarından meydana gelebilecek artifaktları engelleyici EMG filtresi bulunmaktadır. Bu filtre 25 ve 35 Hz olarak ayarlanabilmektedir.
- Cihazda, şehir şebeke cereyanından kaynaklanan parazitleri engellemek için AC filtre devresi bulunmaktadır. Bu filtre 50 ve 60 Hz olarak ayarlanabilmektedir.
- Cihazın ekranında 12 kanal EKG dalga formu, hasta bilgileri, kayıt şekli, işlem çeşidi, kalp atımı QRS işareti, hata mesajı, elektrot temassızlığı ve gürültü bilgileri yazılmalıdır.
- Cihaz periyodik olarak kayıt yapabilme özelliğine sahiptir. Kayıtın periyodu dakikada bir veya altmış dakikada bir olmak üzere ayarlanabilmektedir.
- Batarya ile çalışmada 40 hastanın ölçümü ve kaydı yapılabilmektedir. Boş batarya 6 saat içerisinde tam dolu hale gelmektedir.
- Cihazın kayıt kağıdına cinsiyet, yaş, tarih ve saat bilgileri kayıt edebilmektedir
- Cihaz RS 232C interface ve bir software ile PC 'ye bağlanabilmektedir. Ayrıca bir analog çıkış mevcuttur. Analog çıkıştan yalnızca II derivasyon alınabilmektedir



Şekil 5.2. Nihon Kohden ECG-9022K Cihazı

5.1.2. Veri toplama kartı

Tez çalışması kapsamında, elektrokardiyografin analog çıkışından alınan sinyallerin bilgisayara aktarılabilmesi ve üzerinde çalışılabilmesi için bir veri toplama kartına ihtiyaç duyulmuştur. Veri toplama kartı analog giriş sinyallerinin dijitalle çevrilip bilgisayara aktarılmasını sağlayan bir ara elemandır. Çok çeşitli tipte ve maliyette veri toplama kartları mevcuttur. Ancak çalışmada hem sinyal kayıt kısmını hem de sinyal tanı bloğunu oluşturan program kodları Matlab yazılım paketi kullanılarak yazıldığından, veri toplama kartı da Matlab uyumlu olarak seçilmelidir. *Agilent Technologies*, *Keithley*, *Measurement Computing* ve *National Instruments* firmalarına ait veri toplama sistemleri Matlab ile uyumlu çalışabilmektedir. Bu firmalara ait kartlar da incelenip, ihtiyaçları karşılayacak minimum özellikte ve maliyette olan *Measurement Computing* firması tarafından üretilen USB-1408FS (Şekil 5.3) veri toplama kartı seçilmiştir. USB-1408FS, bilgisayarın USB girişine kablo vasıtasıyla bağlanarak çalışan Matlab uyumlu bir karttır. Seçilen veri toplama kartı USB-1408FS, S.Ü. Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından desteklenen doktora tez projesi kapsamında alınmıştır.



Şekil 5.3 Veri toplama kartı

5.1.2.1. Analog giriş kanal sayısı

Elektrokardiyografin analog çıkışından alınan sinyaller II. derivasyon verileridir. Bu sinyaller analog olduğu için veri toplama kartının analog kanalına bağlanan bir konnektör vasıtasıyla aktarılır. Veri toplama kartının toprağı ile elektrokardiyografin analog çıkışından alınan toprak birleştirilmelidir. Tez çalışmasında seçilen USB-1408FS veri toplama kartı 8 kanal analog girişe sahiptir.


Bu 8 analog giriş, 4 diferansiyel giriş ya da 8 single-ended giriş şeklinde konfigüre edilerek kullanılabilir. Çalışmada bu analog girişlerden sadece biri kullanılmıştır.

5.1.2.2. Giriş aralığı ve polaritesi

Kartta analog girişlerin kullanılma moduna (diferansiyel ya da single-ended) bağlı olarak, izin verilen giriş aralığı ve polaritesi değişmektedir. Tez çalışmasında analog girişler single-ended olarak konfigüre edilmiştir. Bu durumda kartın analog giriş için uygun voltaj aralığı ± 10 V' dur.

5.1.2.3. Örnekleme hızı


Tez çalışmasında ölçülecek veri elektrokardiyografi sinyalleri olduğundan örnekleme hızının belirlenmesinde EKG sinyallerinin frekans aralığının incelenmesi gerekir. EKG sinyalleri 0.5-150 Hz arasında frekans bileşenlerine sahip sinyallerdir (Şekil 5.4). Nyquist kriterine uygun olarak, örnekleme hızının bunun en az iki katı olması gerekir. USB-1408FS veri toplama kartı saniyede 48000 örnek alabilme özelliğine sahiptir. Kanal başına maksimum örnekleme frekansı, en büyük örnekleme frekansının kanal sayısına oranıdır. Bunun yanında örnekleme hızı, kartın programlanması ile kullanıcı tarafından da belirlenebilmektedir.



Şekil 5.4 EKG sinyallerinin frekans bandı

Çalışmada, sistemi oluşturan sınıflandırma ve tanıma için önerilen yapay zeka algoritmasının eğitiminde MIT-BIH ECG Arrhythmia Database' den alınan sinyaller kullanılmıştır. Bu sinyaller 360 Hz' de kayıt edilmiş sinyallerdir. Veri toplama kartından alınan ve sisteme sınıflandırması için sunulan verinin de bu örnekleme hızında örneklenmiş olması gerekir. Bu nedenle tez çalışmasında kayıt edilen sinyallerin örnekleme hızı 360 Hz seçilmiştir.

Veri toplama kartlarında iki tip örnekleme işlemi gerçekleştirilmektedir. Bunlardan ilki, her giriş kanalı için ADC' nin (Analog Digital Converter) kullanıldığı ve çok hızlı uygulamalarda tercih edilen oldukça pahalı cihazlarda yapılan örnekleme türüdür. İkinci örnekleme tipi ise, giriş kanallarının bir multiplekser ile taranmasıdır. Seçilen veri toplama kartında kullanılan örnekleme tipi de ikinci tip örneklemedir ve Şekil 5.5' deki blok diyagramda görülmektedir.



Şekil 5.5 Tarama tipi örnekleme (USB-1408FS)

5.1.2.4. Kuantizasyon

Örneklenen analog sinyali bilgisayarın okuyabilmesi için, sinyalin voltaj değerlerinin ikili (binary) sayılara çevrilmesi gerekir. Bu çevirme işlemi sırasında voltaj değerlerinin önceden belirlenmiş sınırlı sayıdaki seviyeden en yakın olanına yuvarlanmasına kuantizasyon (quantitation) adı verilir. Kuantizasyon sırasında, analog dijital dönüştürücü analog sinyalleri gösteren eşit olarak ayrılmış sonlu değerleri kullanır. Bu farklı değerlerin sayısı, dönüştürme için kullanılan bitlerin

sayısı ile belirlenir. Birçok modern dönüştürücü 12 ya da 16 bit kullanır. Genel olarak, dönüştürücü analog sinyale en yakın dijital değeri seçer.

USB-1408FS veri toplama kartında A/D dönüştürücü analog verileri dijital çevirmede 13 bit kullanmaktadır (single ended modda). Bu durumda kuantalama sayısı $2^{13} = 8192$ olarak bulunur.


5.1.3. QRS dedeksiyonu

Veri kaydı bittikten sonra, veri toplama kartı ile aktarılan verilerin sinyal tanı bloğunda kullanılabilmesi için periyotlara ayrılması gerekir. Bilindiği gibi EKG sinyali düzenli periyotlara ayrılabilen bir sinyaldir. EKG sinyalinin periyotlara bölünmesi işlemi QRS dedeksiyonu olarak adlandırılır. QRS dedeksiyon algoritmalarıyla sinyalin doğru RR aralıklarına bölünebilmesi için öncelikle sinyal üzerinde bulunan gürültülerin filtrelenmesi (elektromiyografik girişim, 50 Hz güç hattı girişimi, elektronik devrelerden kaynaklanan gürültü, elektrot bağlantı gürültüsü) ve sinyaldeki baseline kaymalarının (solunum kaynaklı baseline kayması) düzeltilmesi gereklidir.


EKG sinyalinde karşılaşılabilecek belli başlı gürültüler şu şekilde sıralanabilir

1. *Güç hattı girişimi:* Güç hattı girişimi 50 Hz' lik pikler ile sinüs ve sinüs kombinasyonları olarak modellenen harmonikleri içerir. Bu tür bir girişim 50 Hz' lik Notch filtresi kullanılarak bastırılır.
2. *Elektrot bağlantı gürültüsü:* Elektrot ve deri arasındaki bağlantı kaybı ile oluşan geçici bir girişimdir. Sinyalde yüksek genlikli artifaktların oluşumuna neden olur. Elektrot bağlantısı kontrol edilerek giderilir.
3. *Hareket kaynaklı gürültü:* Elektrot bağlantı gürültüsünde olduğu gibi yüksek genlikli artifaktların oluşumundan gürültünün kaynağı anlaşılabilir.
4. *Kas kasılmaları:* Kas kasılmaları milivolt seviyesinde gerilim artifaktlarına neden olur.
5. *Solunum kaynaklı gürültüler:* Solunumdan kaynaklanan baseline kaymaları da gürültü olarak sinyalde görülebilir.
6. *Elektronik devre gürültüsü:* Enstrümantasyon yükseltecini oluşturan elektronik devreden kaynaklanan gürültü ise bir QRS algoritması ile düzeltilemez. Bu durumda cihazın onarılması ve kalibre edilmesi gerekir.

Çalışmada, baseline kaymalarını gidermek için bütün sinyallerin üzerinde öncelikle “ortalama atma” işlemi gerçekleştirilmiştir. Gürültülerin eliminasyonu için ise, sinyaller 30 Hz’ lik bir alçak geçiren filtreden ve 0.09 Hz’ lik bir yüksek geçiren filtreden geçirilmiştir (Şekil 5.6).



(a)



(b)

Şekil 5.6 (a) 0.09 Hz kesim frekansına sahip yüksek geçiren filtre karakteristiği,
(b) 30 Hz kesim frekansına sahip alçak geçiren filtre karakteristiği

Filtrelenerek gürültü eliminasyonu sağlanmış olan sinyaller, QRS dedeksiyon algoritması ile RR aralıklarına ayrılabilir. Literatürde çok sayıda QRS dedeksiyon algoritması vardır. Bu algoritmalar genel olarak incelendiğinde 3 ana sınıf altında toplanır. Birinci sınıf QRS dedeksiyon algoritmaları, istatistiksel metotlara ve bu metotların geliştirilmesine dayanır (Friesen ve ark. 1990). İkinci sınıf QRS

dedeksiyon algoritmaları Hilbert transformu, dalgacık dönüşümü gibi zaman ve frekans spektrumunda yapılan incelemelere dayanır (Yimman ve ark. 2004, M.Szilagyi ve L. Szilagyi 2000, Benitez ve ark. 2001, Benitez ve ark. 2000, HC Chen ve SW Chen 2003, Nowak ve ark. 2006). Üçüncü sınıf QRS dedeksiyon algoritmalarını ise son yıllarda oldukça kullanılan yapay sinir ağları ve bulanık mantık gibi yapay zeka sistemleri oluşturmaktadır (Xue ve ark. 1992, Reaz ve Wei 2004).

Tez çalışmasında, QRS dedeksiyon işlemi istatistiksel metotlarla yapılmıştır. Literatürde kullanılan ve istatistiksel metotlara dayanan algoritmalar 4 ana başlık altında toplanır:

- Genlik ve birinci türev tabanlı QRS dedeksiyon algoritmaları
- Yalnızca birinci türev tabanlı QRS dedeksiyon algoritmaları
- Birinci ve ikinci türev tabanlı QRS dedeksiyon algoritmaları
- Dijital filtre tabanlı QRS dedeksiyon algoritmaları

Tez çalışmasında normal sinüs ritmi ve 11 aritmi sınıfı olmak üzere toplam 12 elektrokardiyografi veri sınıfı üzerinde çalışılmıştır. Bu veri sınıflarının hepsinde doğru şekilde QRS dedeksiyonu yapabilen algoritmaya ulaşılmaya çalışılmıştır. Bu amaçla, ilk olarak yalnızca birinci türev tabanlı algoritmalar grubuna dahil olan ve Menard tarafından geliştirilen bir algoritma ile QRS dedeksiyonu yapılmıştır. Karşılaştırma açısından dedeksiyon işlemi aynı veri sınıfları için birinci ve ikinci türev tabanlı bir algoritma olan Ahlstrom ve Tompkins (A&T) tarafından geliştirilen algoritma ile de gerçekleştirilmiştir. Gerçekleştirilen çalışmalar sonucunda, QRS dedeksiyonunda, A&T algoritmasının daha başarılı olduğu görülmüştür. Tez çalışmasında kullanılan QRS dedeksiyonu algoritmaları ve her aritmi için detaylı sonuçları 6. bölümde sunulmuştur.

5.2. Sinyal Tanı Bloğu

Tez çalışmasında önerilen telekardiyoloji sisteminin ikinci önemli aşamasını oluşturan sinyal tanı bloğu, özellik çıkarma algoritması ve tip-2 bulanık kümeleme

sinir ağından oluşmaktadır. Sinyal tanı bloğunun gerçekleştirilmesi için çalışma kapsamında 3 farklı kaskat ağ yapısı önerilmiştir.

İlk yapı tip-2 bulanık c-ortalamlar kümeleme algoritmasından ve yapay sinir ağından oluşmuş kaskat bir yapıdır. Bu yapı da tip-2 bulanık c-ortalamlar kümeleme algoritması, sınıfları en iyi karakterize eden örüntülerin seçilerek eğitim setinin yeniden oluşturulmasını sağlar. Elde edilen yeni eğitim verisi ile önerilen kaskat yapının ikinci kısmını oluşturan yapay sinir ağı eğitilmektedir. Test aşamasında, test verisi tip-2 bulanık c-ortalamlar kümeleme algoritması ile kümelenemeden, doğrudan eğitilmiş sinir ağında sınıflandırılmaktadır.

Çalışmada önerilen ikinci ve üçüncü ağ yapıları, birinci yapıya özellik çıkarma bloğu da eklenerek gerçekleştirilmiş yapılardır. Her iki yapıda da tip-2 bulanık c-ortalamlar kümeleme algoritması ile en iyi örüntüler seçilerek yeni bir eğitim verisi oluşturulur. Eğitim verisindeki örüntülerin örnek sayılarının azaltılması özellikle sinir ağının hem eğitim hem de test süresini kısalttığı için çok önemlidir. Örüntülerin örnek sayılarının azaltılmasında kullanılan özellik çıkarma algoritmaları ikinci yapı için dalgacık analizi, üçüncü yapı için temel bileşen analizidir. Özellik çıkarma işlemi sonrasında elde edilen örüntüler sinir ağında sınıflandırılır. Test aşamasında, test verisinde de öncelikle özellik çıkarma işlemi uygulanır, sonra veri ağında sınıflandırılır. Veri toplama kartından alınan veriler sinyal tanı bloğu için test verisidir. Sinyal tanı bloğu ve bu bloğu oluşturmak için tez çalışmasında gerçekleştirilen algoritmalar 6. bölümde detaylı olarak incelenecektir.

Önerilen bu üç yapıya ait kodlar MATLAB yazılım paketi kullanılarak hazırlanmıştır. Lisanslı MATLAB yazılım paketi ve tez çalışması için gerekli araç kutuları, Selçuk Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından desteklenen doktora tez projesi kapsamında alınmıştır.


5.3.Haberleşme Bloğu

Sinyal tanı bloğu ile elde edilen sınıflandırma sonuçlarının araştırma hastanesine gönderilmesi ve uzman doktorun incelenmesine sunulması haberleşme bloğu ile sağlanmaktadır. Haberleşme bloğu tez çalışmasında iki farklı şekilde gerçekleştirilmiştir. Her iki haberleşme türü için de sağlık ocağında ve araştırma


hastanesinde doktorların kullanımını kolaylaştıracak arayüzler hazırlanmıştır. Haberleşme bloğu ilk olarak, sadece tez çalışmasında kullanılmak üzere hazırlanmış bir web sayfası (www.telekardiyoloji.com) ile gerçekleştirilmiştir. Aynı zamanda ikinci seçenek olarak bir ftp hesabı ile gerçekleştirilmiştir. Bu iki haberleşme türünden birini seçmek kullanıcı isteğine bağlıdır.

5.3.1. Web sayfası kullanılarak hazırlanan haberleşme bloğu

Tez çalışmasında araştırma hastanesi ve sağlık ocağı arasındaki iletişim ilk olarak bir web sayfası üzerinden sağlanmıştır. Bu web sayfasına www.telekardiyoloji.com adresinden ulaşılabilmektedir. Hazırlanan siteye ait site haritası Şekil 5.7’ de verilmiştir. Web sayfasının ilk görünüşü Şekil 5.8’ deki gibidir. Araştırma hastanesi ve sağlık ocağı girişi şekilde görüldüğü gibi ayrıdır. Aynı zamanda bu girişler şifre ile sağlandığından herhangi bir güvenlik sorunu yoktur. Kullanıcı araştırma hastanesini seçtiği zaman Şekil 5.9’ da görülen ekran gelir.




Şekil 5.7 Site Haritası - www.telekardiyoloji.com




Şekil 5.8 www.telekardiyoloji.com – ilk sayfa görüntüsü

Şekil 5.9’ da görülen ekranda “Giriş için tıklayınız” yazılı linke girildiğinde hem sağlık ocağı hem de araştırma hastanesi için ortak olan ve Şekil 5.10’ da görülen ekran çıkar. Bu ortak iletişim sayfasında görüldüğü gibi kullanıcının iletileri görebilmesi için öncelikle sayfaya kişiye özel “kullanıcı adı ve şifresi” ile giriş yapması gerekmektedir. Araştırma hastanesi için “doktor1”, “doktor2” ve “doktor3” olmak üzere 3 kullanıcı belirlenmiştir. Kullanıcı sayısı istenirse genişletilebilir.




Şekil 5.9 Araştırma hastanesi giriş sayfası




Şekil 5.10 Ortak iletişim sayfası

Şekil 5.10’ da gösterilen sayfada uzman doktor kullanıcı adını ve şifresini girerek oturum açtığında Şekil 5.11’ de görülen sayfa açılır. Bu sayfada görüldüğü gibi bütün sağlık ocakları sıralanmıştır. Herhangi bir sağlık ocağından mesaj geldiğinde, şekildeki ekrandan da görüleceği gibi o sağlık ocağının isminin yanındaki belirteç kırmızı rengini almaktadır. Kimin tarafından gönderildiği ve saati gibi mesaja ait detaylarda aynı satırda verilmektedir.




Şekil 5.11 Araştırma hastanesinden görülen sağlık ocakları mesaj sayfası

Ayrıca Şekil 5.8’ de verilen ana sayfadan “Sağlık Ocakları” kısmına girilirse Şekil 5.12’ de gösterilen sayfa açılır. Bu sayfada “Giriş için tıklayınız” yazılı linke girilirse Şekil 5.10’ da verilen ortak iletişim sayfası açılır.



Şekil 5.12 Sağlık ocakları giriş sayfası

Bu sayfada aynı şekilde kullanıcı adı ve şifre girilerek her sağlık ocağı kendi mesaj sayfasına geçebilir. Çalışmada web sayfasına kayıtlı 1 araştırma hastanesi ve 3 sağlık ocağı varsayılmıştır. Araştırma hastanesi için 3 uzman doktor kaydı yapılmıştır. Aynı şekilde sağlık ocaklarının her biri için 2 pratisyen hekim kaydı yapılmıştır. Sağlık ocaklarının isimleri kolaylık olması açısından 1. Sağlık Ocağı, 2. Sağlık Ocağı ve 3. Sağlık Ocağı olarak verilmiştir. Pratisyen hekimler, 1. Sağlık Ocağı için “phekim1”, “phekim2”, 2. Sağlık Ocağı için “phekim3”, “phekim4”, 3. Sağlık Ocağı için ise “phekim5”, “phekim6” olarak isimlendirilmiştir. Şekil 5.13’ de phekim1 isimli kullanıcı yani 1. Sağlık Ocağı’ na kayıtlı pratisyen hekimlerden biri oturum açtığı zaman gelen ekran görülmektedir. Görüldüğü gibi sadece bağlı olduğu sağlık ocağının sayfasına ait mesajları görebilmektedir. Bu durum diğer kayıtlı hekimler için de söz konusudur.



Şekil 5.13 1. Sağlık Ocağı mesaj sayfası

Web sayfasının kullanımından önce sağlık ocağına gelen hastanın EKG' si çekilir. Bu EKG sinyalinin pratisyen hekim tarafından incelenebilmesi için bir arayüz tasarlanmıştır. Kullanıcı arayüzleri geliştirilirken Matlab' ın *GUI (Graphical User Interface) Toolbox* sihirbazından yararlanılmıştır. Bu gereç vasıtasıyla, ekranda bulunması istenen kullanıcıdan alınacak komutların butonları, grafikler ve analiz sonuçları pencerelerinin büyüklükleri ve konumları vb. özellikleri kolay şekilde belirlenebilmektedir. Hazırlanan taslak sayfası kaydedildiğinde, belirlenen elemanlar *.figure* uzantılı dosyaya nesneler olarak kaydedilmektedir. Belirlenen elemanların özellikleri GUI tarafından oluşturulan “.m” uzantılı bir dosyaya da kayıt edilmektedir. GUI kullanarak hazırlanan kullanıcı arayüzü Şekil 5.14’ de sunulmuştur.




Şekil 5.14 Sağlık ocağı arayüzü - web sayfası ile haberleşme

Şekil 5.14’ de görüldüğü gibi, arayüzde “kayıt” butonu ile veri toplama kartından veriler alınmaya başlanır ve alınan veriler ekrana çizdirilir. “Sınıflandır” butonuna basıldığında sınıflandırma sisteminin test hatası hesaplanır ve sınıflandırma sonucu sinyalde dedekte edilen aritmi sınıfları tespit edilir. Sinyalde tespit edilen aritmilerin sınıflara göre dağılımı ekrana yazdırılır. Kullanıcı her aritmi sınıfı için sinyalde tespit edilen vuru sayısını ekranda görebilir. Ayrıca yaş, cinsiyet, şikayet gibi hasta bilgileri de arayüz üzerinde girilerek kayıt edilebilir.

Web sayfası ile haberleşme sağlanırken araştırma hastanesinde uzman doktorun sinyali incelemek istediği zaman kullanacağı arayüz Şekil 5.15’ de görüldüğü gibi hazırlanmıştır. Şekilden de görüldüğü gibi kullanıcı “EKG” butonuna basarak ftp yoluyla aldığı sinyali çizdirebilir. Bu sinyalin incelenmek istenilen zaman aralığı “minimum” ve “maksimum” bölümlerine girilerek çizdirilebilir. Şekil 5.15’

de görüldüğü gibi sinyalin 40-50 sn arası çizdirilmiştir. “Program Sonucu” butonuna basıldığı zaman sınıflandırma sonucu ve sağlık ocağı tarafından girilen bilgiler aktarılır.




Şekil 5.15 Araştırma hastanesi arayüzü - web sayfası ile haberleşme

5.3.2. Ftp kullanılarak hazırlanan haberleşme bloğu

Tez çalışmasında ftp.telekardiyoloji.com adresinden sağlanan ftp hesabı ile gönderilmek istenen veriler araştırma hastanesine iletilmektedir. Aynı zamanda hazırlanan arayüzler sayesinde ftp yolu ile sağlık ocağı ve araştırma hastanesi karşılıklı görüş alışverişinde bulunabilmektedir. Burada da kullanıcı arayüzleri geliştirilirken Matlab’ ın GUI (Graphical User Interface) Toolbox sihirbazından yararlanılmıştır.

Şekil 5.16’ de ftp kullanılarak gerçekleştirilen haberleşme bloğunun da dahil olduğu ve sağlık ocağı için hazırlanan arayüz görülmektedir. Şekilden de görüleceği gibi elektrokardiyograftan alınan veriler “Kayıt” butonuna basılarak gerçek zamanlı

olarak bilgisayara aktarılmaktadır. “Sınıflandır” butonuna basıldığında tez çalışmasında önerilen tip-2 bulanık kümeleme dalgacık sinir ağı ile sınıflandırma gerçekleştirilir. Arayüzde yaş, cinsiyet ve şikayet gibi hasta bilgileri girilerek, kayıt edilebilmektedir. Aynı zamanda bu bilgiler araştırma hastanesine de gönderilebilmektedir. Haberleşme kısmında sağlık ocağı için ayrılan bölüme iletmek istenen başka yorum ya da mesaj varsa yazılarak gönderilebilir. Ayrıca araştırma hastanesinden gönderilen herhangi bir mesaj da “Mesaj al” butonuna basılarak alınabilir.



Şekil 5.16 Sağlık ocağı arayüzü - ftp ile haberleşme

Şekil 5.17’ de ftp haberleşmesinin kullanılması durumunda araştırma hastanesi için hazırlanan arayüz görülmektedir. Arayüz incelenecek olursa web sayfası haberleşmesi için hazırlanan arayüzden tek farkının karşılıklı mesajlaşmayı sağlayacak haberleşme bloğudur. Hazırlanan arayüzde “EKG” butonuna basıldığı zaman sağlık ocağında yapılan EKG kaydı kullanılan ftp adresinden alınır. “Sinyali çizdir” butonuna basıldığında kullanıcı tarafından girilen minimum-maksimum örnek aralığında sinyal çizdirilebilmektedir. “Program Sonucu” butonu kullanılarak, hastanın şikayeti, yaşı ve cinsiyeti gibi bilgilerle sınıflandırma sonucu da ekranda görülmektedir. Aynı zamanda haberleşme bloğunda araştırma hastanesi için ayrılan bölüme incelemeyi yapan uzman doktor yorumunu yazarak, “Mesaj gönder” butonunu kullanarak sağlık ocağına gönderebilir. “Mesaj al” butonunu kullanarak sağlık ocağından gönderilen mesajı alabilir.



Şekil 5.17 Araştırma hastanesi arayüzü – ftp ile haberleşme

6. QRS DEDEKSİYON ALGORİTMALARI VE ELDE EDİLEN SONUÇLAR

6.1. Menard' ın birinci türev tabanlı QRS dedeksiyon algoritması

Bu algoritmada EKG sinyalini oluşturan her örneğin birinci türevi aşağıdaki formülle hesaplanır (Sinyal uzunluğu N olarak alınmıştır) (Friesen ve ark. 1990).

$$Y[n] = -2X_{n-2} - X_{n-1} + X_{n+1} + 2X_{n+2} \quad 2 < n < N-2 \quad (6.1)$$

QRS dedeksiyonun yapılması için birinci türev kullanılarak eğim eşiği hesaplanır. Sinyale ait eğim eşiğinin belirlenmesinde aşağıdaki formül kullanılır.

$$\text{Eğim eşiği} = 0.7 \times \max[Y_n] \quad 2 < n < N-2 \quad (6.2)$$

Eğim eşiğini aşan yani $Y_n > \text{eğim eşiği}$ ifadesini sağlayan ilk nokta ilk R tepesi olarak alınır (Friesen ve ark. 1990).

Çalışmada eğim eşiğinin katsayısı, bütün veri sınıfları için, “0.6” alınarak simülasyonlar gerçekleştirilmiştir.

6.2. Ahlstrom ve Tompkins' in birinci ve ikinci türev tabanlı QRS dedeksiyon algoritması

Bu algoritmada EKG sinyalini oluşturan her örneğin birinci türevi (6.3) eşitliğine göre hesaplanır (N =Sinyal uzunluğu) (Friesen ve ark. 1990).

$$Y0_n = \text{ABS}[X_{n+1} - X_{n-1}] \quad 3 < n < N-1 \quad (6.3)$$

(6.3) eşitliği kullanılarak birinci türev denkleminde elde edilen değerler aşağıdaki gibi yeniden düzenlenir.

$$Y1_n = [Y0_{n-1} + 2Y0_n + Y0_{n+1}] / 4 \quad 3 < n < N-1 \quad (6.4)$$

QRS dedeksiyonu yapılacak sinyal için, düzenlenmiş ikinci türev ise (6.5) eşitliğindeki gibi hesaplanır.

$$Y2 \ n = ABS \left[X \ n+2 - 2X \ n + X \ n-2 \right] \quad 3 < n < N-1 \quad (6.5)$$

İkinci türev ve birinci türev vektörleri (6.6) eşitliğindeki gibi toplanır.

$$Y3 \ n = Y1 \ n + Y2 \ n \quad 3 < n < N-1 \quad (6.6)$$

$Y3 \ n$ dizisinin maksimum değeri kullanılarak birincil ve ikincil olmak üzere iki eşik belirlenir.

$$\begin{aligned} \text{Birincil eşik} &= 0.8 \times \max[Y3 \ n] \quad 3 < n < N-1 \\ \text{İkincil eşik} &= 0.1 \times \max[Y3 \ n] \quad 3 < n < N-1 \end{aligned} \quad (6.7)$$

Bir örnek noktasının QRS adayı olarak tanımlanabilmesi için (6.8) eşitliği ile verilen iki şartı sağlaması gerekir (Friesen ve ark. 1990).

$$\begin{aligned} Y3 \ i &> \text{Birincil eşik} \\ Y3 \ i+1, Y3 \ i+2, \dots, Y3 \ i+6 &> \text{İkincil eşik} \end{aligned} \quad (6.8)$$

Çalışmada birincil eşiğin katsayısı, çalışmadaki sinyal kayıtları için, “0.4” alınarak simülasyonlar gerçekleştirilmiştir.


6.3. QRS Dedeksiyon Algoritmaları ile Elde Edilen Sonuçlar

Menard’ın birinci türev tabanlı QRS dedeksiyon algoritması ve Ahlstrom ve Tompkins’ in birinci ve ikinci türev tabanlı QRS dedeksiyon algoritması kullanılarak 12 aritmi sınıfı üzerinde QRS dedeksiyonu yapılmıştır. Algoritmaların doğruluğunun karşılaştırılması açısından, her aritmi sınıfı için dedeksiyon sonucu elde edilen R tepesi örnek noktalarının ilk 5’ i tablolarda verilmiştir.


6.3.1. Normal sinüs ritmi ile elde edilen QRS dedeksiyon sonuçları

Normal sinüs ritmi için ham EKG sinyali Şekil 6.1(a)' da görülmektedir. Ham EKG sinyali incelenecek olursa üzerinde yüksek frekans gürültülerinin olduğu görülebilir. Sinyalin filtrelendikten sonraki normalize hali Şekil 6.1(b)' de verilmiştir. Filtrelenmiş sinyal şekil olarak ham sinyalden farklı değildir. Sadece filtrelenmiş sinyalde QRS dedeksiyonunu etkileyecek gürültüler olabildiğince elimine edilmeye çalışılmıştır. Filtrelenmiş normal sinüs sinyali üzerinde QRS dedeksiyonu yapılmıştır ve R tepelerinin bulunduğu örnek noktaları kaydedilmiştir. Sinyal boyunca iki R tepesi arasındaki örnek sayısı incelenecek olursa aynı kişiye ait kayıtlarda bile farklılık gösterdiği görülebilir. QRS dedeksiyon algoritması tarafından bulunan R tepesi örnek noktası bilgileri ve Matlab' da bulunan “resample” komutu kullanılarak her RR aralığındaki örnek sayısı 200 örneğe eşitlenmiştir. 200 örneklik RR aralığına sahip normal sinüs ritmi Şekil 6.1(c)' de görülmüştür. Şekil 6.1(b)' de normalize edilmiş ve filtrelenmiş normal sinüs ritminin ilk 5 R tepesinin bulunduğu örnek noktaları Şekil 6.1(d)' de verilmiştir.


Çizelge 6.1' de normal sinüs ritmi için QRS dedeksiyon algoritmaları ile elde edilen sonuçlar verilmiştir. Çizelgeden de görüleceği gibi her iki algoritma ile de normal sinüs ritminde R tepesi örnek noktaları doğru olarak elde edilmiştir.



(a) Original EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG

(d) R Tepelerinin bulunduğu noktalar


Şekil 6.1 Normal sinüs ritmine ait filtreleme ve QRS dedeksiyon sonuçları

Çizelge 6.1 Normal sinüs ritmine ait QRS dedeksiyon algoritması sonuçları


		R1	R2	R3	R4	R5
Normal Sinüs Ritmi	R Tepesi	209	482	758	1043	1322
	Menard	209	482	758	1043	1322
	A&T	209	482	758	1043	1322

6.3.2. Sinüs bradikardisi ile elde edilen QRS dedeksiyon sonuçları


Sinüs bradikardisi için kayıttan alınmış ve işlenmemiş ham sinyalin çizimi Şekil 6.2(a)' da verilmiştir. Şekilden de görüleceği gibi sinyal üzerinde gürültü mevcuttur. Bu gürültünün elimine edilebilmesi için sinyal filtrelenir ve normalize edilir. Normalize edilmiş ve filtrelenmiş sinüs bradikardisi sinyali Şekil 6.2(b)' de görülmektedir. Normalize edilen ve filtrelenen EKG sinyalinin R tepeleri QRS dedeksiyon algoritmaları ile tespit edilir ve her iki R tepesi arası yeniden örneklenerek 200 örneğe eşitlenir. Eşit RR aralıklarına sahip yeni sinüs bradikardisi Şekil 6.2(c)' de verilmiştir. Şekil 6.2(b)' de verilen sinyal için bulunan ilk 5 R tepesi örnek noktası Şekil 6.2(d)' de çizilmiştir. QRS dedeksiyonu algoritmaları ile elde edilen sonuçlar Çizelge 6.2' de verilmiştir. Her iki algoritma ile de tatmin edici sonuçlar elde edilmiştir.




(a) Orijinal EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG



(d) R Tepelerinin bulunduğu noktalar

Şekil 6.2 Sinüs bradikardisine ait filtreleme ve QRS dedeksiyon sonuçları


Çizelge 6.2 Sinüs bradikardisine ait QRS dedeksiyon algoritması sonuçları

		R1	R2	R3	R4	R5
Sinüs Bradikardisi	R Tepesi	394	804	1202	1639	2083
	Menard	394	804	1202	1639	2083
	A&T	394	804	1202	1639	2083


6.3.3. Ventriküler taşikardi ile elde edilen QRS dedeksiyon sonuçları

Ventriküler taşikardi düzensiz bir ritimdir. Bu yüzden R tepelerinin tespit edilmesi de oldukça zordur. Ham ventriküler taşikardi sinyalinin çizimi Şekil 6.3(a)'da verilmiştir. Şekil 6.3(b)'de normalize edilmiş ve filtrelenmiş sinyal şekli sunulmuştur. Şekiller incelenecek olursa ritmin düzensizliği daha iyi görülecektir. Çizelge 6.3' den de görüleceği gibi, her iki algoritma ile de, R tepelerinin bulunduğu


noktalar tam doğru olarak bulunamamıştır. Örneğin ikinci R tepesi iki algoritma da farklı bir nokta da tespit edilmiştir.




(a) Orijinal EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG



(d) R Tepelerinin bulunduğu noktalar

Şekil 6.3 Ventriküler taşikardiye ait filtreleme ve QRS dedeksiyon sonuçları


Çizelge 6.3 Ventriküler taşikardiye ait QRS dedeksiyon algoritması sonuçları

		R1	R2	R3	R4	R5
Ventriküler Taşikardi	R Tepesi	280	842	1413	1920	2415
	Menard	280	452	842	1060	1413
	A&T	280	448	842	1060	1413


6.3.4. Sinüs aritmisi ile elde edilen QRS dedeksiyon sonuçları

Sinüs aritmisi için ham bir sinyal örneği Şekil 6.4 (a)' da görülmektedir. Şekilde verilen sinyalde QRS dedeksiyonunun yapılabilmesi için filtrelenmesi ve normalize edilmesi gerekir. Sinyalin normalize edilmiş ve filtrelenmiş hali Şekil 6.4(b)' de görülmektedir. Şekil 6.4(b)' den de görüleceği gibi R tepelerinin araları farklı örnek sayısına sahiptir. Bu sebepten her RR aralığı Matlab' ın “resample”


komutu kullanılarak yeniden örneklenir ve her RR aralığının örnek sayısı 200'e eşitlenir. Şekil 6.4(c)' de RR aralıkları 200' e eşitlenmiş sinyal görülmektedir. Şekil 6.4(d)' de R tepelerinin bulunduğu noktalar gösterilmiştir. Çizelge 6.4' de her iki algoritma ile bulunan sonuçlar sunulmuştur.




(a) Orijinal EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG



(d) R Tepelerinin bulunduğu noktalar

Şekil 6.4 Sinüs aritmisine ait filtreleme ve QRS dedeksiyon sonuçları

Çizelge 6.4 Sinüs aritmisine ait QRS dedeksiyon algoritması sonuçları


		R1	R2	R3	R4	R5
Sinüs Aritmisi	R Tepesi	1693	2044	2508	3008	3410
	Menard	1693	2044	2508	3008	3410
	A&T	1693	2044	2508	3008	3410

Sonuçlar incelenirse, sinüs aritmisinde Menard algoritması ilk 4 R tepesini tespit edememiş yalnız 6. R tepesinden sonra doğru sonuçlar üretmiştir. Ancak


çizelgede gösterilmemiş olmasına rağmen, A&T algoritması ilk R tepesinden itibaren doğru olarak R tepelerinin bulmuştur.

6.3.5. Atrial prematüre kasılması ile elde edilen QRS dedeksiyon sonuçları


Atrial prematüre kasılması sinyalinin ham hali Şekil 6.5(a)' da görülmektedir. Görüldüğü gibi sinyal çok düzensizdir, fakat R tepeleri ventriküler taşikardiye göre daha belirgindir. Sinyalin normalize edilmiş ve filtrelenmiş hali Şekil 6.5(b)' de görülmektedir. Normalize edilmiş ve filtrelenmiş sinyalin sınıflandırılması için sinyalin periyotlarına ayrılması gerekir. Sınıflandırma için, QRS dedeksiyon algoritmaları ile R tepeleri tespit edilmelidir ve her R tepesi arası eşit örnek sayısına ayarlanır. Her R tepesi arasının 200 örneğe ayarlanmış hali Şekil 6.5(c)' de görülmektedir. R tepelerinin bulunduğu örnek noktaları Şekil 6.5(d)' de görülmektedir. Ayrıca hem Menard hem de A&T algoritmaları ile bulunan ilk 5 R tepesinin örnek değerleri Çizelge 6.5' de verilmiştir. Çizelgeden de görüleceği gibi R tepelerinin yerleri doğru olarak tespit edilmiştir.



(a) Orijinal EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG (d) R Tepelerinin bulunduğu noktalar
Şekil 6.5 Atrial prematüre kasılmasına ait filtreleme ve QRS dedeksiyon sonuçları


Çizelge 6.5 Atrial prematüre kasılmasına ait QRS dedeksiyon algoritması sonuçları

		R1	R2	R3	R4	R5
APC	R Tepesi	480	854	1030	1496	1871
	Menard	480	854	1030	1496	1871
	A&T	480	854	1030	1496	1871


Menard algoritmasının aksine, A&T algoritması sinyalde ilk R tepesi olan “46. örnek” noktasını tespit edebilmiştir.

6.3.6. Yapay vuru ile elde edilen QRS dedeksiyon sonuçları


Yapay vuru sinyali Şekil 6.6(a)’da görülmektedir. Sinyalin normalize edilmiş ve filtrelenmiş hali Şekil 6.6(b)’de verilmiştir. Sınıflandırma için, bütün aritmilerde olduğu gibi, QRS dedeksiyon algoritmaları ile R tepeleri tespit edilir ve her RR aralığı 200 örneğe eşitlenir. 200 örneklik RR aralıklarının birleştirilmiş hali Şekil 6.6(c)’de görülmektedir. R tepelerinin bulunduğu örnek noktalar Şekil 6.6(d)’de verilmiştir. Ayrıca hem Menard hem de A&T algoritmaları ile bulunan ilk 5 R tepesinin örnek değerleri Çizelge 6.6’da verilmiştir. Çizelgeden de görüldüğü gibi her iki algoritma ile de R tepelerinin yerleri doğru olarak tespit edilmiştir.




(a) Orijinal EKG sinyali



(b) Normalized edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG



(d) R Tepelerinin bulunduğu örnek noktalar

Şekil 6.6 Yapay vuruya ait filtreleme ve QRS dedeksiyon sonuçları


Çizelge 6.6 Yapay vuruya ait QRS dedeksiyon algoritması sonuçları

		R1	R2	R3	R4	R5
Yapay Vuru	R Tepesi	52	367	685	996	1291
	Menard	52	367	685	996	1291
	A&T	52	367	685	996	1291


6.3.7. Sağ dal bloku ile elde edilen QRS dedeksiyon sonuçları

Sağ dal bloku için ham sinyal Şekil 6.7(a)'da görülmektedir. Görüldüğü gibi sinyalde gürültüler vardır. Sınıflandırmayı etkilememesi için QRS dedeksiyonundan önce bu gürültülerin elimine edilmesi gerekir. Sinyalin filtrelenmiş ve normalize edilmiş hali Şekil 6.7(b)'de görülmektedir. QRS dedeksiyonundan sonra


düzenlenmiş sinyal Şekil 6.7(c)' de ve R tepelerinin örnek noktaları Şekil 6.7(d)' de verilmiştir. Ayrıca hem Menard hem de A&T algoritmaları ile bulunan ilk 5 R tepesinin örnek değerleri Çizelge 6.7' de sunulmuştur.




(a) Orijinal EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG



(d) R Tepelerinin bulunduğu örnek noktalar

Şekil 6.7 Sağ dal blokuna ait filtreleme ve QRS dedeksiyon sonuçları


Çizelge 6.7 Sağ dal blokuna ait QRS dedeksiyon algoritması sonuçları

		R1	R2	R3	R4	R5
Sağ Dal Bloku	R Tepesi	48146	48488	48774	49052	49331
	Menard	48146	48488	48774	49052	49331
	A&T	48146	48488	48774	49052	49331


Çizelge 6.7' den görüleceği gibi her iki algortmada da doğru sonuçlar tespit edilmiştir. Ancak A&T algoritması kayıttaki bütün R tepelerinin tespit etmiştir.

6.3.8. Sol dal bloku ile elde edilen QRS dedeksiyon sonuçları


Sol dal bloku için ham sinyal Şekil 6.8(a)' da görülmektedir. Sinyalin gürültülerden elimine edilmiş ve normalize hali Şekil 6.8(b)' de verilmiştir. QRS dedeksiyonu yapılmış düzenli sinyal şekli Şekil 6.8(c)' de ve ilk 5 R tepesinin örnek noktası ise Şekil 6.8(d)' de görüldüğü gibidir. Ayrıca hem Menard hem de A&T algoritmaları ile doğru olarak tespit edilen ilk 5 R tepesinin örnek değerleri Çizelge 6.8' de sunulmuştur.




(a) Orijinal EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG



(d) R Tepelerinin bulunduğu örnek noktalar


Şekil 6.8 Sol dal blokuna ait filtreleme ve QRS dedeksiyon sonuçları

Çizelge 6.8 Sol dal blokuna ait QRS dedeksiyon algoritması sonuçları


		R1	R2	R3	R4	R5
Sol Dal Bloku	R Tepesi	201	466	727	985	1253
	Menard	201	466	727	985	1253
	A&T	201	466	727	985	1253

6.3.9. Atrial fibrilasyon ile elde edilen QRS dedeksiyon sonuçları


Atrial fibrilasyon sinyalinin ham hali Şekil 6.9(a)' da görüldüğü gibidir. Atrial fibrilasyonun normalize edilmiş ve filtrelenmiş hali Şekil 6.9(b)' de verilmiştir. Bütün aritmi sınıfları için olduğu gibi, atrial fibrilasyon için de QRS dedeksiyonu gerçekleştirilmiştir, sinyalin düzenli hali Şekil 6.9(c)' de görülmektedir. Şekil 6.9(b)' de görülen sinyalden tespit edilen ilk 5 R tepesi için örnek noktaları Şekil 6.9(d)' de görülmektedir. Ayrıca hem Menard hem de A&T algoritmaları ile bulunan ilk 5 R tepesinin örnek değerleri Çizelge 6.9' da verilmiştir. Çizelge incelenecek olursa her iki algoritma ile de doğru tespit yapıldığı görülebilir.




(a) Orijinal EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG



(d) R Tepelerinin bulunduğu örnek noktalar


Şekil 6.9 Atrial fibrilasyona ait filtreleme ve QRS dedeksiyon sonuçları

Çizelge 6.9 Atrial fibrilasyona ait QRS dedeksiyon algoritması sonuçları


		R1	R2	R3	R4	R5
Atrial Fibrilasyon	R Tepesi	87	303	649	878	1143
	Menard	87	303	649	878	1143
	A&T	87	303	649	878	1143

6.3.10. Atrial flutter ile elde edilen QRS dedeksiyon sonuçları


Atrial flutter sinyalinin ham hali Şekil 6.10(a)' da verilmiştir. Şekil 6.10(b)' de sinyalin normalize edilmiş ve filtrelenmiş hali görülmektedir. QRS dedeksiyonu gerçekleştirildikten sonra her RR aralığı 200' e eşitlenmiş sinyal şekli Şekil 6.10(c)' de ve Şekil 6.10(b)' de görülen sinyalden tespit edilen ilk 5 R tepesi için örnek noktaları Şekil 6.10(d)' de görülmektedir Ayrıca hem Menard hem de A&T algoritmaları ile bulunan ilk 5 R tepesinin örnek değerleri Çizelge 6.10' da sunulmuştur.




(a) Orijinal EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG



(d) R Tepelerinin bulunduğu örnek noktalar

Şekil 6.10 Atrial fluttera ait filtreleme ve QRS dedeksiyon sonuçları


Çizelge 6.10 Atrial fluttere ait QRS dedeksiyon algoritması sonuçları

		R1	R2	R3	R4	R5
Atrial Flutter	R Tepesi	182	346	505	666	822
	Menard	182	346	505	666	822
	A&T	182	346	505	666	822


Çizelgeden de görüldüğü gibi, atrial flutter aritmisinde sinyal çizimine dikkat edilirse, ilk R tepesi “16.örnek” dedir. Bu R tepesi Menard algoritması tarafından tespit edilemezken A&T algoritması tarafından tespit edilememiştir.

6.3.11. Atrial couplet ile elde edilen QRS dedeksiyon sonuçları


Atrial couplet sinyalinin ham hali Şekil 6.11(a)’ da görüldüğü gibidir. Sinyalin gürültülerden elimine edilebilmesi için filtrelenmiş ve normalize edilmiş şekli Şekil 6.11(b)’ de verilmiştir. Şekil 6.11(c)’ de görüldüğü gibi sinyalde sınıflandırma için her RR aralığının örnek sayısı 200’ e eşitlenmiştir. Tespit edilen ilk 5 R tepesinin örnek değerleri Şekil 6.11(d)’ de görüldüğü gibidir. Ayrıca hem Menard hem de A&T algoritmaları ile bulunan ilk 5 R tepesinin örnek değerleri Çizelge 6.11’ de verilmiştir. Çizelgeden de görüldüğü gibi, her iki algoritma ile de doğru QRS tespitleri yapılmıştır.



(a) Orijinal EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG (d) R Tepelerinin bulunduğu örnek noktalar


Şekil 6.11 Atrial coupleta ait filtreleme ve QRS dedeksiyon sonuçları

Çizelge 6.11 Atrial coupleta ait QRS dedeksiyon algoritması sonuçları


		R1	R2	R3	R4	R5
Atrial Couplet	R Tepesi	40	357	666	969	1290
	Menard	40	357	666	969	1290
	A&T	40	357	666	969	1290

6.3.12. Ventriküler trigeminisi ile elde edilen QRS dedeksiyon sonuçları


Ventriküler trigeminisi sinyalinin ham hali Şekil 6.12(a)' da verilmiştir. Sinyalin normalize edilmiş ve filtrelenmiş hali Şekil 6.12(b)' de görülmektedir. Şekil 6.12(b)' de görülen sinyale QRS dedeksiyonu uygulanarak R tepeleri tespit edilmiştir. Sinyalin düzenli RR aralıklarına sahip hali Şekil 6.12(c)' de ve ilk 5 R tepesi için bulunan örnek noktalar Şekil 6.12(d)' de görülmektedir. Ayrıca hem Menard hem de A&T algoritmaları ile bulunan ilk 5 R tepesinin örnek değerleri Çizelge 6.12' de verilmiştir. Çizelgeden de görüldüğü gibi, her iki algoritma ile de doğru QRS tespitleri yapılmıştır.




(a) Orijinal EKG sinyali



(b) Normalize edilmiş ve filtrelenmiş EKG



(c) RR aralıkları 200 örneğe düşürülmüş EKG



(d) R Tepelerinin bulunduğu örnek noktalar

Şekil 6.12 Ventriküler trigemisinine ait filtreleme ve QRS dedeksiyon sonuçları

Çizelge 6.12 Ventriküler trigemisinine ait QRS dedeksiyon algoritması sonuçları

		R1	R2	R3	R4	R5
Ventriküler Trigeminy	R Tepesi	112	300	777	1097	1283
	Menard	112	300	777	1097	1283
	A&T	112	300	777	1097	1283

7. EKG ARİTMİLERİNİ SINIFLANDIRMA SİSTEMLERİ VE UYGULAMALARI


Literatürde gerçekleştirilen otomatik teşhis sistemlerinin (automatic diagnostic system) çoğu 3 ortak yapıdan oluşur. Bu yapılar sırasıyla; sinyal işleme bloğu, özellik çıkarma/seçme bloğu ve sınıflandırma bloğudur. Sinyal işleme bloğu, prosesin kusursuz işlemesi için şüphesiz en önemli işlem adımıdır. Ancak sınıflandırma performansının yüksek elde edilmesi isteniyorsa; en az sinyal işleme bloğu kadar özellik çıkarma/seçme bloğu da önemlidir. İşlenmiş sinyal içerisinde sınıflandırma sonucunu olumsuz yönde etkileyecek gereksiz özellikler bulunur. Bu gereksiz özelliklerin elimine edilmesi özellik çıkarma/seçme metotları kullanılarak gerçekleştirilir. Daha az örnek sayısından oluşmuş örüntülerle sınıflandırmanın yapılması hem daha iyi bir tanıma doğruluğu elde edilmesini hem de daha az sürede eğitim ve test işleminin gerçekleştirilmesini sağlar (De ve ark. 2002, Özbay ve ark. 2006, Ceylan ve Özbay 2007, Ceylan ve ark. 2008). Son yıllardaki çalışmalarda özellik çıkarma/seçme bloğunun dalgacık dönüşümü, temel bileşen analizi, bağımsız bileşen analizi gibi farklı algoritmalarla gerçekleştirildiği görülmektedir (Petranek 1997, Patridge 1998, Ceylan ve Özbay 2007).

Tez çalışmasında, tanıma doğruluğunu artırmak ve yapay zeka sınıflandırmalarında önemli bir sorun olan eğitim ve test süresini azaltmak için üç farklı yapı gerçekleştirilmiştir. Önerilen ilk yapıda sadece örüntü seçme ve sınıflandırma prosesleri gerçekleştirilerek sonuçlar karşılaştırmalı olarak incelenmiştir. İlk yapıda, sınıflandırmada kullanılacak aynı sınıftaki örüntüler içinden sınıfın özelliklerini daha az gösteren örüntülerin elenmesi için “örüntü seçme” prosesi gerçekleştirildi. Sınıf özelliklerinin daha baskın görüldüğü örüntülerle gerçekleştirilen bir sınıflandırma işleminde, doğruluğun daha yüksek olacağı fikrinden yola çıkılarak gerçekleştirilen yapı ile elde edilen sonuçların da bu fikrin doğruluğunu kanıtlar nitelikte olduğu görülmüştür. Yapıda örüntü seçme işlemi literatürde özellikle biyomedikal sinyallerin kümelenmesinde henüz kullanılmamış tip-2 bulanık c-ortalamlar kümeleme algoritması ile gerçekleştirilmiştir. Seçilmiş örüntülerle oluşturulan yeni eğitim seti ile sınıflandırma

işlemi yapılmıştır. Örüntü seçme işlemi sadece sınıflandırma için önerilen yapay sinir ağının eğitimi için hazırlanan verilerin optimize edilmesinde kullanılmıştır. Çalışmada sunulan ikinci ve üçüncü yapılar da ise örüntü seçme prosesi ile sınıflandırma prosesi arasında, özellik çıkarma prosesi de gerçekleştirilmiştir. İkinci ve üçüncü yapılarda, özellik çıkarma algoritması olarak sırasıyla dalgacık dönüşümü ve temel bileşen analizi kullanılmıştır. Bu yapılarda özellik çıkarma prosesinden sonra birinci yapıda gerçekleştirildiği gibi örüntü seçme ve sınıflandırma prosesleri mevcuttur. Tezde önerilen yapılarla elde edilen sonuçlar ilerleyen bölümlerde detaylı olarak sunulmuştur.

7.1. Tip-2 Bulanık Kümeleme Sinir Ağı


Bu tez çalışmasında, örüntü tanıma ve sınıflandırmada hatayı ve eğitim süresini azaltmak için üç yapı önerilmiştir. Bunlardan ilki Şekil 7.1’ de blok gösterimi verilen yapıdır. Şekil 7.1’ den görüleceği gibi, bu yapı “Tip-2 Bulanık Kümeleme Sinir Ağı” olarak isimlendirilmektedir. Tip-2 bulanık kümeleme sinir ağı (T2BKSA) yapısı tip-2 bulanık c-ortalamlar kümeleme bloğu ve yapay sinir ağının kaskat bağlanması ile elde edilmiştir.



Şekil 7.1 Tip-2 Bulanık Kümeleme Sinir Ağı

T2BKSA’ da sınıflandırılacak veri öncelikle tip-2 bulanık c-ortalamlar kümeleme algoritması kullanılarak kümelenmektedir. Kümeleme işlemi her sınıf için ayrı ayrı gerçekleştirilmektedir. Böylece her sınıf içerisinde o sınıfı en iyi temsil eden

örüntüler seçilerek yeni bir eğitim setinin oluşturulması sağlanmaktadır. Yapıda tip-2 bulanık c-ortalamlar kümeleme algoritması ile elde edilen küme merkezi değerleri yapay sinir ağı için söz konusu sınıfı en iyi temsil eden giriş örüntüleri olarak kullanılmaktadır. Tip-2 bulanık c-ortalamlar kümeleme algoritması danışmansız bir kümeleme algoritmasıdır ve algoritmaya ait akış diyagramı Şekil 7.2’ de verilmiştir.




Şekil 7.2 Tip-2 Bulanık C-Ortalamlar Kümeleme Algoritması

Akış diyagramından da görüleceği gibi bulanık kümeleme işlemi için sadece eğitim veri setindeki giriş verileri kullanılmaktadır. Hedef verisi algoritma danışmansız olduğu için kümeleme işlemi sırasında kullanılmamaktadır. Gerçekleştirilen tez çalışmasında tip-2 bulanık c- ortalamalar kümeleme algoritmasının kullanılma amacı, eğitim verisinde aynı sınıfı temsil eden örüntü sayısını azaltmak olduğu için danışmansız bir algoritmanın kullanılması daha uygun olmuştur. Kümeleme algoritmasında her iterasyon sonunda, gerçekleşen iterasyonda elde edilen maliyet fonksiyonu ile bir önceki iterasyonda elde edilen maliyet fonksiyonu arasındaki fark hesaplanarak hata büyüklüğünün istenilen minimum değere düşüp düşmediği kontrol edilmektedir. Bu minimum değer “durdurma kriteri” adını alır ve kullanıcı tarafından programa parametre olarak girilir. Eğer son iki iterasyon arasındaki hata farkı durdurma kriterini sağlamıyorsa, iterasyon devam eder. Fark, durdurma kriterini sağlıyorsa iterasyon biter ve elde edilen küme merkezleri kayıt edilir. Yapay sinir ağı için giriş örüntüleri olan bu küme merkezlerinin sayısına göre hedef verisinin set sayıları düzenlenir. Algoritmanın örüntü sayısını indirgeyeceği küme sayısı kullanıcı tarafından girilir.

T2BKSA kaskat yapısını oluşturan ikinci blok danışmanlı yapay sinir ağı yapısından oluşmaktadır. Çalışmada danışmanlı yapay sinir ağının eğitimi için geriye yayılım algoritması kullanılmaktadır. Bulanık c-ortalamalar kümeleme algoritması ile elde edilen her sınıf için en iyi örüntülerden oluşturulmuş eğitim giriş veri seti ve bu sete uygun olarak hazırlanan hedef seti Şekil 7.3’ de akış diyagramı verilen YSA algoritmasına sunulur. Akış diyagramından da görüldüğü gibi algoritma danışmanlı olduğu için hem giriş verileri hem de ağın elde etmesi istenilen hedef verileri sisteme girilir. Başlangıç ağırlıkları ve parametreler girildikten sonra, ağ geriye yayılım algoritmasına göre eğitilir. Ağın eğitilmesinde kullanılan geriye yayılım algoritmasında da her iterasyon sonunda ardışık son iki iterasyon arasındaki lokal hata farkı hesaplanır. Eğer bulunan lokal hata fark değeri durdurma kriterini sağlamıyorsa, ağın ağırlıklarının güncellenmesi işlemi devam eder. Lokal hata fark değeri durdurma kriterinden küçükse, ki bu kriter bulanık kümeleme bloğunda olduğu gibi kullanıcı tarafından belirlenir, iterasyon durdurulur, son ağırlık ve bias değerleri kayıt edilir. Kayıt edilen ağırlık ve bias değerleri ağın test edilmesinde kullanılır. Yapay zekâ mantığına uygun olarak, test işleminde ağı herhangi bir hedef


verisi verilmez, sadece test verisine ait giriş değerleri ağı sunularak, ağı elde ettiği çıkışlar yorumlanır.



Şekil 7.3 T2BKSA yapısında bulunan danışmanlı yapay sinir ağı algoritması akış diyagramı

7.2. Tip-2 Bulanık Kümeleme Dalgacık Sinir Ağı

Bu tez çalışmasında, örüntü tanıma ve sınıflandırmada hatayı ve eğitim süresini azaltmak için önerilen ikinci yapı Şekil 7.4’ de blok gösterimi verilen “Tip-2 Bulanık Kümeleme Dalgacık Sinir Ağı”dır. Tip-2 bulanık kümeleme dalgacık sinir ağı (T2BKDSA) yapısı tip-2 bulanık c-ortalamlar kümeleme bloğu, dalgacık dönüşümü bloğu ve yapay sinir ağının kaskat bağlanması ile elde edilmiştir.



Şekil 7.4 Tip-2 Bulanık Kümeleme Dalgacık Sinir Ağı


T2BKDSA yapısında kümelenecek giriş verisi öncelikle tip-2 bulanık c-ortalamlar kümeleme algoritması kullanılarak kümelendir. Buradaki kümeleme işlemi T2BKSA yapısında olduğu gibi her sınıfta o sınıfı temsil eden en iyi örüntülerin seçilmesini amaçladığından her sınıf için ayrı ayrı gerçekleştirilir. Her sınıf için elde edilen küme merkezi değerleri birleştirilerek yeni eğitim seti elde edilir. Elde edilen eğitim setindeki toplam set sayısı orijinal eğitim verisinin set sayısından farklıdır. Bu yeni eğitim setinin toplam set sayısı bulanık kümeleme algoritmasında her sınıf için belirlenen küme sayısının toplamına eşittir. Fakat eğitim setinin giriş örüntülerinde bir örüntüyü oluşturan örnek sayısı değişmez. Eğitim setinde daha az set sayısı ile çalışılmasının sinir ağının performansını olumsuz yönde etkileyeceği düşünülse de, burada önemli olan husus her sınıfı en iyi ifade eden verilerle ağın öğrenme prosedürünün gerçekleştirileceğidir. Bu durum ağın performansını sanılanın aksine artırmaktadır.

T2BKDSA kaskat yapısının ikinci bloğu Şekil 7.4’ den de görüleceği gibi dalgacık dönüşüm bloğudur. Tip-2 bulanık kümeleme algoritması ile elde edilen yeni eğitim setini oluşturan örüntülerin örnek sayılarını azaltmak için ayrık dalgacık dönüşümü (discrete wavelet transform) kullanılmıştır. Örüntülerin örnek sayılarının azaltılmasında Matlab Dalgacık Araç Kutusu’ nda yer alan pek çok ayrık dalgacık dönüşümünden iki seviyeli “Daubechies2” ayrık dalgacık dönüşümü kullanılmıştır. Ayrık dalgacık dönüşümü ile örnek sayısı azaltılan örüntülerden oluşan eğitim seti geriye yayılım algoritması ile eğitilen danışmanlı yapay sinir ağına verilir. Eğitim sonucu ağı ürettiği değerler ile hedef değerler arasında hata hesabı yapılarak elde edilen sonuçlar karşılaştırmalı olarak sunulmuştur.

T2BKSA yapısında olduğu gibi T2BKDSA yapısında da kullanılan bulanık kümeleme ve yapay sinir ağı bloklarına ait akış diyagramları Şekil 7.2 ve Şekil 7.3’ de görüldüğü gibidir. Hem T2BKSA hem de T2BKDSA yapısında eğitim ve test prosesi arasındaki fark tip-2 bulanık c-ortalamlar kümeleme algoritmasının kullanımıdır. Tip-2 bulanık c-ortalamlar kümeleme algoritması her iki yapıda da yalnızca eğitim prosesindeki verilerde kullanılır. Bulanık kümeleme yapılmasındaki amaç, sistemin en iyi ve az örüntü ile daha iyi performans elde edip edemeyeceğinin tespit edilmesidir. Dolayısıyla test verisi için ağı üreteceği sonuçlar performans tespitinin yapılabileceği yegane ölçüttür. Bu sebepten test verisinde bulanık kümeleme gerçekleştirilmez. Böylece ağı daha az ama seçilmiş örüntü ile eğitilmesinin performans üzerine etkisi incelenmiş olur.

7.3. Tip-2 Bulanık Kümeleme-Temel Bileşen Analizi-Yapay Sinir Ağı

Tez çalışmasında, önerilen üçüncü yapının ikinci yapıdan (T2BKDSA) tek farkı Şekil 7.5’ deki blok gösteriminden de görüleceği gibi burada özellik çıkarma işleminin temel bileşen analizi (principal component analysis) ile gerçekleştirilmesidir. Temel bileşen analizi literatürde özellik çıkarma/seçme algoritması olarak haberleşme, biyomedikal, kontrol gibi pek çok alanda kullanılmaktadır. Tez çalışmasında elektrokardiyogram sinyallerinde özellik çıkarma işlemi için kullanılmıştır.



Şekil 7.5 Tip-2 Bulanık Kümeleme-Temel Bileşen Analizi-Yapay Sinir Ağı

Şekil 7.5’ den de görüleceği gibi tip-2 bulanık c-ortalamlar kümeleme algoritması ile elde edilen yeni eğitim seti temel bileşen analizi bloğuna sunulur. Temel bileşen analizi kullanılarak eğitim setinde her örüntü içerisindeki gereksiz örnekler elimine edilerek bir örüntüyü oluşturan örnek sayısı azaltılır. Azaltılmış örnek sayısı ile boyutu küçülen ve seçilmiş örneklerden oluşan eğitim seti danışmanlı yapay sinir ağına verilir. Ağın eğitim verisi için ürettiği sonuçlar ve hedef verileri karşılaştırılarak eğitim hatası hesaplanır. Aynı işlem ağın test edilmesi için sunulan test verileri için de gerçekleştirilir. Elde edilen eğitim ve test hatası ile sınıflandırma sonuçları tez çalışmasının uygulama kısmında sunulmuştur.

7.4. Eğitim ve Test Verisinin Özellikleri

Tez çalışmasında, Physionet veri tabanından alınan MIT-BIH ECG Arrhythmia Database’ e ait veriler tez çalışmasında önerilen sistemleri eğitime ve test etme amacıyla kullanılmıştır. Veri tabanından alınan kayıtlar 1975-1979 yılları arasında Boston’s Beth Israel Hospital’ da yatan veya gözlem altında olan hastalardan alınmış ve 360 Hz de örneklenmiş kayıtlardır. Genel olarak her kayıt üç sütundan oluşmuş verileri içerir. İlk sütunda zaman verileri yer alır. İkinci sütun genellikle derivasyon II verileri olmakla birlikte ikinci ve üçüncü sütunlar kayda göre iki farklı derivasyon için kayıt edilmiş verileri içerir. Her kayıt 30.06 dakikalıktır. Bu

süre ve örnekleme frekansı 360 Hz göz önüne alındığında kayıtlarda her derivasyon için örnek sayısı yaklaşık 649800' dür.

Çalışmada gerçekleştirilen 3 farklı elektrokardiyografi sınıflandırma sisteminin eğitimi ve testi için Çizelge 7.1' de özellikleri verilen veri setleri kullanılmıştır. Eğitim ve test verileri aynı kayıtların söz konusu aritmiyi gösteren bölümlerinden kesilerek oluşturulmuştur.

Çizelge 7.1 Eğitim ve test verisinin özellikleri

Aritmi	Kayıt No	Kısaltma	Süre (dak)	Eğitim	Test
				166 Set	152 Set
Normal Sinüs Ritmi	103	NS	1.09-17.21	20	20
Sinüs Bradikardisi	202	SB	18.22-18.45	10	5
Ventriküler Taşikardi	200	VT	1.41-5.38	10	5
Sinüs Aritmisi	113	SA	12.27-22.10	15	15
Atrial Prematüre Kasılması	202	APC	12.24-12.41	6	2
Yapay vuru	107	PB	0.44-12.30	15	15
Sağ Dal Bloku	118	RBB	13.47-22.32	15	15
Sol Dal Bloku	109	LBB	17.08-17.50	15	15
Atrial Fibrilasyon	202	AFib	29.35-30.06	15	15
Atrial Flutter	202	AFlut	25.58-27.55	15	15
Atrial Couplet	220	ACoup	25.44-29.40	15	15
Ventriküler Trigeminy	119	VTri	2.38-4.51	15	15

Tez çalışmasında gerçekleştirilen, EKG cihazı ve I/O kartı ile yapılan kayıt sisteminde sadece derivasyon II' ye ait veriler alınabildiğinden, oluşturulan sınıflandırma yapıları da derivasyon II verileri ile eğitilerek, test edilmek zorundadır. Bu sebepten 3 sütundan oluşan veri tabanı kayıtlarında özellikle derivasyon II verileri bulunan kayıtlar seçilmiştir. Veri tabanından alınan kayıtların zaman sütunu ile derivasyonu II içeren sütundaki veriler kullanılmıştır. Çizelge 7.1' den görüleceği gibi eğitim verisi 166 setten, test verisi de 152 setten oluşmaktadır. Hem eğitim hem de test verisi için her set bir RR aralığını içerir ve 200 örnekten oluşmaktadır. Veri setleri Çizelge 7.1' de verilen kayıtlardan gösterilen zaman aralıklarında kesilerek oluşturulmuştur. Veriler 360 Hz' de örneklenmiş sinyal şeklindedir. Bu sinyallerin veri setleri haline getirilmesi için QRS dedeksiyonu gerçekleştirilmiş ve ham veri setleri elde edilmiştir. Veri set uzunluklarının eşitlenmesi için her RR aralığı 200 örnek olacak şekilde setler düzenlenmiştir.

Ayrıca gerçekleştirilen sistemlerde kullanılan yapay sinir ağı danışmanlı bir ağıdır. Danışmanlı ağlarda eğitim aşamasında sisteme hem eğitim giriş verilerinin hem de bu verilere karşılık ağıın üretmesi istenilen hedef verilerinin verilmesi gerekir. Bu hedef verileri Şekil 7.6’ da verilen matris formatına göre oluşturulur. Şekilden de görüleceği gibi hedef verisinin set sayısı eğitim giriş verisinin set sayısına eşittir. Aynı şekilde hedef verisinin satır sayısı başka bir deyişle sistemin çıkış sayısı eğitim giriş verisindeki sınıf sayısına eşittir.

	NS	SB	VT	SA	APC	PB	RBB	LBB	AFib	AFlut	ACoup	VTri
	1 ... 20	21 ... 30	31 ... 40	41 ... 55	56 ... 61	62 ... 76	77 ... 91	92 ... 106	107 ... 121	122 ... 136	137 ... 151	152 ... 166
1. Çıkış	1 ... 1	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0
2. Çıkış	0 ... 0	1 ... 1	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0
3. Çıkış	0 ... 0	0 ... 0	1 ... 1	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0
4. Çıkış	0 ... 0	0 ... 0	0 ... 0	1 ... 1	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0
5. Çıkış	0 ... 0	0 ... 0	0 ... 0	0 ... 0	1 ... 1	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0
6. Çıkış	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	1 ... 1	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0
7. Çıkış	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	1 ... 1	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0
8. Çıkış	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	1 ... 1	0 ... 0	0 ... 0	0 ... 0	0 ... 0
9. Çıkış	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	1 ... 1	0 ... 0	0 ... 0	0 ... 0
10. Çıkış	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	1 ... 1	0 ... 0	0 ... 0
11. Çıkış	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	1 ... 1	0 ... 0
12. Çıkış	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	0 ... 0	1 ... 1

Şekil 7.6 Eğitim verisine göre hedef verisinin oluşturulması

7.5. Eğitim ve Test Hatalarının Hesaplanması

Tez çalışmasında önerilen yapılarda yapay sinir ağı ile elde edilen eğitim sonuçları $a(i)$ ve ağıın ulaşması istenen hedefleri de $t(i)$ ile gösterilirse, yüzde ortalama eğitim hatası (E.H.(%)), (7.1) eşitliği kullanılarak bulunur (Özbay ve ark 2006).

$$E.H.(%) = \frac{\sum_{i=1}^k |t(i) - a(i)|}{\text{set sayısı} \times \text{çıkış sayısı}} \times 100 \quad (7.1)$$

Burada k , hedef datası örüntü sayısıdır.

Çalışmada önerilen elektrokardiyografi sınıflandırma sistemlerinin test edilmesinde, ağa test verisi sunulduktan sonra ağıın elde ettiği veriler kullanılarak test hatası bulunurken, öncelikle yazılan algoritma ile test verisi ile elde edilen çıkışlar

sınıflandırılmış daha sonra sınıflandırılan çıkışlar için ayrı ayrı hatalar hesaplanarak toplanmış ve test hatası bulunmuştur. Sınıflandırılan çıkış $n(i)$ ise, hata (h), (7.2) ve (7.3) denklemleri kullanılarak bulunmuştur (Özbay 1999, Özbay ve ark 2006).

$$n(i) \geq 0.5 \text{ ise } h = \sum_{i=1}^k |1 - n(i)| \quad (7.2)$$

$$n(i) < 0.5 \text{ ise } h = \sum_{i=1}^k |0 - n(i)| \quad (7.3)$$

(7.4) eşitliğinde ise k , test verisi set sayısıdır (3000 veriden oluşan bir test verisi için, ağ 200 girişli olduğuna göre $3000/200=15$ set mevcuttur. Bu durumda çıkış datası uzunluğu $15*12=180$ veri olacaktır). Bu tek bir sınıfa ait hatadır. Dolayısıyla toplam yüzde test hatası bütün sınıfların hatalarının toplamıdır ve (7.4) eşitliği kullanılarak bulunmuştur (Özbay 1999, Özbay ve ark 2006).

$$T.H (\%) = \frac{\sum_{j=1}^m h(j)}{\text{test datası set sayısı} \times \text{çıkış sayısı}} \times 100 \quad (7.4)$$

7.6. Elektrokardiyografi Sınıflandırma Sistemleri Uygulama Sonuçları

Çalışmada önerilen elektrokardiyografi (EKG) sınıflandırma sistemlerine (T2BKSA, T2BKDSA, T2BK-TB-YSA) Bölüm 7.4' de özellikleri verilen eğitim ve test setindeki veriler sunulmuştur. Karşılaştırma açısından, 3 sınıflandırma yapısı ile elde edilen test sonuçları detaylı olarak sunulmuştur. Elde edilen sonuçların karşılaştırılabilmesi için eğitim ve test hataları Bölüm 7.5' de verilen formüller kullanılarak hesaplanmıştır.

Önerilen sistemlerle uygulamaların yapılması için sistemlere ait optimum parametrelerin belirlenmesi gerekir. Belirlenmesi gereken öncelikli parametre tip-2 bulanık c-ortalamalar kümeleme ortalamasına ait iki bulanıklık sabitinin değerleridir. Çizelge 7.2' de optimum bulanıklık sabitinin bulunması için seçilen $m_1 - m_2$ kombinasyonları incelenecek olursa bu iki değerin birbirine eşit olduğu

kombinasyonların ele alınmadığı görülebilir. m_1 ve m_2 değerlerinin birbirine eşit olması tip-2 bulanık c-ortalamalar kümeleme algoritmasından tip-1 bulanık c-ortalamalar kümeleme algoritmasına geçildiğini gösterir. Çalışmada tip-2 bulanık kümeleme gerçekleştirilmek istendiğinden bu iki değerin eşit olduğu kombinasyonlar incelenmemiştir. Çizelge 7.2’ de verilen değerler T2BKSA yapısı kullanılarak elde edilmiştir.

Çizelge 7.2 Optimum bulanıklık sabitinin bulunması

m_1	m_2	Eğitim hatası (E.H., %)	Test Hatası (T.H., %)	Yanlış sınıflandırılan set sayısı	İterasyon sayısı
2	3	$7.38.10^{-9}$	0.016	2	1156
3	2	$7.19.10^{-9}$	0.016	2	1274
4	5	$7.69.10^{-9}$	0.072	4	1220
5	4	$7.25.10^{-9}$	0.055	4	1080
6	5	$7.31.10^{-9}$	0.027	4	1183
7	6	$7.4.10^{-9}$	0.044	3	1090
8	7	$7.33.10^{-9}$	0.024	3	1053
9	8	$7.27.10^{-9}$	0.019	3	1160
10	9	$7.09.10^{-9}$	0.028	3	1090
11	10	$7.02.10^{-9}$	0.034	3	1091
12	11	$7.019.10^{-9}$	0.037	3	1024
13	12	$7.019.10^{-9}$	0.012	2	1497
14	13	$7.12.10^{-9}$	0.023	2	1199
15	14	$7.74.10^{-9}$	0.023	2	3369

Çizelge 7.2’ den de görüleceği gibi optimum m_1 ve m_2 değeri sırasıyla 3 ve 2 olarak elde edilmiştir. Literatürde de en çok kullanılan bulanıklık sabiti değerleri 3 ya da 2’ dir. Ancak literatürde, bu iki değerin ya da tip-1 bulanık c-ortalamalar kümeleme algoritması için incelenecek olursa, bulanıklık sabitinin seçimi ile ilgili herhangi bir kriter yoktur. Bu sebepten olası her problem için farklı optimum değerlerin elde edilmesi mümkündür.

Önerilen sistemlere ait ortak diğer parametreler de öğrenme oranı ve momentum sabiti değerleridir. Bunlar, sistemlerde son sınıflandırma aşaması için kullanılan yapay sinir ağına ait parametrelerdir. Bu iki parametrenin optimum değerinin belirlenmesi için yapılan iterasyon sonuçları Çizelge 7.3 ve Çizelge 7.4’ de verilmiştir. Çizelge 7.3 ve Çizelge 7.4’ de verilen değerler Çizelge 7.2’ de olduğu gibi T2BKSA yapısı kullanılarak elde edilmiştir. Bütün çizelgelerde maksimum iterasyon sayısı 10000 olarak alınmıştır.

Çizelge 7.3 Optimum öğrenme oranının belirlenmesi (Gizli düğüm sayısı=50, momentum sabiti=0.9)

Öğrenme oranı	Eğitim hatası (E.H., %)	Test Hatası (T.H., %)	Yanlış sınıflandırılan set sayısı	İterasyon sayısı
1.0	$7.75.10^{-9}$	0.025	3	1119
2.0	$7.19.10^{-9}$	0.016	2	1274
3.0	$7.64. 10^{-9}$	0.017	3	1740
4.0	$7.47.10^{-9}$	0.042	3	3851
5.0	4.16	0.0078	73	10000
7.0	4.86	0.013	95	10000


Çizelge 7.4 Optimum momentum sabitinin belirlenmesi (Gizli düğüm sayısı=50, Öğrenme oranı=2.0)

Momentum sabiti	Eğitim hatası (E.H., %)	Test Hatası (T.H., %)	Yanlış sınıflandırılan set sayısı	İterasyon sayısı
0.1	$7.19.10^{-9}$	0.012	3	3950
0.3	$7.7.10^{-9}$	0.015	3	2815
0.5	$7.37. 10^{-9}$	0.015	3	1896
0.7	$7.47.10^{-9}$	0.024	3	1338
0.9	$7.19.10^{-9}$	0.016	2	1274
1.0	8.33	$1.59.10^{-11}$	152	10000

Ayrıca uygulama sonuçları sunulurken, eğitim ve test setindeki verilere ait sınıflandırma sonuçlarının verilmesinde Çizelge 7.1’ de 3. sütunda verilen kısaltmalar kullanılacaktır.

7.6.1. T2BKSA yapısı ile elde edilen uygulama sonuçları

T2BKSA yapısı ile elektrokardiyografi verilerinin sınıflandırılmasında oluşturulan sisteme ait daha detaylı bir çizim Şekil 7.7’ de görülmektedir.



Şekil 7.7 T2BKSA ile EKG verilerinin sınıflandırılması

Şekil 7.7 incelenecek olursa eğitim setinde bir örüntüyü oluşturan örnek sayısı tip-2 bulanık c-ortalamalar kümeleme algoritması ile elde edilen yeni eğitim verisinde de değişmemektedir. Tip-2 bulanık c-ortalamalar kümeleme algoritması ile her sınıfa ait en iyi örüntüler seçilerek yeni bir eğitim verisi oluşturulduğundan, elde edilen yeni eğitim verisinde başlangıçtaki eğitim verisinden farklı olan, toplam örüntü sayısıdır. Çalışmada tip-2 bulanık c-ortalamalar kümeleme algoritması kullanılarak toplam örüntü sayısı farklı iki yeni eğitim verisi elde edilmiştir. Yeni eğitim verilerinin toplam örüntü sayıları sırasıyla 84 ve 100' dür. Elde edilen bu yeni eğitim verilerinde örüntü sayılarının aritmi sınıflarına göre dağılımı Çizelge 7.5' de verilmiştir. Bu yeni eğitim verilerinin elde edilmesinde bulanıklık sabitleri, Çizelge 7.2' ye göre optimum değerler olan $m_1=3$ ve $m_2 = 2$ seçilmiştir.

Çizelge 7.5 Tip-2 bulanık c-ortalamalar kümeleme ile elde edilen eğitim verilerinde toplam örüntü sayısının aritmi sınıflarına göre dağılımı

EKG Sinyal Sınıfı	Orijinal eğitim verisi	Yeni eğitim verileri	
	166 Set	84 Set	100 Set
Normal Sinüs Ritmi	20	10	10
Sinüs Bradikardisi	10	7	7
Ventriküler Taşikardi	10	7	7
Sinüs Aritmisi	15	7	9
Atrial Prematüre Kasılması	6	4	4
Yapay vuru	15	7	9
Sağ Dal Bloku	15	7	9
Sol Dal Bloku	15	7	9
Atrial Fibrilasyon	15	7	9
Atrial Flutter	15	7	9
Atrial Couplet	15	7	9
Ventriküler Trigeminy	15	7	9

Tip-2 bulanık kümeleme ile bir örüntüyü oluşturan örnek sayısı değişmediğine ve EKG verilerinde bir veriyi oluşturan örnek sayısı 200 olduğuna göre, yapay sinir ağının giriş düğüm sayısı da 200' dür. Yapay sinir ağının çıkış düğüm sayısı Şekil 7.7' den de görüldüğü gibi eğitim ve test setindeki sınıf sayısına eşittir ve 12' dir. Gizli düğüm sayısı ise ağın çıkışlarını etkileyen en önemli parametredir. Optimum gizli düğüm sayısı söz konusu iki yeni eğitim verisi için de ayrı ayrı gerçekleştirilmiştir. 84 setlik eğitim verisi için T2BKSA yapısı ile

gerçekleştirilen iterasyon sonuçları Çizelge 7.6’ da verilmiştir. En düşük eğitim ve test hatasının elde edildiği optimum T2BKSA yapısı çizelgeden de görüldüğü gibi 200:50:12 olarak elde edilmiştir.

T2BKSA yapısının test aşamasında; test verileri, tip-2 bulanık c-ortalamlar kümeleme algoritmasına sunulmadan, örüntü sayısı azaltılmış yeni eğitim verisi ile eğitilmiş sinir ağına sunularak ağ test edilmiştir. Test verisi için Çizelge 7.6’ daki gizli düğüm sayıları kullanılarak T2BKSA yapısında elde edilen sınıflandırma sonuçları her aritmi sınıfı için detaylı bir şekilde Çizelge 7.7’ de verilmiştir.

*Çizelge 7.6 T2BKSA yapısı için optimum gizli düğüm sayısının bulunması
(84 setlik eğitim verisi ile elde edilen sonuçlar)*

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	$1.1.10^{-8}$	0.134	18.71	6252
20	$9.34.10^{-9}$	0.046	9.76	2035
30	$8.3.10^{-9}$	0.045	8.74	1549
40	$7.51.10^{-9}$	0.026	7.64	1102
50	$7.19.10^{-9}$	0.016	10.14	1274
60	$7.03.10^{-9}$	0.032	12.92	1510
70	$7.99.10^{-9}$	0.02	25.39	2799
80	0.099	0.046	49.25	4830

*Çizelge 7.7 T2BKSA yapısı için test verisi sınıflandırma sonuçları
(84 setlik eğitim verisi ile eğitilen sistemde)*

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlut	AFib	ACoup	VTri	YS
10	20	5	6	15	1	15	11	15	13	16	17	15	7
20	20	5	4	16	2	15	15	15	13	16	15	15	3
30	20	5	4	16	1	15	15	15	14	16	15	15	3
40	20	6	4	15	1	15	15	15	13	16	15	15	4
50	20	5	4	15	3	15	15	15	14	16	15	15	2
60	20	5	4	16	2	15	15	15	13	16	15	15	3
70	20	5	4	15	3	15	15	15	13	16	15	15	3
80	20	5	4	15	1	15	15	15	14	16	15	10	8

YS=Yanlış sınıflanan set (örüntü) sayısı

Aynı şekilde 100 setlik eğitim verisi için de T2BKSA yapısı ile optimum gizli düğüm sayısının bulunması amacıyla yapılan uygulamaların sonuçları Çizelge 7.8’ de sunulmuştur. Test aşamasında; test verileri 100 setlik eğitim verisi ile eğitilen ağda test edilmiştir. Gizli düğüm sayısına göre test hatalarının değişimi Çizelge 7.8’ de verilmiştir. Ancak test verisi sınıflandırma sonuçlarının detaylı dağılımı Çizelge 7.9’ da görülebilir.

Çizelge 7.8 T2BKSA yapısı için optimum gizli düğüm sayısının bulunması
(100 setlik eğitim verisi ile elde edilen sonuçlar)

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	0.083	0.102	37.01	10000
20	9.87.10⁻⁹	0.024	8.79	1822
30	7.97.10 ⁻⁹	0.018	9.012	1446
40	7.19.10 ⁻⁹	0.037	9.24	1224
50	7.37.10 ⁻⁹	0.049	13.64	1588
60	7.84.10 ⁻⁹	0.026	17.84	1762
70	4.16	0.044	105.6	10000
80	7.01.10 ⁻⁹	0.05	44.21	3956

Çizelge 7.9 T2BKSA yapısı için test verisi sınıflandırma sonuçları
(100 setlik eğitim verisi ile eğitilen sistemde)

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlut	AFib	ACoup	VTri	YS
10	20	5	6	15	2	15	13	15	13	16	15	10	9
20	20	5	4	15	2	15	15	15	14	16	15	15	2
30	20	5	4	16	1	15	15	15	14	16	15	15	3
40	20	6	4	16	1	15	15	15	13	16	15	15	4
50	20	5	4	15	3	15	15	15	13	16	15	15	3
60	20	5	4	16	2	15	15	15	13	16	15	15	3
70	0	5	4	0	0	15	16	0	14	16	0	0	84
80	20	5	4	15	1	15	15	15	13	16	15	15	4


YS=Yanlış sınıflanan set (örüntü) sayısı

Çizelge 7.8 ve Çizelge 7.9 incelenecek olursa en iyi sınıflandırma sonuçları gizli düğüm sayısı “20” olarak seçildiğinde elde edilmiştir. Çizelge 7.8’ den görüleceği gibi, daha düşük eğitim ve test hatalarının elde edildiği gizli düğüm sayıları vardır (örneğin 30 gizli düğümde elde edilen değerler). Ancak sınıflandırma problemlerinde optimum ağ yapısının bulunmasında amaç sadece en düşük eğitim ve test hatasının elde edilmesi, en kısa sürede eğitilmesi değildir. Asıl amaç bu koşulların sağlanması ile birlikte aynı zamanda iyi sınıflandırma sonuçlarına ulaşmaktır. Ağ en az hata ile en doğru sınıflandırma oranına eriştiği zaman optimum yapı bulunmuş demektir. Bu ifadeye uygun olarak optimum yapının belirlenmesinde Çizelge 7.8 ile Çizelge 7.9 birlikte incelenmelidir. İnceleme sonucu 200:20:12 hiyerarşisinin 100 setlik eğitim verisi ile eğitilen ağ için optimum olduğu görülecektir.

Çizelge 7.7 ve Çizelge 7.9’ da elde edilen sınıflandırma sonuçları incelenecek olursa, T2BKSA yapısında her iki eğitim veri seti ile eğitilen ağlarla en az 2 örüntü yanlış sınıflandırılmıştır.

7.6.2. T2BKDSA yapısı ile elde edilen uygulama sonuçları


Tip-2 bulanık kümeleme dalgacık sinir ağı yapısı ile EKG verilerinin sınıflandırılmasında Şekil 7.8’ de verilen yapı kullanılmıştır. Şekilden de görüleceği gibi tip-2 bulanık kümeleme algoritmasına girilen veride bir örüntüyü oluşturan örnek sayısı 200’ dür. Tez çalışmasında önerilen yapılarda bulanık kümeleme eğitim verisindeki en iyi örüntülerin seçilmesi amacıyla kullanıldığından, tip-2 bulanık kümeleme algoritmasından sonra oluşturulan yeni veri setinde de bir örüntü için örnek sayısı 200’ dür. Şekil 7.8’ verilen ve EKG verilerinin sınıflandırılması için gerçekleştirilen yapıda ayrık dalgacık dönüşümü kullanılarak örüntüdeki sınıflandırmayı olumsuz yönde etkileyecek örneklerin elimine edilmesi amaçlanmıştır. Gerçekleştiren uygulamada farklı sinyal boyutları için elde edilen ve ileride sunulacak olan sonuçlar incelenecek olursa bu gereksiz örneklerin sinyalden elimine edilmesinin ne kadar önemli olduğu görülecektir. Aynı zamanda ayrık dalgacık dönüşümü ile girişteki sinyal sıkıştırılmış olacağından daha az örnekle yapıdaki sinir ağı eğitilmektedir. Bu da hem eğitim hem de test aşamasında süre açısından çok büyük avantaj sağlamaktadır. Şekilde ayrık dalgacık dönüşümü sonrası eğitim yada test verisinde bir örüntüyü oluşturan örnek sayısı “W” ile gösterilmektedir. Burada “W” değeri dalgacık dönüşümü sonunda elde edilen en son yaklaştırma (approximation) parametresi sayısına eşittir.




Şekil 7.8 T2BKDSA ile EKG verilerinin sınıflandırılması

Tez çalışmasında bir örüntüyü oluşturan örnek sayısı 200' den 101, 52 ve 27 olmak üzere üç farklı değere düşürülmüştür. Bütün bu değerler için sistemde ayrık dalgacık dönüşümünden sonra yer alan yapay sinir ağının hiyerarşisi de değişecektir. Dolayısıyla dalgacık dönüşümünün seviyesi arttıkça kullanılacak yeni ağ yapısı için optimum gizli düğüm sayısının belirlenmesi gerekir. Bu uygulamada da tip-2 bulanık kümeleme algoritmasına ve yapay sinir ağına ait bulanıklık sabiti, öğrenme oranı ve momentum sabiti gibi parametrelerin Çizelge 7.2-7.4' de bulunan optimum değerleri kullanılmıştır. Dalgacık dönüşümü sadece 1 seviyede gerçekleştirildiğinde yaklaştırma parametresi sayısı, başka bir deyişle elde edilen örüntü örnek sayısı "101" olacaktır. Normal sinüs ritmi ve sinüs bradikardisi için karşılaştırma yapılması açısından 200 örneklilik orijinal bir sinyal ve aynı sinyalin dalgacık dönüşümü sonucunda elde edilen 101 örneklilik sıkıştırılmış hali Şekil 7.9' gösterilmiştir. Her iki sınıf için de orijinal sinyal ve sıkıştırılmış sinyal incelenecek olursa sinyaldeki veri kaybının sinyalin genel karakteristiğini etkilemediği görülür.


101 örnekten oluşan bir örüntü için ağ yapısı değişeceğinden yeni yapı T2BKDSA-1 yapısı olarak isimlendirilmiştir. Uygulamalarda tip-2 bulanık kümeleme ile elde edilen iki farklı boyutta (84 ve 100 setlik) eğitim verisi olduğundan simülasyonlar iki veri için de ayrı ayrı gerçekleştirilmiştir. 84 setlik eğitim verisi ile eğitilen T2BKDSA-1 yapısında optimum gizli düğüm değerinin bulunması için gerçekleştirilen simülasyonların sonuçları Çizelge 7.10 ve Çizelge 7.11' de sunulmuştur.




(a)



(b)



(c)



(d)

Şekil 7.9 (a) Normal sinüs ritmi-orijinal sinyal, (b)Normal sinüs ritmi-dalgacık dönüşümü ile elde edilen 101 örneklilik sinyal, (c)Sinüs bradikardisi-orijinal sinyal, (d) Sinüs bradikardisi- dalgacık dönüşümü ile elde edilen 101 örneklilik sinyal

Çizelge 7.10 T2BKDSA-1 yapısı için optimum gizli düğüm sayısının bulunması
(84 setlik eğitim verisi ile elde edilen sonuçlar)

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	$2.41 \cdot 10^{-7}$	0.028	27.66	10000
20	$8.65 \cdot 10^{-9}$	0.047	5.04	1172
30	$8.27 \cdot 10^{-9}$	0.048	7.98	1561
40	$7.55 \cdot 10^{-9}$	0.011	10.4	2083
50	$7.37 \cdot 10^{-9}$	0.044	10.04	1707
60	$7.77 \cdot 10^{-9}$	0.04	15.87	2621
70	0.69	0.006	62.3	10000
80	$7.39 \cdot 10^{-9}$	0.057	14.99	2096

Çizelge 7.11 T2BKDSA-1 yapısı için test verisi sınıflandırma sonuçları
(84 setlik eğitim verisi ile eğitilen sistemde)

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlut	AFib	ACoup	VTri	YS
10	20	5	5	15	2	16	14	15	14	16	15	14	3
20	20	5	4	15	1	15	15	15	14	16	15	15	3
30	20	5	4	15	1	15	15	15	14	16	15	15	3
40	20	6	5	15	1	15	15	15	13	16	15	15	3
50	20	5	5	15	1	15	15	15	13	16	15	15	3
60	20	5	4	16	1	15	15	15	13	16	15	15	4
70	20	5	4	15	1	15	15	15	0	16	15	15	17
80	20	5	4	16	1	15	15	15	14	16	15	15	3

YS=Yanlış sınıflanan set (örüntü) sayısı

Çizelge 7.10 ve Çizelge 7.11 birlikte incelenecek olursa en düşük eğitim ve test hatası ile en iyi sınıflandırma sonucu gizli düğüm sayısı “40” olduğunda elde edilmiştir. Başka bir deyişle T2BKDSA-1 yapısı için optimum ağ yapısı 101:40:12’ dir. Test aşamasında; T2BKSA yapısından farklı olarak test verisi sadece sinir ağına sunulmaz. Test verilerinin ağa sunulabilmesi için öncelikle örnek sayısının azaltılması gerekir. Aksi halde test verisinde bir örüntüyü oluşturan örnek sayısı 200 olduğu için 101 giriş düğümüne sahip bir ağda test işlemi gerçekleştirilemez. Test verileri de öncelikle ayrık dalgacık dönüşümü ile sıkıştırılır. 101 örnek×152 set boyutlarına sahip yeni test verisi sinir ağına sunulur. Elde edilen test sınıflandırma sonuçları Çizelge 7.11’ de yer almaktadır. Buradan da görüleceği gibi optimum T2BKDSA-1 yapısında elde edilen minimum yanlış sınıflandırılan set sayısı “3” dür.

T2BKDSA-1 yapısında dalgacık dönüşümü ve sinir ağından oluşan yapıya tip-2 bulanık kümeleme algoritması ile elde edilen 100 setlik farklı bir eğitim seti sunulduğunda ağın optimum gizli düğüm sayısı değişmektedir. Gerçekleştirilen simülasyonların sonuçları Çizelge 7.12 ve Çizelge 7.13’ de sunulmuştur.

*Çizelge 7.12 T2BKDSA-1 yapısı için optimum gizli düğüm sayısının bulunması
(100 setlik eğitim verisi ile elde edilen sonuçlar)*

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	0.083	0.188	27.6	10000
20	$8.29.10^{-9}$	0.024	7.25	1780
30	$7.9.10^{-9}$	0.004	8.62	1749
40	$7.47.10^{-9}$	0.021	14.86	2913
50	0.75	0.036	61.23	10000
60	$7.65.10^{-9}$	0.023	20.4	2966
70	0.75	0.02	68.37	10000
80	$7.09.10^{-9}$	0.006	20.33	2471


*Çizelge 7.13 T2BKDSA-1 yapısı için test verisi sınıflandırma sonuçları
(100 setlik eğitim verisi ile eğitilen sistemde)*

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlut	AFib	ACoup	VTri	YS
10	20	5	5	15	1	16	12	17	14	15	15	14	6
20	20	5	4	15	1	15	15	15	14	16	15	15	3
30	20	5	4	16	1	15	15	15	14	16	15	15	3
40	20	6	4	15	1	15	15	15	13	16	15	15	4
50	20	5	4	15	1	15	15	15	14	16	15	0	18
60	20	5	4	16	1	15	15	15	13	16	15	15	4
70	20	5	4	15	1	15	15	15	13	16	0	15	19
80	20	5	4	15	1	15	15	15	14	16	15	15	3


YS=Yanlış sınıflanan set (örüntü) sayısı

Çizelge 7.13 ve Çizelge 7.14 incelenecek olursa; 100 setlik eğitim verisi ile eğitilen T2BKDSA-1 yapısında optimum ağ hiyerarşisi 101:30:12’ dir. Burada en önemli nokta yanlış sınıflandırılan set sayısı 84 setlik eğitim verisi ile eğitilen yapıda elde edildiği gibi “3” dır.


T2BKDSA yapısında dalgacık dönüşümü 2 seviyeli olarak gerçekleştirilirse bu durumda bir örüntüyü oluşturan örnek sayısı yani son seviyede elde edilen yaklaştırma parametrelerinin sayısı “52” olacaktır. Bu durumda dalgacık dönüşümü uygulanmış ve sıkıştırılmış verilerin sınıflanacağı ağ yapısında giriş düğüm sayısı da 52 olacaktır. Ancak veri değiştiği için söz konusu ağ için optimum hiyerarşi de değişecektir. Bu durumda oluşan 52 giriş düğümlü yapı T2BKDSA-2 yapısı olarak isimlendirilmiştir. Normal sinüs ritmi ve sinüs bradikardisi olmak üzere iki sınıf için dalgacık dönüşümü sonucunda elde edilen 52 örneklik sinyallerin çizimi Şekil 7.10’ da verilmiştir. Bu sıkıştırılmış sinyaller Şekil 7.9’ daki orijinal halleri ile karşılaştırılırsa, sıkıştırma sonucunda oluşan veri kaybının sinyalin özelliklerini ve genel şeklini değiştirmedeği görülebilir. Bu sebepten dalgacık dönüşümü literatürde de en az kayıpla sıkıştırma yapılabilen özellik çıkarma tekniği olarak kullanılır.



(a)



(b)



Şekil 7.10 (a)Normal sinüs ritmi-orijinal sinyal, (b)Normal sinüs ritmi-dalgacık dönüşümü ile elde edilen 52 örneklik sinyal, (c)Sinüs bradikardisi-orijinal sinyal, (d) Sinüs bradikardisi- dalgacık dönüşümü ile elde edilen 52 örneklik sinyal

Optimum T2BKDSA-2 yapısının bulunması için 84 setlik eğitim verisi ile gerçekleştirilen simülasyonların sonuçları Çizelge 7.14 ve Çizelge 7.15’ de verilmiştir. Çizelgeler birlikte incelenecek olursa optimum gizli düğüm sayısının “20” olarak elde edildiği ve minimum yanlış sınıflandırılan set sayısının “1” olduğu görülecektir.

Çizelge 7.14 T2BKDSA-2 yapısı için optimum gizli düğüm sayısının bulunması
(84 setlik eğitim verisi ile elde edilen sonuçlar)

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	0.49	0.127	22.5	10000
20	8.67.10⁻⁹	0.05	5.66	1497
30	7.84.10 ⁻⁹	0.015	7.29	1439
40	7.33.10 ⁻⁹	0.027	7.28	1307
50	7.23.10 ⁻⁹	0.068	7.47	1287
60	7.71.10 ⁻⁹	0.031	13.1	2409
70	7.58.10 ⁻⁹	0.038	12.5	2047
80	7.07.10 ⁻⁹	0.038	13.7	2085

Çizelge 7.15 T2BKDSA-2 yapısı için test verisi sınıflandırma sonuçları
(84 setlik eğitim verisi ile eğitilen sistemde)

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlut	AFib	ACoup	VTri	YS
10	20	7	2	16	1	14	15	15	12	14	15	10	15
20	20	5	5	15	1	16	15	15	15	15	15	15	1
30	20	5	4	15	1	15	15	15	13	16	15	15	4
40	20	5	4	15	2	15	15	15	13	16	15	15	3
50	20	6	5	15	2	15	15	15	13	16	15	15	2
60	20	5	4	15	1	15	15	15	13	16	15	15	4
70	20	5	4	15	2	15	15	15	13	16	15	15	3
80	20	5	4	15	1	15	15	15	13	16	15	15	4

YS=Yanlış sınıflanan set (örüntü) sayısı

Aynı şekilde 100 setlik eğitim verisi kullanılarak T2BKDSA-2 yapısında optimum gizli düğüm sayısının bulunması için gerçekleştirilen iterasyonların sonuçları Çizelge 7.16 ve Çizelge 7.17’ de sunulmuştur. Çizelgelerden de görüleceği gibi tip-2 bulanık kümeleme ile elde edilen 100 setlik eğitim verisi kullanıldığında en iyi sınıflandırma sonuçları “50” gizli düğüm sayısı için bulunmuştur. Fakat 84 setlik eğitim verisi kullanıldığında optimum T2BKDSA-2 yapısında minimum yanlış sınıflandırılan set sayısı “1” olarak elde edilirken, burada yanlış sınıflandırılan set sayısı en az “3” e düşmüştür.

Çizelge 7.16 T2BKDSA-2 yapısı için optimum gizli düğüm sayısının bulunması
(100 setlik eğitim verisi ile elde edilen sonuçlar)

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	$9.84.10^{-9}$	0.07	17.37	6570
20	0.083	0.054	7.91	2246
30	$7.61.10^{-9}$	0.019	10.43	2732
40	$7.98.10^{-9}$	0.041	9.16	1836
50	$7.73.10^{-9}$	0.029	8.17	1391
60	0.75	0.034	57.18	10000
70	$7.43.10^{-9}$	0.047	12.63	1927
80	2.33	0.042	67.9	10000


Çizelge 7.17 T2BKDSA-2 yapısı için test verisi sınıflandırma sonuçları
(100 setlik eğitim verisi ile eğitilen sistemde)

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlut	AFib	ACoup	VTri	YS
10	20	5	4	15	1	15	15	15	13	16	15	15	4
20	20	5	4	15	1	15	15	15	14	16	15	10	8
30	20	5	5	16	1	15	15	15	13	16	15	15	3
40	20	5	4	15	2	15	15	15	13	16	15	15	3
50	20	5	4	15	3	15	15	15	13	16	15	15	3
60	20	6	4	15	1	15	15	15	13	16	0	15	19


70	20	6	4	16	2	15	15	15	13	16	15	15	3
80	0	5	4	16	2	15	15	0	13	16	0	15	53

YS=Yanlış sınıflanan set (örüntü) sayısı


T2BKDSA yapısında dalgacık dönüşümü üçüncü seviyeye ilerletilirse, son seviyede elde edilen yaklaştırma katsayılarının sayısı 27' dir.




(a)



(b)



(c)



(d)

Şekil 7.11 (a)Normal sinüs ritmi-orijinal sinyal, (b)Normal sinüs ritmi-dalgacık dönüşümü ile elde edilen 27 örneklik sinyal, (c)Sinüs bradikardisi-orijinal sinyal, (d) Sinüs bradikardisi- dalgacık dönüşümü ile elde edilen 27 örneklik sinyal

Başka bir ifadeyle dalgacık dönüşümünün girişine verilen 200 örnekten oluşan orijinal sinyalin 27 örneklelik sıkıştırılmış hali elde edilmiş olur (Şekil 7.11). Bu durumda yapay sinir ağı giriş düğüm sayısı 27 olacaktır. Oluşan yeni yapı T2BKDSA-3 olarak isimlendirilmiştir. Orijinal sinyal ile eğitilen bir ağıdaki süre ile 27 örneğe sıkıştırılmış bir sinyal ile eğitilen bir ağıdaki süre karşılaştırılırsa dalgacık dönüşümünün sağladığı avantaj daha belirgin olarak görülecektir. Burada da simülasyonlar öncelikle 84 setlik eğitim verisi ile gerçekleştirilmiştir. Elde edilen eğitim/test hatası sonuçları ile sınıflandırma sonuçları Çizelge 7.18 ve Çizelge 7.19’ da sunulmuştur. T2BKDSA-3 yapısında, çizelgelerden de görüleceği gibi, optimum ağ yapısı 27:40:12 olarak bulunmuştur.

*Çizelge 7.18 T2BKDSA-3 yapısı için optimum gizli düğüm sayısının bulunması
(84 setlik eğitim verisi ile elde edilen sonuçlar)*

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	0.099	0.075	21.7	10000
20	0.099	0.022	12.77	4445
30	$7.59 \cdot 10^{-9}$	0.04	7.64	1690
40	$7.34 \cdot 10^{-9}$	0.028	7.31	1885
50	0.099	0.063	14.25	3299
60	$7.71 \cdot 10^{-9}$	0.031	10.38	1942
70	$7.64 \cdot 10^{-9}$	0.028	17.85	3516
80	3.07	0.022	53.26	10000

*Çizelge 7.19 T2BKDSA-3 yapısı için test verisi sınıflandırma sonuçları
(84 setlik eğitim verisi ile eğitilen sistemde)*

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlut	AFib	ACoup	VTri	YS
10	20	5	4	16	2	15	15	15	14	15	15	10	7
20	20	5	4	15	1	15	15	15	14	16	15	10	8
30	20	6	4	15	1	15	15	15	13	16	15	15	4
40	20	5	4	15	2	15	15	15	14	16	15	15	2
50	20	5	5	15	2	15	15	15	14	16	15	10	6
60	20	5	4	15	1	15	15	15	14	16	15	15	3
70	20	5	4	15	2	15	15	15	14	16	15	15	2
80	0	5	4	15	3	15	15	0	14	0	15	0	66

YS=Yanlış sınıflanan set (örüntü) sayısı

Çizelge 7.19 incelenecek olursa minimum yanlış sınıflandırılan set sayısı 40 gizli düğümde “2” olarak elde edilmiştir. Gizli düğüm sayısı 70 olarak alındığında da minimum yanlış sınıflandırılan set sayısı 2 olarak elde edilmiştir. Ancak Çizelge 7.18 incelenecek olursa 70 gizli düğümüne sahip bir ağın minimuma daha fazla iterasyon

sayısı ile yakınsadığı görülecektir. 40 gizli düğümde durdurma kriteri 1885 iterasyonda alındığı halde 70 gizli düğümde ancak 3516 iterasyonda bu kriter sağlanabilmiştir.

T2BKDSA-3 yapısında 100 setlik eğitim verisi kullanılarak gerçekleştirilen simülasyonların sonuçları Çizelge 7.20 ve Çizelge 7.21’ de sunulmuştur. Çizelge 7.20 incelenecek olursa en düşük hata ve iterasyon süresi 60 gizli düğümlü ağda elde edilmiştir. Ancak Çizelge 7.21’ de görüldüğü gibi 60 gizli düğümlü ağda yanlış sınıflandırılan set sayısı “3” dür. Test verisi sınıflandırma sonuçları ağın sınıflandırma kabiliyetini daha belirgin bir şekilde ortaya koyar. Bu fikre uygun olarak, yanlış sınıflandırılan set sayısının “1” olarak elde edildiği 20 gizli düğüm sayısının seçilmesi daha uygundur. Bu durumda, T2BKDSA-3 yapısında 100 setlik eğitim verisi kullanıldığında optimum ağ yapısı 27:20:12 olarak belirlenmiş olur.

*Çizelge 7.20 T2BKDSA-3 yapısı için optimum gizli düğüm sayısının bulunması
(100 setlik eğitim verisi ile elde edilen sonuçlar)*

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	$9.11.10^{-9}$	0.023	14.18	6088
20	$8.18.10^{-9}$	0.039	11	3789
30	$7.45.10^{-9}$	0.031	7.79	1908
40	$7.15.10^{-9}$	0.036	9.08	1924
50	0.083	0.031	17.26	3668
60	$7.54.10^{-9}$	0.012	9.99	1721
70	0.58	0.011	52.11	10000
80	4.16	0.01	55.17	10000


*Çizelge 7.21 T2BKDSA-3 yapısı için test verisi sınıflandırma sonuçları
(100 setlik eğitim verisi ile eğitilen sistemde)*

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlut	AFib	ACoup	VTri	YS
10	20	5	4	16	2	15	15	16	13	15	15	15	3
20	20	5	4	15	2	15	15	15	15	15	15	15	1
30	20	5	4	15	1	15	15	15	13	16	15	15	4
40	20	5	4	15	2	15	15	15	14	16	15	15	2
50	20	5	5	15	2	15	15	15	14	16	15	10	6
60	20	5	4	15	1	15	15	15	14	16	15	15	3
70	20	5	0	15	2	15	15	15	14	16	15	15	6
80	0	5	4	15	0	15	0	15	0	16	0	0	83

YS=Yanlış sınıflanan set (örüntü) sayısı

7.6.3. Tip-2 Bulanık Kümeleme-Temel Bileşen Analizi-Yapay Sinir Ağı

Elektrokardiyografi verilerinin sınıflandırılması problemi için oluşturulan Tip-2 Bulanık Kümeleme-Temel Bileşen Analizi-Yapay Sinir Ağı (T2BK-TB-YSA) yapısı Şekil 7.12’ de sunulmuştur.



Şekil 7.12 T2BK-TB-YSA ile EKG verilerinin sınıflandırılması

Şekil 7.12’ den de görüleceği gibi, T2BK-TB-YSA yapısında, tip-2 bulanık kümeleme algoritması ile elde edilen en iyi örüntülerden oluşturulmuş 200 örneklik yeni eğitim verisi üzerinde temel bileşen analizi ile özellik çıkarma gerçekleştirilmektedir. Temel bileşen analizi, dalgacık dönüşümü gibi veri kaybının minimuma indirgendiği bir metot değildir. Temel bileşen analizinde giriş verisinin özvektörleri ve özdeğerleri hesaplanarak ilk “TB” özdeğer seçilir. TB değeri giriş verisinde bir örüntüyü oluşturan örnek sayısından az olmak kaydıyla istenildiği gibi seçilebilir. Seçilen TB değeri, T2BK-TB-YSA yapısında sınıflandırmada kullanılacak yapay sinir ağı için giriş düğümü sayısına eşit olacaktır. Optimum gizli düğüm sayısı ise her TB değeri için yeniden bulunmalıdır.

Uygulamada temel bileşen analizi ile özellik çıkarma prosesinin gerçekleştirilmesinde 100, 50, 20 ve 10 olmak üzere 4 farklı TB değeri seçilmiştir. TB=100 olarak alındığında sınıflandırmada kullanılacak YSA' nın da giriş düğüm sayısı 100 olacaktır. 100 giriş düğümlü yeni ağ yapısı T2BK-TB-YSA-1 olarak isimlendirilmiştir. T2BK-TB-YSA-1 yapısında tip-2 bulanık c-ortalamlar kümeleme algoritması ile elde edilen 84 setlik eğitim verisi ile gerçekleştirilen simülasyonların sonuçları Çizelge 7.22 ve Çizelge 7.23' de sunulmuştur. İlk olarak en düşük eğitim ve test hatasının elde edilmesi düşünülse de, asıl amaç en iyi sınıflandırma sonucunun en kısa sürede elde edilmesidir. Sınıflandırma sonucunun iyi olmaması durumunda süre göz ardı edilmesi gereken bir parametredir. Bu sebepten Çizelge 7.22' de düşük hata ve süre kriterini sağlayan pek çok gizli düğüm sayısı olmasına rağmen, Çizelge 7.23' de yanlış sınıflandırılan set sayısına göre, "10 gizli düğüm" ağ için optimum değerdir. Elbette yanlış sınıflandırılan set sayısının 86 olması T2BK-TB-YSA-1 yapısının EKG sınıflandırma probleminde başarılı olamadığını göstermektedir. 84 setlik eğitim verisi ile iyi sonuçlar alınmadığı için 100 setlik eğitim verisi ile aynı yapıda çalışılmamıştır.

*Çizelge 7.22 T2BK-TB-YSA-1 yapısı için optimum gizli düğüm sayısının bulunması
(84 setlik eğitim verisi ile elde edilen sonuçlar)*

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	1.23.10⁻⁸	0.66	20.96	8013
20	1.01.10 ⁻⁸	0.595	4.76	1121
30	9.07.10 ⁻⁹	0.39	5.34	1092
40	8.48.10 ⁻⁹	0.43	7.65	1300
50	7.88.10 ⁻⁹	0.35	7.17	1239
60	7.5.10 ⁻⁹	0.39	17.71	3014

*Çizelge 7.23 T2BK-TB-YSA-1 yapısı için test verisi sınıflandırma sonuçları
(84 setlik eğitim verisi ile eğitilen sistemde)*

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlu	AFib	ACoup	VTri	YS
10	2	2	1	21	4	4	0	7	7	4	7	26	86
20	2	0	0	9	6	1	1	12	3	2	3	6	111
30	2	0	1	12	1	1	0	11	0	0	2	7	115
40	1	0	0	9	0	2	0	11	1	1	2	4	121
50	0	0	1	7	0	2	0	12	1	3	0	5	121
60	2	0	0	11	0	1	0	12	0	1	1	7	117

YS=Yanlış sınıflanan set (örüntü) sayısı

TB=50 olarak alındığında oluşacak yeni yapı T2BK-TB-YSA-2 yapısı olarak isimlendirilmiştir. T2BK-TB-YSA-2 yapısında 84 setlik eğitim verisi ile elde edilen sonuçlar Çizelge 7.24’ de ve Çizelge 7.25’ de sunulmuştur. Çizelgeler birlikte incelenecek olursa, en az yanlış sınıflandırılan set sayısının, gizli düğüm sayısı “10” olarak alındığında elde edildiği görülebilir. Ancak elektrokardiyografi sınıflandırma problemi için 152 örüntülük bir test verisinde “36” örüntünün yanlış sınıflandırılması oldukça kötü bir sonuçtur.

*Çizelge 7.24 T2BK-TB-YSA-2 yapısı için optimum gizli düğüm sayısının bulunması
(84 setlik eğitim verisi ile elde edilen sonuçlar)*

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	1.17.10⁻⁸	0.34	11.28	4677
20	9.12.10 ⁻⁹	0.42	4.6	1225
30	8.55.10 ⁻⁹	0.37	5.29	1217
40	7.98.10 ⁻⁹	0.33	4.82	991
50	7.29.10 ⁻⁹	0.46	7.12	1160

*Çizelge 7.25 T2BK-TB-YSA-2 yapısı için test verisi sınıflandırma sonuçları
(84 setlik eğitim verisi ile eğitilen sistemde)*

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlu	AFib	ACoup	VTri	YS
10	16	5	5	22	4	9	1	18	9	13	6	15	36
20	17	5	2	14	2	8	0	15	9	9	12	16	44
30	15	5	5	15	0	7	0	15	7	6	13	17	49
40	18	5	4	14	0	5	0	15	8	5	14	18	48
50	18	5	4	14	0	6	1	15	6	4	5	16	59

YS=Yanlış sınıflanan set (örüntü) sayısı

TB=20 olarak seçildiğinde 200 örneklik örüntülerden oluşan eğitim ve test verisinde örnek sayısı 20’ ye düşmüş olur. Böylece ağı eğitim ve test süresi oldukça azalmıştır. TB değeri 20 olarak seçildiğinde oluşan yeni ağ yapısı (T2BK-TB-YSA-3) için optimum gizli düğüm sayısının bulunması için gerçekleştirilen simülasyonların sonuçları Çizelge 7.26 ve Çizelge 7.27’ de sunulmuştur. Temel bileşen analizi ile TB=100 ve 50 seçilerek gerçekleştirilen özellik çıkarma proseslerinde başarı sağlanamadığı, yukarıdaki çizelgelerde sunulan test sınıflandırma sonuçları ile gösterilmiştir. TB=20 için elde edilen sonuçlar incelenecek olursa, yanlış sınıflandırılan set sayısının minimum değerinin “8” olduğu görülür. Bu da yukarıda elde edilen değerlere göre daha başarılı bir sonuçtur.

Çizelge 7.26 T2BK-TB-YSA-3 yapısı için optimum gizli düğüm sayısının bulunması
(84 setlik eğitim verisi ile elde edilen sonuçlar)

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	9.44.10⁻⁹	0.28	4	1269
20	8.41.10 ⁻⁹	0.21	3.79	1008
30	7.49.10 ⁻⁹	0.22	4.25	1048
40	7.04.10 ⁻⁹	0.18	4.82	1088
50	7.69.10 ⁻⁹	0.21	5.4	1096
60	7.28.10 ⁻⁹	0.18	7.02	1125
70	0.69	0.23	45.9	10000
80	7.10 ⁻⁹	0.19	12.15	2301

Çizelge 7.27 T2BK-TB-YSA-3 yapısı için test verisi sınıflandırma sonuçları
(84 setlik eğitim verisi ile eğitilen sistemde)

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlu	AFib	ACoup	VTri	YS
10	19	6	5	16	2	15	13	15	15	10	15	18	8
20	20	5	7	16	1	12	10	15	11	14	17	16	14
30	19	6	7	16	2	14	11	15	12	14	14	15	11
40	20	5	6	16	2	15	11	15	11	14	16	17	9
50	20	5	7	16	2	13	11	15	12	14	18	16	10
60	20	5	6	16	2	15	12	15	11	15	13	17	9
70	20	6	6	16	2	15	11	15	11	0	16	17	23
80	20	6	6	16	1	15	11	15	11	14	13	17	12

YS=Yanlış sınıflanan set (örüntü) sayısı

TB=10 olarak seçildiğinde oluşan yeni yapı T2BK-TB-YSA-4 olarak isimlendirilmiştir ve bu yapıya ait optimum gizli düğüm sayısının bulunması için gerçekleştirilen simülasyonların sonuçları Çizelge 7.28 ve Çizelge 7.29’ da görülmektedir. T2BK-TB-YSA-4 yapısında 84 setlik eğitim verisi ile gerçekleştirilen sınıflandırmanın sonuçları söz konusu çizelgelerden incelenecek olursa 10:50:12 ağ yapısının optimum yapı olarak belirlendiği görülebilir.

Çizelge 7.28 T2BK-TB-YSA-4 yapısı için optimum gizli düğüm sayısının bulunması
(84 setlik eğitim verisi ile elde edilen sonuçlar)

H	E.H.(%)	T.H.(%)	Süre	İterasyon
10	9.28.10 ⁻⁹	0.083	17.5	7982
20	8.17.10 ⁻⁹	0.097	4.08	1192
30	7.12.10 ⁻⁹	0.185	5.82	1713
40	1.68	0.044	31.7	10000
50	7.57.10⁻⁹	0.14	5.09	1042
60	0.29	0.066	27.13	6296
70	0.69	0.15	44.55	10000
80	0.69	0.12	49.12	10000

*Çizelge 7.29 T2BK-TB-YSA-4yapısı için test verisi sınıflandırma sonuçları
(84 setlik eğitim verisi ile eğitilen sistemde)*

H	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlu	AFib	ACoup	VTri	YS
10	21	5	8	13	3	15	13	15	13	15	15	15	6
20	20	5	6	15	2	15	11	15	14	16	10	19	10
30	21	6	6	15	3	15	12	15	12	16	14	14	7
40	20	0	6	14	3	15	13	15	14	16	0	9	30
50	21	6	6	15	3	15	13	15	13	16	15	14	4
60	20	5	6	15	3	15	13	15	14	16	15	9	9
70	21	5	6	16	2	15	11	15	0	16	15	16	15
80	21	5	6	15	3	15	11	15	14	16	15	0	20

YS= Yanlış sınıflanan set (örüntü) sayısı

50 gizli düğüm sayısı ile gerçekleştirilen sınıflandırma sonucunda yanlış sınıflandırılan set sayısında minimum değere ulaşılmıştır. Çizelge 7.29’ dan da görüleceği gibi test verisi sınıflandırma sonucunda bulunan 4 değeri, temel bileşen analizi ile özellik çıkarma gerçekleştirildiğinde elektrokardiyografi sınıflandırma problemi için en düşük yanlış sınıflandırılan örüntü sayısıdır.

7.7. Gerçekleştirilen Hasta Kayıtlarının Sınıflandırma Sonuçları

Tez çalışması kapsamında Selçuk Üniversitesi Tıp Fakültesi Kardiyoloji Yoğun Bakım Ünitesinde hastalardan kayıtlar alınmıştır. Çalışmada şu ana kadar sunulan yapılar ve bu yapılarla elde edilen sonuçlar incelenecek olursa, 84 setlik eğitim verisi ile eğitilen T2BKDSA yapısında optimum test sonuçlarına ulaşıldığı görülür. T2BKDSA yapısında optimum sonuçların elde edildiği durumdaki ağ parametreleri (ağırlıklar, biaslar, ağ özellikleri vb.) kayıt edilmiştir. Kayıt edilen ağ parametreleri kullanılarak hasta kayıtları bu optimum ağda sınıflandırılmıştır. Çizelge 7.30’ de hasta bilgileri ve elde edilen sınıflandırma sonuçları detaylı olarak sunulmuştur. 45 kayıt için yaş ortalaması 47.2’ dir.

Çizelge 7.30 Hasta kayıtlarının sınıflandırma sonuçları

No	E/K	Yaş	Örnek Sayısı/ Set Sayısı	Q ₁	Q ₂	Q ₃	Q ₄	Q ₅	Q ₆	Q ₇	Q ₈	Q ₉	Q ₁₀	Q ₁₁	Q ₁₂	?	Hata %
1	K	47	150000/ 45	0	0	0	1	1	0	0	7	0	0	0	12	24	0.87
2	K	47	130000/ 35	0	0	0	0	6	0	0	0	0	0	0	3	26	0.97
3	K	47	140000/ 48	0	0	1	0	7	0	0	0	8	1	0	3	28	1.31
4	K	56	60000/ 16	0	0	0	0	0	0	0	7	0	0	0	0	9	1.81
5	K	47	60000/ 15	0	0	0	0	0	0	1	0	0	0	5	0	9	0.53
6	E	24	140000/ 26	0	0	0	0	0	0	0	0	0	0	4	0	22	1.69
7	E	24	140000/ 30	0	0	0	0	0	0	0	0	0	0	0	30	30	1.73
8	E	24	80000/ 15	0	0	0	0	0	0	0	0	0	0	15	0	15	0.33
9	K	52	130000/ 32	0	0	0	0	0	0	0	0	0	0	27	5	0	0.95
10	K	50	110000/ 28	0	0	0	0	0	0	0	0	0	0	28	0	0	1.05
11	K	35	110000/ 28	0	0	0	0	0	0	0	1	0	0	12	5	10	1.06
12	K	35	110000/ 27	0	0	0	0	0	0	0	0	0	0	17	0	10	1.79
13	E	62	120000/ 28	0	0	0	0	0	0	0	0	0	0	28	0	0	0.09
14	E	55	140000/ 33	0	0	0	0	0	0	0	0	0	0	33	0	0	0.89
15	E	55	55000/ 17	0	0	1	0	0	0	0	2	0	0	11	1	2	1.04
16	E	55	45000/ 11	0	0	0	0	0	0	0	0	0	0	8	3	0	0.79

No	E/K	Yaş	Örnek Sayısı/ Set Sayısı	N	Br	T	S	Apc	P	R	L	Afib	Aflt	ACoup	Vtre	?	Hata %
17	K	47	55000/ 13	0	0	0	0	0	0	0	0	0	0	3	0	10	0.63
18	E	63	140000/ 39	0	0	0	0	0	0	1	0	0	0	5	11	22	1.18
19	K	39	210000/ 55	0	0	2	0	0	0	1	23	0	0	1	22	6	4.11
20	K	39	110000/ 29	0	0	0	0	0	0	0	12	0	0	0	15	2	4.44
21	K	37	150000/ 52	0	0	0	0	0	0	52	0	0	0	0	0	0	0.09
22	K	37	120000/ 38	0	0	1	0	0	0	1	0	0	0	0	0	36	0.54
23	E	23	150000/ 52	0	0	0	0	0	0	0	25	0	0	0	0	27	2.68
24	K	37	150000/ 42	0	0	0	0	0	0	0	9	0	0	9	6	18	1.21
25	K	37	140000/ 40	0	0	0	0	0	0	0	0	1	0	22	7	10	1.69
26	K	47	120000/ 32	0	0	2	0	3	0	0	0	3	0	0	4	20	1.28
27	E	76	15000/ 57	5	0	0	4	0	0	0	0	0	1	10	16	21	0.92
28	E	33	15000/ 44	0	0	31	1	0	0	1	0	0	0	4	0	7	1.34
29	E	58	15000/ 17	0	0	0	0	0	0	0	0	0	9	0	1	7	0.05
30	K	79	15000/ 24	1	0	0	0	0	0	0	1	10	0	1	7	4	1.23
31	E	77	15000/ 36	0	0	0	0	0	0	0	0	0	0	36	0	0	0.12
32	E	46	15000/ 57	5	0	0	4	0	0	0	0	0	1	10	16	21	0.92
33	K	69	15000/ 54	0	0	0	0	0	0	26	0	0	0	7	1	20	1.38
34	K	29	15000/ 53	51	0	0	0	0	0	0	0	0	0	0	0	2	0.53
35	K	29	15000/ 54	40	0	0	0	0	0	0	0	12	0	0	0	2	1.06
36	E	20	45000/ 153	0	0	4	0	0	0	0	0	0	0	116	0	33	0.37
37	K	20	45000/ 183	49	0	0	3	0	0	0	4	5	0	0	57	65	0.85
38	E	21	45000/ 161	1	0	0	1	0	0	0	0	1	0	0	130	28	0.92
39	K	20	45000/ 132	0	0	0	119	0	0	0	0	0	0	1	2	10	0.95
40	E	31	45000/ 133	0	0	0	0	0	0	0	0	0	0	130	0	3	0.14
41	E	20	45000/ 167	86	0	0	0	0	0	0	3	20	0	3	1	54	0.79
42	E	21	45000/ 134	0	15	0	43	0	0	0	0	0	0	22	0	54	0.94
43	E	21	45000/ 158	0	0	0	16	0	0	0	0	0	0	46	2	94	1.29
44	E	21	45000/ 139	0	0	3	4	0	0	0	0	0	0	69	2	61	1.22
45	E	20	45000/ 189	0	0	153	0	0	0	0	0	0	0	0	0	36	0.94
2816 set				238	15	198	196	17	0	83	94	60	12	683	362	858	1.12

Çizelgeden de görüleceği gibi, 2816 periyotluk EKG kaydından 238 set normal sinüs ritmi olarak sınıflandırılmıştır. 83 set sağ dal bloku ve 94 set sol dal bloku olarak sınıflandırılmıştır. Optimum ağı sunulan kayıtlarda 60 set atrial fibrilasyon ve 12 set atrial flutter olarak tanımlanmıştır. 858 set ise eğitim veri kümesi içindeki herhangi bir sınıfa ait olmadığı için sınıflandırılamamıştır. 45 kayıt için ortalama test hatası % 1.12 olarak bulunmuştur.

7.8. Tez Çalışmasında Önerilen Yapıların Yapay Sinir Ağları ve Geleneksel Bulanık Kümeleme ile Gerçekleştirilen Yapılarla Karşılaştırılması

Tez çalışmasında tip-2 bulanık kümeleme algoritması, dalgacık dönüşümü, temel bileşen analizi ve yapay sinir ağları ile gerçekleştirilen üç sinir ağı yapısı (T2BKSA, T2BKDSA, T2BK-TB-YSA) daha önceki çalışmalarda gerçekleştirilen bulanık kümeleme sinir ağı, bulanık kümeleme dalgacık sinir ağı ve yapay sinir ağı ile karşılaştırılmıştır.

Bulanık kümeleme sinir ağı (BKSA), Ceylan (2004) yüksek lisans tez çalışmasında gerçekleştirilmiştir. Ayrıca yapı ile elde edilen sonuçlar Özbay ve ark. tarafından 2006’ da “A Fuzzy Clustering Neural Network Architecture for Classification of ECG Arrhythmias” isimli yayında sunulmuştur. Bu yapıda bulanık kümeleme geleneksel (tip-1) bulanık c-ortalamlar kümeleme algoritması ile yapılmıştır. Tip-1 bulanık kümeleme ile elde edilen yeni eğitim seti yapay sinir ağlarında sınıflandırılmıştır.

Bulanık kümeleme dalgacık sinir ağı (BKDSA) yapısı ise tip-2 bulanık kümeleme dalgacık sinir ağı yapısı ile aynıdır. Sadece BKDSA yapısında geleneksel (tip-1) bulanık c-ortalamlar kümeleme algoritması kullanılmıştır. BKDSA yapısında, tip-1 bulanık kümeleme algoritması ile elde edilen yeni eğitim seti üzerinde dalgacık dönüşümü kullanılarak özellik çıkarma işlemi uygulanmıştır. Dalgacık dönüşümü ile çıkarılmış özelliklerden oluşturulan eğitim seti YSA’ da sınıflandırılmıştır.

Tez çalışmasında önerilen yapıların, BKSA, BKDSA ve YSA ile karşılaştırması Çizelge 7.31 ve Çizelge 7.32’ de sunulmuştur.

Çizelge 7.31 Yapılarla elde edilen hata sonuçlarının karşılaştırılması
(84 setlik eğitim verisi ile elde edilen sonuçlar)

No	Yapı	Hiyerarşi	E.H.(x10 ⁻⁹ - %)	T.H.(%)	İterasyon
1	T2BKSA	200:50:12	7.19	0.016	1274
2	BKSA	200:50:12	7.33	0.004	1940
3	YSA	200:50:12	5.88	0.043	1656
4	T2BKDSA-1	101:40:12	7.55	0.011	2083
5	BKDSA-1	101:40:12	7.55	0.031	2171
6	T2BKDSA-2	52:20:12	8.66	0.05	1497
7	BKDSA-2	52:20:12	8.55	0.044	1907
8	T2BKDSA-3	27:40:12	7.34	0.028	1885
9	BKDSA-3	27:40:12	7.52	0.026	1792

Çizelge 7.32 BKSA ile elde edilen sınıflandırma sonuçlar

No	NS	SB	VT	SA	APC	PB	RBB	LBB	AFlu	AFib	ACoup	VTri	YS
1	20	5	4	15	3	15	15	15	14	16	15	15	2
2	20	5	4	15	3	15	15	15	14	16	15	15	2
3	20	5	4	15	3	15	15	15	14	16	15	15	2
4	20	6	5	15	1	15	15	15	13	16	15	15	3
5	20	5	4	16	1	15	15	15	14	16	15	16	3
6	20	5	5	15	1	16	15	15	15	15	15	15	1
7	20	5	4	15	1	16	15	15	14	16	15	15	3
8	20	5	4	15	2	15	15	15	14	16	15	15	2
9	20	5	4	15	2	15	15	15	14	16	15	16	2

Çizelge 7.31’ de sunulan sonuçlar incelenecek olursa iterasyon sayısı bakımından en iyi sonucun T2BKSA yapısı ile elde edildiği görülür. Optimum ağ hiyerarşisi olarak seçilen 200:50:12 ile BKSA ve YSA yapılarında gerçekleştirilen eğitime ve test proseslerinin sonucunda daha yüksek iterasyon sayısı ve test hatası ile aynı sınıflandırma sonucuna ulaşılabilmiştir. Ayrıca elde edilen sonuçlar yanlış sınıflandırılan set sayısına göre değerlendirilecek olursa Çizelge 7.32’ de verildiği gibi en iyi sonucun T2BKDSA-2 yapısı ile elde edildiği görülür. T2BKDSA-2 yapısı ile ortak bütün parametreler aynı alınmak kaydıyla BKDSA-2 yapısında gerçekleştirilen eğitime ve test işlemleri sonucunda yanlış sınıflandırılan set sayısı 3 olarak elde edilmiştir.

8. TARTIŞMA

Literatürdeki telekardiyoloji çalışmaları incelendiğinde, genellikle kalp hastası olduğu kanıtlanmış kişilerin evde bakımlarına ve kalp durumlarının gözlenmesi üzerine gerçekleştirilmiş çalışmalar olduğu görülmektedir. Tez kapsamında önerilen telekardiyoloji sisteminde ise, amaç kalp rahatsızlığı olduğu henüz bilinmeyen, ama göğüs ağrısı, kalp sıkışması, kolda uyuşma vb. gibi kalp krizi şüphesi uyandırabilecek rahatsızlıklarla sağlık ocağına getirilen bir hastaya uzman tavsiyesi ışığında acil müdahalenin gerçekleştirilmesi ve sonrasında hastaya bir uzman kontrolünün sağlanması amaçlanmaktadır. Bu yönüyle projenin literatürdeki çalışmalar arasında orijinal bir yeri vardır.

Telekardiyoloji sisteminde, uzak bölgedeki hastanın hayati sinyallerinin, EKG ile araştırma hastanesindeki kardiyoloji uzmanlarına iletilmesi amaçlanmaktadır. Birçok vakada, pratisyen hekimin uzman doktor ile çabuk konsültasyon yapabilmesi, hasta için kritiktir. Ayrıca rahatsızlığın kalp krizine yol açan bir aritmi olup olmadığının birinci basamak bir sağlık kuruluşunda teşhisinin yapılması hasta açısından hayati önem taşıdığı kadar, hastanelerdeki yoğunluğun azaltılması açısından da oldukça önemlidir. Önerilen sistem sayesinde, birinci basamak sağlık kuruluşuna getirilen hastanın durumu incelenerek, hastaneye gitmesinin gerekip gerekmediği uzman fikri de alınarak belirlenebilmektedir.

Bilindiği gibi; ülkemiz nüfusunun bir bölümü kırsal alanlarda yada sağlık hizmetlerinin tam anlamıyla götürülemediği uzak bölgelerde yaşamaktadır. Bu bölgelerde yaşayan insanların, büyük sağlık kuruluşlarının kentlerde bulunmasından dolayı sağlık hizmetlerine ulaşımı zor olmaktadır. Kırsal bölgelerde bulunan sağlık ocakları, insanların sağlık ihtiyaçlarını belli imkânlar ölçüsünde karşılayabilmektedir. Bu anlamda, sunulan telekardiyoloji uygulaması ülkemizde özellikle kırsal ve kentsel alanlar arasındaki sağlık dağılımının eşitsizliğini giderebilecek olması açısından da oldukça önemlidir.

Tez çalışmasında gerçekleştirilen telekardiyoloji sistemini oluşturan en önemli adım EKG sinyallerinin doğru ve hızlı bir şekilde sınıflandırılmasıdır. Tez çalışmasında literatürde daha önce biyomedikal sinyallerin sınıflandırılmasında

kullanılmamış tip-2 bulanık kümeleme metodu kullanılarak gerçekleştirilen yeni bir sınıflayıcı önerilmiştir. Önerilen sınıflayıcının yapısına literatürde kullanılan dalgacık dönüşümü ve temel bileşen analizi gibi özellik çıkarma algoritmaları eklenerek sınıflama performansı artırılmış, elde edilen sonuçlar detaylı olarak sunulmuştur. Özellik çıkarma algoritmalarının kullanımında, literatürdeki benzer çalışmaların aksine tek bir özellik sayısına bağlı kalınmaksızın, sinyaller üzerinde pek çok farklı özellik sayısı ile sınıflandırma gerçekleştirilmiştir. Elde edilen sonuçlar incelenerek EKG sinyali için en uygun özellik çıkarma adımı ve örnek sayısı tespit edilmeye çalışılmıştır. Ayrıca gerçekleştirilen yapı, literatürde gerçekleştirilen yapılarla ve çalışmalarla karşılaştırıldığında; EKG sinyallerinin sınıflandırılması konusunda aritmi sayısı bakımından en kapsamlı çalışma olduğu ve hata bakımından en az iterasyon sayısı ile eğitilen ağda en iyi ortalama tanıma oranının elde edildiği yapı olduğu görülmüştür. Karşılaştırma sonuçları tez çalışmasının 6.8 ve 8. bölümünde sunulan tablolarla verilmiştir.

Tez çalışmasında gerçekleştirilen telekardiyoloji sisteminin temel öğelerinden biri olan haberleşme kısmının web sayfası ile gerçekleştirilerek sağlık ocağı ile araştırma hastanesi arasında interaktif haberleşme imkânının sağlanması daha önce literatürde sunulmamış bir uygulamadır.

9. SONUÇLAR VE ÖNERİLER

9.1. Sonuçlar

Bu tez çalışmasında, özellik çıkarma algoritmaları ve yapay sinir ağları kullanılarak bir telekardiyoloji sistemi tasarlanmıştır. Gerçekleştirilen sistemde, göğüs ağrısı, kalp sıkışması, kolda uyuşma vb. gibi kalp krizi şüphesi uyandırabilecek rahatsızlıklarla sağlık ocağına getirilen bir hastaya uzman tavsiyesi ışığında acil müdahalenin gerçekleştirilmesi ve sonrasında hastaya bir uzman kontrolünün sağlanması amaçlanmıştır.

Önerilen telekardiyoloji sistemi, tip-2 bulanık kümeleme algoritması ve yapay sinir ağı kullanılarak gerçekleştirilen bir EKG sınıflama sistemi ve haberleşme bloğundan oluşmaktadır. Tez çalışması kapsamında üç farklı EKG sınıflandırma ağı önerilmiştir. Bu ağların gerçekleştirilmesinde özellik çıkarma algoritması olarak dalgacık dönüşümü ve temel bileşen analizi metotları kullanılmıştır. Özellik çıkarma algoritmalarının kullanılmasının amacı bir verinin sınıflandırılmasında ağın karar verme kabiliyetini artırmak ve karar için kullanılan süreyi azaltmaktır.

Önerilen ilk EKG sınıflandırma sistemi bulanık kümeleme ve yapay sinir ağının kaskat bağlanmasıyla gerçekleştirilmiştir. Önerilen sınıflandırma sistemi tez çalışmasında “T2BKSA” olarak isimlendirilmiştir. Yapıda tip-2 bulanık kümeleme algoritması kullanılarak, yapay sinir ağının eğitimi için oluşturulan eğitim verisi optimize edilmiştir. Bir başka deyişle, tip-2 bulanık kümeleme algoritması ile eğitim setindeki her aritmi sınıfının içerisinde söz konusu aritmeyi en iyi temsil eden örüntüler seçilerek, diğer örüntüler elimine edilmiştir. Seçilen örüntülerden oluşturulan yeni eğitim setinin örüntü sayısı ilk sete göre yaklaşık %37 oranında azaldığı için ağın eğitim süresi kısalmıştır. Ayrıca eğitim seti sınıfı en iyi temsil eden örüntülerden oluştuğu için ağın doğru tanıma oranı da artmıştır. Önerilen yapıda test verisi bu seçilmiş örüntülerle eğitilen ağda test edilmektedir. Çalışmada test verisine tip-2 bulanık kümeleme algoritması uygulanmamaktadır. Çünkü tip-2 bulanık kümeleme algoritmasındaki amaç, daha öncede belirtildiği gibi sınıflandırmada

kullanılacak olan ve yapay sinir ağının eğitimi için oluşturulmuş eğitim setini optimize etmek, ağın öğrenme kabiliyetini artırmaktır. T2BKSA yapısında, 166 örüntülük orijinal eğitim seti bulanık kümeleme algoritmaları kullanılarak 84 ve 100 örüntü sayısına sahip iki farklı eğitim seti oluşturulmuştur. Örüntü sayısının sistem üzerine etkisinin incelenmesi amacı ile uygulamalar farklı örüntü sayısına sahip iki eğitim setinde ayrı ayrı gerçekleştirilmiş ve sonuçlar karşılaştırmalı olarak sunulmuştur. T2BKSA yapısı ile gerçekleştirilen uygulama sonuçları Çizelge 8.1' de duyarlılık (sensitivity), belirlilik (specificity) ve ortalama tanıma oranı (average detection rate) parametreleri temel alınarak özetlenmiştir. Çizelgeden de görüleceği gibi, her iki eğitim setinde de T2BKSA yapısı ile %99.2 ortalama tanıma oranına ulaşılmıştır. Sonuçlar iterasyon sayısı ve test hatasına göre değerlendirilecek olursa 84 örüntülük eğitim verisi ile T2BKSA yapısında elde edilen sonuçların 100 örüntülük eğitim verisi ile elde edilenlerden daha iyi olduğu söylenebilir.

Çizelge 8.1 T2BKSA ile elde edilen optimum sonuçlar

Eğitim seti boyutu	Optimum yapı	T.H (%)	Toplam Süre (s)	İterasyon	YS	Duyarlılık (%)	Belirlilik (%)	Ortalama Tanıma Oranı (%)
84 set	200:50:12	0.016	10.14	1274	2	98.5	100	99.2
100 set	200:20:12	0.024	8.79	1822	2	98.5	100	99.2

YS=Yanlış sınıflanan set (örüntü) sayısı

Tez çalışmasında sunulan ikinci EKG sınıflandırma sistemi, tip-2 bulanık kümeleme dalgacık sinir ağı (T2BKDSA) dır . T2BKDSA yapısında tip-2 bulanık kümeleme algoritması ile seçilerek en iyi örüntülerden oluşturulan eğitim setinde özellik çıkarma işlemi gerçekleştirilmektedir. Yapı da özellik çıkarma algoritması olarak dalgacık dönüşümü kullanılmıştır. Bulanık kümeleme ile elde edilen eğitim setinde bir örüntüyü oluşturan örnek sayısı dalgacık dönüşümü kullanılarak 200 örnekten 101, 52 ve 27 örnek değerlerine düşürülmüştür. Bu örnek değerleri sırasıyla dalgacık dönüşümünün 200 örneklilik örüntüye 1, 2 ve 3 seviyede uygulanması ile elde edilmiştir. Özellik çıkarma işleminin yapılmasında amaç, öncelikli olarak sinyaldeki gereksiz örnekleri elimine ederek ağın doğru tanıma oranını artırmaktır. Bir başka kazanç ise daha az örnekle yorum yapabilen ağın cevap süresini hızlandırmaktır. Örnek değerleri azaltılmış örüntülerden oluşan eğitim verisi yapay sinir ağının eğitiminde kullanılır. Yapıda ağı sunulan test verileri de öncelikli olarak

özellik çıkarma işlemine tabi tutulduğundan test süresi de kısalmış olur. Çizelge 8.2’ de T2BKDSA yapısında dalgacık dönüşümü ile elde edilen her yeni örnek değeri için iki eğitim verisi (84 örüntülük ve 100 örüntülü) ile ulaşılan sonuçlar duyarlılık, belirlilik ve ortalama tanıma oranı parametreleri temel alınarak karşılaştırmalı olarak sunulmuştur. Sunulan sonuçlar incelenecek olursa, dalgacık dönüşümü ile örnek sayısının 101’ e düşürülmesi ile gerçekleştirilen T2BKDSA-1 yapısında 84 ve 100 örüntülük eğitim verileri ile %98.8 ortalama hata oranına ulaşılmıştır. Aynı şekilde dalgacık dönüşümü kullanılarak örnek sayısının 52’ ye düşürüldüğü T2BKDSA-2 yapısında 84 örüntülük eğitim verisi ile eğitilen ağda test aşamasında %99.6 ortalama tanıma oranına ulaşılmıştır. T2BKDSA-3 yapısında ise 200 örneklik eğitim verisi 27 örneğe düşürülmüştür. Bu yapı ile elde edilen test sonuçları çizelgenin son iki satırında sunulmuştur. Görüldüğü gibi T2BKDSA-3 yapısında 100 örüntülük eğitim verisi ile eğitilen ağda test aşamasında %99.6 ortalama tanıma oranına erişilmiştir.

Çizelge 8.2 T2BKDSA ile elde edilen optimum sonuçlar

Eğitim seti boyutu	Optimum yapı	T.H (%)	Toplam Süre (s)	İterasyon	YS	Duyarlılık (%)	Belirlilik (%)	Ortalama Tanıma Oranı (%)
84 set	101:40:12	0.011	10.4	2083	3	97.7	100	98.8
100 set	101:30:12	0.004	8.62	1749	3	97.7	100	98.8
84 set	52:20:12	0.05	5.66	1497	1	99.2	100	99.6
100 set	52:50:12	0.029	8.17	1391	3	97.7	100	98.8
84 set	27:40:12	0.028	7.31	1885	2	98.5	100	99.2
100 set	27:20:12	0.039	11	3789	1	99.2	100	99.6

YS=Yanlış sınıflanan set (örüntü) sayısı

Gerçekleştirilen üçüncü EKG sınıflandırma sisteminde özellik çıkarma algoritması olarak temel bileşen analizi kullanılmıştır. Çalışmada tip-2 bulanık kümeleme ile elde edilen eğitim verisinde örüntü örnek sayıları temel bileşen analizi metodu ile azaltılarak yapay sinir ağının test süresinin kısaltılması ve tanıma oranının artırılması amaçlanmıştır. Çizelge 8.3’ de T2BK-TB-YSA yapısı ile elde edilen sonuçlar duyarlılık, belirlilik ve ortalama tanıma oranı parametreleri gözönüne alınarak verilmiştir. Çizelgede T2BK-TB-YSA yapısı için sadece 84 örüntülük eğitim seti ile elde edilen sonuçlar sunulmuştur. Bu yapıda ağ sadece 84 örüntülük eğitim verisi ile eğitilmiştir. Sonuçlar diğer yapılara göre iyi olmadığından 100 örüntülük eğitim verisi kullanılmamıştır. Çizelgeden de görüleceği gibi, T2BK-TB-YSA yapısında örüntü örnek sayıları temel bileşen analizi kullanılarak 200 örüntüden

100, 50, 20 ve 10 değerlerine düşürülmüştür. Çizelge 8.3 incelenecek olursa, test aşamasında en iyi sonuç temel bileşen analizi ile örnek sayısının 10' a düşürüldüğü durumda alınmıştır. 10:50:12 optimum ağ yapısı ile elde edilen sonuç incelenecek olursa, %98.1 ortalama tanıma oranına ulaşıldığı görülür. Ayrıca tablo incelendiğinde daha az sayıda temel bileşenle çalışıldığında ağda daha iyi sonuçlar alındığı görülebilir. Çalışmada temel bileşen sayısının (örüntü örnek sayısı) ağ performansı üzerine etkisinin gösterilmesi amacıyla, farklı sayılarda temel bileşenle eğitim ve test süreci gerçekleştirilmiştir. Literatürde de incelenecek olursa, özellik çıkarma algoritması olarak temel bileşen analizinin kullanılması durumunda temel bileşen sayısı genellikle düşük değerlerde (çoğunlukla 2) alınır. Temel bileşen analizinde verinin özelliği birinci ve ikinci temel bileşen de en belirgin görülür. Temel bileşenin sayısı arttıkça verinin karakteristik özelliklerini yansıtmaması da azalır.

Çizelge 8.3 T2BK-TB-YSA ile elde edilen optimum sonuçlar

Eğitim seti boyutu	Optimum yapı	T.H (%)	Toplam Süre (s)	İterasyon	YS	Duyarlılık (%)	Belirlilik (%)	Ortalama Tanıma Oranı (%)
84 set	100:10:12	0.66	20.9	8013	86	48.5	10	29.2
84 set	50:10:12	0.34	11.3	4677	36	75.7	80	77.8
84 set	20:10:12	0.28	4	1269	8	94.7	95	94.8
84 set	10:50:12	0.14	5.09	1042	4	96.2	100	98.1

YS= Yanlış sınıflanan set (örüntü) sayısı

Tez çalışmasında önerilen yapılarla maksimum %99.2 duyarlılığa, %100 belirliliğe ve %99.6 ortalama tanıma oranına ulaşılmıştır. Yanlış tanımlanan örüntü sayısı minimum “1” olarak elde edilmiştir. Bu değerlerin elde edildiği yapı T2BKDSA yapısıdır. Çizelgeler incelenecek olursa, optimum sonuç, T2BKDSA yapısında dalgacık dönüşümü ile örnek sayısının 52' ye düşürülmesi durumunda 84 setlik eğitim verisi ile eğitilen ağda elde edilen test sonuçlarıdır. Görüldüğü gibi 5.66 sn' de 1497 iterasyonda 0.05 test hatasına ulaşılmış ve sadece 1 set yanlış sınıflandırılmıştır.

Tez çalışmasında önerilen yapılarla elde edilen sonuçların literatürde gerçekleştirilen EKG sınıflandırma çalışmaları ile karşılaştırması Çizelge 8.4' de sunulmuştur. Çizelgeden de görüleceği gibi tez çalışmasında EKG sınıf sayısı literatürdeki çalışmalara göre oldukça fazladır. Ortalama tanıma oranı incelenecek

olursa; ağın daha önce görmediği verilerle gerçekleştirilen çalışmalar içerisinde, tez çalışması kapsamında önerilen T2BKDSA yapısının en iyi değeri verdiği görülebilir.

Çizelge 8.4 Tez çalışmasında elde edilen sonuçların literatürle karşılaştırılması

Çalışma	Metot	EKG sinyal sınıfı sayısı	Test verisi örüntü say	Duyarlılık (%)	Belirlilik (%)	Ortalama Tanıma Oranı (%)
Osowski (2001)	FNN	7	3150	99.7	98	98.8
Özbay ve ark. (2006)	FCNN	10	106 (Eğitim verisi)	96.7	100	98.3
Yu ve Chou (2006)	ICA-MLP	8	4900	98.37	99.6	98.9
Ceylan ve ark. (2007)	WT-NN	10	106 (Eğitim verisi)	100	100	100
Yu ve Chen (2007)	WT-PNN	6	360	99.65	99.32	99.5
Yu ve Chen (2007)	ICA-MLP	8	360	99.65	98.37	98.9
Hosseini (2007)	Forward NN	6	850	85.3	82.02	83.6
Übeyli (2008)	Eigenvector metodu	4	360	98.89	98.05	98.47
Ceylan ve ark. (2009)	T2BKSA	10	106 (Eğitim verisi)	100	100	100
Tez çalışması (2009)	T2BKDSA	12	152	99.2	100	99.6

“Duyarlılık, Belirlilik ve Ortalama Tanıma Oranı” parametrelerinin tanımları ve tez çalışmasından elde edilen sonuçların bu parametreler cinsinden yorumlanması tezin ekler kısmında verilmiştir (EK 8).

9.2. Öneriler

Tez çalışmasında, hızlı teşhis ve uzaktan tedaviyi amaçlayarak gerçekleştirilen bir telekardiyoloji sistemi önerilmiştir. Önerilen sistem EKG sinyallerini işleyen ve sınıflandıran bir ağ yapısı ile bir haberleşme bloğundan oluşmaktadır. Haberleşme bloğu tez çalışmasında iki şekilde gerçekleştirilmiştir. Haberleşme türünün seçimi kullanıcıya bırakılmıştır. Çalışma kapsamında hazırlanan web sayfası ile haberleşme sağlandığı gibi, ftp adresi kullanılarak da haberleşme sağlanabilmektedir. Haberleşmenin daha hızlı gerçekleşmesini sağlayacak cep telefonu uyarıları eklenebilir.

Ayrıca bu tez çalışmasında EKG sınıflandırma problemi için üç farklı ağ yapısı önerilmiştir. Bu ağ yapılarında tip-2 bulanık kümeleme algoritması, dalgacık dönüşümü, temel bileşen analizi ve yapay sinir ağları kullanılmıştır. Önerilen ağ yapıları literatürde daha önce gerçekleştirilmemiş yapılardır. Aynı şekilde tip-2 bulanık kümeleme sinir ağı da literatürde ilk kez EKG sinyallerinin sınıflandırılmasında kullanılmıştır.

Çalışma kapsamında özellik çıkarma algoritması olarak bağımsız bileşen analizi (independent component analysis), öğrenme vektör kuantizasyonu (learning vector quantization) algoritmalar kullanılarak, yeni ağ yapıları oluşturulabilir. Böylece farklı özellik çıkarma algoritmalarının tip-2 bulanık kümeleme sinir ağı üzerine etkisi incelenebilir.

Tez çalışmasında önerilen ağ yapılarında aktivasyon fonksiyonu olarak “logaritmik sigmoid” kullanılmıştır. Burada farklı aktivasyon fonksiyonları kullanılarak ağ performansı üzerine etkileri incelenebilir.

EKG sinyalleri gibi biyolojik sinyaller üzerinde gerçekleştirilen çalışmalarda ön işleme çok önemlidir. Özellikle filtreleme sinyal tanı prosesini etkileyen en önemli faktörlerden biridir. Gerçekleştirilen tez çalışmasında literatürde incelenerek EKG sinyallerine uygun filtreler seçilmeye çalışılmıştır. Ancak banda geçiren filtre kullanımı ile sinyal üzerindeki gürültüler temizlenebilmektedir. Literatürde taranarak, uygun kesim frekansına sahip band geçiren filtre ile uygulamalar gerçekleştirilebilir.

Çalışmada QRS dedeksiyonu istatistiksel algoritmalar kullanılarak gerçekleştirilmiştir. Literatür incelenecek olursa R tepelerinin tespitinin yapay zekâ metotları ile de yapılabildiği görülür. Yapay sinir ağı ya da bulanık sinir ağı gibi hibrit bir sistem kullanılarak QRS dedeksiyonu gerçekleştirilebilir.

Tez çalışmasında, MIT-BIH verileri kullanıldığı için örnekleme frekansı olarak uygulamada da 360 Hz kullanılmıştır. Ancak farklı örnekleme frekansı ile örneklenmiş verilerden oluşturulacak veri setleri ile uygulamalar yapılabilir. Böylece önerilen yapıların farklı örnekleme frekansına sahip sinyaller üzerindeki etkisi incelenmiş olur.

10. KAYNAKLAR

- Abiyev R.H., 2004, Fuzzy Wavelet Neural Network For Control of Dynamic Plants, Trans. on Engineering, Computing and Tech. VI. World Enformatika Society, 441-444.
- Acharya U.R., Bhat P.S., Iyengar S.S., Rao A., Dua S., 2002, Classification of heart rate data using artificial neural network and fuzzy equivalence relation, Pattern recognition.
- Addison P.S., 2005, Wavelet Transforms and The ECG: a review, Phsiological Meausurements-Ins. Phys., vol.26, 155-199.
- Carliso O., Melin P., 2004, Adaptive Noise Cancellation Using Type-2 Fuzzy logic and Neural Network, Fuzzy Systems IEEE International Conference 25-29 July, 1093-1098.
- Ceylan R., 2004, Bulanık Sinir Ağı Sisteminin Ayarlanabilir Parametrelerinin Analizi ve Uygulamaları, Fen Bilimleri Enstitüsü, Selçuk Üniversitesi.
- Ceylan R., Özbay Y., 2007, Comparison of FCM, PCA and WT Techniques for Classification ECG arrhythmias using Neural Network, Expert Systems with Application, Vol.33, 286-295.
- Ceylan R., Özbay Y., Karlık B., 2009, A novel approach for classification of ECG arrhythmias: Type-2 fuzzy clustering neural network, Expert Systems with Application, vol.36, 6721-6726.
- Chen W.-S., Hsieh L., Yuan S.-Y., 2004, High Performance Data Compression Method with Pattern Matching for Biomedical ECG and Arterial Pulse Waveforms, Computer Methods and Programs in Biomedicine, vol.74, 11-27.
- De R.K., Basak J., Pal S., 2002, Unsupervised feature extraction using neuro-fuzzy approach, Fuzzy Sets and Systems, Vol.126, 277-291.

- Dong J., Xu M., 2005, Wearable ECG Recognition and Monitor, Proceedings of 18th IEEE Symposium on Computer-Based Medical Systems (CBMS'05).
- Dutt D.N., Krishnan S.M., Srinivasan N., 2003, A Dynamic Nonlinear Time Domain Model for Reconstruction and Compression of Cardiovascular Signals with Application to Telemedicine, Computer in Biology and Medicine.
- Er M. J., Deng C., 2004, Online Tuning of Fuzzy Inference Systems Using Dynamic Fuzzy Q-Learning, IEEE Trans. on Systems, Man and Cybernetics, vol.34, no.3,1478-1489.
- Engin M., Demirağ S., 2003, Fuzzy hybrid neural network based ECG beat recognition using three different types of feature sets, Cardiovascular Engineering, Vol.3, No.2, 71-80.
- Foo S.Y., Stuart G., Harvey B., Meyer-Baese A., 2002, Neural network-based EKG pattern recognition, Engineering Applications of Artificial Intelligence, Vol. 15, 253-260.
- Friesen G.M., Jannett T.C., Jadallah M.A., Yates S., Quint S.R., Nagle H.T., 1990, A comparison of the noise sensitivity of nine QRS detection algorithms, IEEE Transaction on Biomedical Engineering, vol.37, no.1, p. 85-98, January.
- Güler İ. and Übeyli E.D.,2005, ECG beat classifier designed by combined neural network model, Elsevier Science Pattern Recognition, vol.38, 199-208.
- Ham F.M., Kostanic I., 2001, Principles of Neurocomputing for Science and Engineering, Mc-Graw Hill Int. Edition.
- Jiang X., Adeli H., 2005, Dynamic Wavelet Neural Network for Nonlinear Identification of Highrise Buildings, Computer-Aided Civil and Infrastructure Engineering, vol.20, 316-330.
- Jang, J.-S.R., Sun C.T., Mizutani E., 1997, Neuro-Fuzzy and Soft Computing, Prentice Hall Inc., U.S.A.

- John R.I., Innocent P.R., Barnes M.R., 1998, Type-2 Fuzzy Sets and Neuro-fuzzy clustering of Radioagraphic Tibia Images, Fuzzy Systems, IEEE World Congress on Computational Intelligence, 1373-1376.
- John R.I., Innocent P.R., Barnes M.R., 2000, Neuro-Fuzzy Clustering of Radiographic Tibia Image Data Using Type-2 Fuzzy Sets, Information Science, vol.125, 65-82.
- Karaköse M., Akın E., 2004, Type-2 Fuzzy Activation Function for Multilayer Feedforward Neural Networks, IEEE Int. Conf. on Sys., Man and Cybernetics, vol.10, no.2, 117-127.
- Karlık B., Şahin Y.G., Ercan T., Tavlı T., 2006, Bir Tele-Kardiyoloji Sistem Tasarımı ve Gerçekleştirilmesi, GAP V.Mühendislik Kongresi, 26-28 Nisan.
- Lin C.-J., Chin C.-C., 2004, Prediction and Identification Using Wavelet- Based Recurrent Fuzzy Neural Networks, IEEE Trans. on Systems, Man and Cybernetics, vol.34, no.5, 2144-2154.
- McAndrew A. Digital Image Processing with Matlab, USA, 2004.
- Mendel J., John R. I. B., 2002, Type-2 Fuzzy Sets Made Simple, IEEE Trans. on Fuzzy Systems.
- Osowski S., Linh T.H., 2001, ECG Beat Recognition Using Fuzzy Hybrid Neural Network, IEEE Trans. on Biomedical Eng., vol.48, no.11, 1265-1271.
- Özbay Y. 1999. EKG aritmilerini hızlı tanıma, Doktora Tezi, Fen Bilimleri Enstitüsü, Selçuk Üniversitesi.
- Özbay Y., Ceylan R., Karlık B., 2006, A Fuzzy Clustering Neural network Architecture for Classification of ECG Arrhythmias, Computers in Biology and Medicine, vol.36, 376-388.
- Öztemel E., Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 2003.

- Park K.S., Yi W.J., 2003, Application of Non-Intrusive Physiological Data Monitoring in Normal Apartment Style House, IEEE EMBS Asian-Pacific Conference on Biomedical Engineering 20-22 October.
- Partridge M., Calvo R.A., 1998, Fast dimensionality reduction and simple PCA, Intelligent Data Analysis, 203-214.
- Petranek S., 1997, Neural network based principal component analysis for EEG preprocessing and analysis, Electroencephalography and Clinical Neurophysiology, vol.103, issue 1, p.115, July.
- Physionet web sayfası: www.physionet.org (Erişim tarihi:Nisan/2007)
- Rhee F.C.-H., Hwang C., 2001, A Type-2 Fuzzy C-Means Clustering Algorithm, IFSA World Congress and 20th NAFIPS Int. Conf., 1926-1929.
- Rhee F.C.-H., 2007, Uncertain Fuzzy Clustering: Insights and Recommendations, IEEE Computational Intelligence Magazine, February, s.44-56.
- Rodriguez J., Goni A., Illarramendi A., 2005, Real-Time Classification of ECGs on a PDA, IEEE Trans. on Information Technology in Biomedicine, vol.9, no.1, 23-34.
- Semmlow J.L., 2004, Biosignal and Biomedical Image Processing-MATLAB Based Application, Marcel Decker,Inc..
- Silverman M.E., Meyer R.J., 1983, Electrocardiography: Basic Concepts and Clinical Applications, McGarwhill Com, New York.
- Theodoridis S., Koutroumbas K., 2003, Pattern Recognition, Elsevier Science.
- Tura A., Badanai M., 2003, A Medical Wearable Device with Wireless Bluetooth-based Data Transmission, Measurement Science Review.
- Uçak D., 2005, Elektrokardiyografi, Nobel Tıp Kitabevleri.
- Übeyli E.D. and Guler I. Neural network analysis of internal carotid arterial Doppler signals: predictions of stenosis and occlusion, Expert Systems with

Applications, Vol. 25, pp. 1-13, 2003.

Vargas F., Lettnin D., Castro M.C.F., Macarthy M., 2002, Electrocardiogram pattern recognition by means of MLP network and PCA: A case study on equal amount of input signal types, IEEE Proceedings of the VII. Brazillian Symposium on Neural Networks.

Wang C.-H., Liu H.-L., Lin C.-T., 2001, Dynamic Optimal Learning Rates of a Certain Class of Fuzzy Neural Networks and its Applications with Genetic Algorithm, IEEE Trans. on Systems, Man and Cybernetics, vol.31, no.3, 467-475.

Wang C.-H., Cheng C.-S., Lee T.-T., 2004, Dynamical Optimal Training for Interval Type-2 Fuzzy Neural Network (T2FNN), IEEE Trans. On Systems, Man and Cybernetics, vol.34, no.3, 1462-1477.

Wenyu Y., Gang L., Ling L., Qilian Y., 2003, ECG analysis based on PCA and SOM, IEEE Int. Conf. Neural Network and Signal Processing, China, December.

EKLER

EK 1: Tip-2 Bulanık C-Ortalamalar Kümeleme Algoritması Matlab Kodları

EK 2: Tip-2 Bulanık Kümeleme Sinir Ağının Matlab Kodları

EK 3: Tip-2 Bulanık Kümeleme Dalgacık Sinir Ağının Matlab Kodları

EK 4: Tip-2 Bulanık Kümeleme-Temel Bileşen Analizi-Sinir Ağının Matlab Kodları

EK 5: Telekardiyoloji Sistemi Arayüzlerinin Kodları

EK 6: USB-1408FS veri toplama kartının teknik özellikleri

EK 7: Duyarlılık, Belirlilik ve Ortalama Tanıma Oranı Parametrelerinin

Hesaplanması ve tez çalışmasında elde edilen sonuçların bu parametreler ile yorumlanması

EK 1: Tip-2 Bulanık C-Ortalamlar Kümeleme Algoritması Matlab Kodları

```
function center_giris=t2fcm_r2(data_giris,n,expo1,expo2,max_iter,min_impro)

% expo1 - bulaniklik sabiti1
% expo2 - bulaniklik sabiti2
% n=100 - küme sayisi
% max_iter - maximum iterasyon sayisi
% min_impro - ulasilmasi istenen minimum lokal hata

data_n=size(data_giris,1);%data sayisi
obj_fcn_giris=zeros(max_iter,1);

U_giris=initT2fcm_r2(n,data_n); %baslangiç fuzzy bölgeleri
[U_giris,center_giris,obj_fcn_giris]=stepT2fcm_r4(data_giris,U_giris,n,expo1,expo2);;%baslangiç küme merkezleri

%iterasyon sayisina kadar tekrar edecek döngü
for i=1:max_iter;
    [U_giris,center_giris,obj_fcn_giris(i)] =
    stepT2fcm_r4(data_giris,U_giris,n,expo1,expo2);
    fprintf('iteration count=%d, obj.fcn.giris=%f\n',i,obj_fcn_giris(i));
    if i>1,
        if abs(obj_fcn_giris(i)-obj_fcn_giris(i-1))<min_impro,break;end;
    end
end

function [U_new,center,obj_fcn1,obj_fcn2] =
stepT2fcm_r4(data,U,cluster_n,expo1,expo2)

rand('state',0);
mf1 = U.^expo1; % MF matrix after exponential modification
mf2 = U.^expo2; % MF matrix after exponential modification
U_new11=[];U_new1=[];
U_new22=[];U_new2=[];

center1 = mf1*data./((ones(size(data, 2), 1)*sum(mf1'))'); % new center
center2 = mf2*data./((ones(size(data, 2), 1)*sum(mf2'))'); % new center
center=(center1+center2)./2; % Type-reduction formülü-kesin kümelerin
bulunması için("Uncertain Fuzzy Clustering" makalesi Eq.12)

dist1 = distT2fcm_r2(center1, data); % fill the distance matrix
dist2 = distT2fcm_r2(center2, data); % fill the distance matrix

obj_fcn1 = sum(sum((dist1.^2).*mf1)); % objective function
obj_fcn2 = sum(sum((dist2.^2).*mf2)); % objective function
obj_fcn=(obj_fcn1+obj_fcn2)./2;

tmp1 = dist1.^(-2/(expo1-1)); % calculate new U, suppose expo != 1
tmp2 = dist2.^(-2/(expo2-1)); % calculate new U, suppose expo != 1

U_new11 = tmp1./((ones(cluster_n, 1)*sum(tmp1)));
U_new22 = tmp2./((ones(cluster_n, 1)*sum(tmp2)));
ms_size=size(U_new11,2);

for i=1:ms_size % ("Uncertain Fuzzy Clustering" makalesi Eq.6)
    if U_new11(:,i)>U_new22(:,i)
        U_new1(:,i)=U_new11(:,i);
    else
        U_new1(:,i)=U_new22(:,i);
    end
end
for i=1:ms_size
    if U_new11(:,i)<=U_new22(:,i)
```

```

        U_new2(:,i)=U_new1(:,i);
    else
        U_new2(:,i)=U_new22(:,i);
    end
end

for i=1:ms_size % ("Uncertain Fuzzy Clustering" makalesi Eq.15)
    if U_new1(:,i)>U_new2(:,i)
        U_newR(:,i)=U_new1(:,i);
    else
        U_newR(:,i)=U_new2(:,i);
    end
    if U_new2(:,i)>U_new1(:,i)
        U_newL(:,i)=U_new2(:,i);
    else
        U_newL(:,i)=U_new1(:,i);
    end
end

U_newR=U_newR./ms_size;% ("Uncertain Fuzzy Clustering" makalesi Eq.15)
U_newL=U_newL./ms_size;

U_new=(U_newR+U_newL)./2; % Type-reduction formülü("Uncertain Fuzzy
Clustering" makalesi Eq.14)

function out = distT2fcm_r2(center, data)
%DISTFCM Distance measure in fuzzy c-mean clustering.
% OUT = DISTFCM(CENTER, DATA) calculates the Euclidean distance
% between each row in CENTER and each row in DATA, and returns a
% distance matrix OUT of size M by N, where M and N are row
% dimensions of CENTER and DATA, respectively, and OUT(I, J) is
% the distance between CENTER(I,:) and DATA(J,:).
%
% See also FCMDEMO, INITFCM, IRISFCM, STEPFCM, and FCM.

% Roger Jang, 11-22-94, 6-27-95.
% Copyright 1994-2002 The MathWorks, Inc.
% $Revision: 1.13 $ $Date: 2002/04/14 22:20:29 $

out = zeros(size(center, 1), size(data, 1));

% fill the output matrix

if size(center, 2) > 1,
    for k = 1:size(center, 1),
        out(k, :) = sqrt(sum(((data-ones(size(data, 1), 1)*center(k, :)).^2)'));
    end
else % 1-D data
    for k = 1:size(center, 1),
        out(k, :) = abs(center(k)-data)';
    end
end

function U = initT2fcm_r2(cluster_n, data_n)
%INITFCM Generate initial fuzzy partition matrix for fuzzy c-means
clustering.
% U = INITFCM(CLUSTER_N, DATA_N) randomly generates a fuzzy partition
% matrix U that is CLUSTER_N by DATA_N, where CLUSTER_N is number of
% clusters and DATA_N is number of data points. The summation of each
% column of the generated U is equal to unity, as required by fuzzy
% c-means clustering.
%
% See also DISTFCM, FCMDEMO, IRISFCM, STEPFCM, FCM.

```

```
% Roger Jang, 12-1-94.  
% Copyright 1994-2002 The MathWorks, Inc.  
% $Revision: 1.11 $ $Date: 2002/04/14 22:21:58 $  
  
rand('state',0);  
U = rand(cluster_n, data_n);  
col_sum = sum(U);  
U = U./col_sum(ones(cluster_n, 1), :);
```

EK 2: Tip-2 Bulanık Kümeleme Sinir Ağının Matlab Kodları

```
% T2FCM ve YSA İLE EKG ARITMİLERİNİ SINIFLANDIRMA

clear all
clc;
tic
format long

% =====

% EKG' NİN OKUTTURULMASI
load center_t2fcm2.dat;
load hedeftrain_84.dat;
train_input=center_t2fcm2;
ekg_hedef=hedeftrain_84;

load ecgtest.dat;
load hedeftest_152.dat;
test_input=ecgtest;

% =====

% Yapay sinir agina EKG' nin sunulmasi ve egitme
rand('state',0);
net=newff(minmax(train_input),[50 12],{'logsig','logsig'},'traingdx');
net.trainParam.show = 200;
net.trainParam.epochs = 10000;
net.trainParam.goal = 0;
net.trainParam.time=inf;
net.trainParam.max_fail=5;
net.trainParam.min_grad = 1e-20;
net.trainParam.lr=2.0;
net.trainParam.mc=1.0;
net.trainParam.delt_inc=1.0;
net.trainParam.delt_dec=0.5;
net.trainParam.delta0=0.07;
net.trainParam.deltamax=50.0;

[net,tr]=train(net,train_input,ekg_hedef);
atr=sim(net,train_input);% Egitilen YSA' da girisin simüle edilmesi ve
cikislarin üretilmesi

test=sim(net,test_input);
save test.dat test -ascii % test sonucunun kaydedilmesi

% Orjinal data ile son data arasindaki hatanın hesaplanmasi
hatatr1=sum(abs(ekg_hedef-atr));
egitimhatasi =(sum(hatatr1))/(size(train_input,2)*size(ekg_hedef,1))*100

test_hatasi_12 % test hatasinin ve siniflandirma sonucunun bulunmasi

t=toc % program için harcanan CPU süresi
```

EK 3: Tip-2 Bulanık Kümeleme Dalgacık Sinir Ağının Matlab Kodları

```
% T2FCM ve YSA İLE EKG ARITMİLERİNİ SINIFLANDIRMA

clear all;clc;
tic
format long

% =====

% EKG' NIN OKUTTURULMASI
load center_t2fcm2.dat; % FCM ile 84 set'e azaltılmış datalar
load hedeftrain_84.dat;
ekg_inpl=center_t2fcm2;
ekg_hedef=hedeftrain_84;

load ecgtest.dat;
load hedeftest_152.dat;
ekg_test1=ecgtest;

% =====

% EKG' NIN WAVELET İLE AZALTILMASI
CA=zeros(101,84);
CD=zeros(101,84);
for i=1:84
    [CA(:,i),CD(:,i)]=dwt(ekg_inpl(:,i),'db2');
end

CA_test=zeros(101,152);
CD_test=zeros(101,152);
for i=1:152
    [CA_test(:,i),CD_test(:,i)]=dwt(ekg_test1(:,i),'db2');
end

train_input1=CA;
for i=1:84
    train_input(:,i)=(train_input1(:,i)-
min(train_input1(:,i)))/(max(train_input1(:,i))-min(train_input1(:,i)));
end

test_input1=CA_test;
for i=1:152
    test_input(:,i)=(test_input1(:,i)-
min(test_input1(:,i)))/(max(test_input1(:,i))-min(test_input1(:,i)));
end

% =====

% Yapay sinir ağına Wavelet katsayılarının sunulması ve eğitme

rand('state',0);
net=newff(minmax(train_input),[30 12],{'logsig','logsig'},'traingdx');
net.trainParam.show = 200;
net.trainParam.epochs = 10000;
net.trainParam.goal = 0;
net.trainParam.time=inf;
net.trainParam.max_fail=5;
net.trainParam.min_grad = 1e-20;
net.trainParam.lr=2.0;
net.trainParam.mc=0.9;
net.trainParam.delt_inc=1.0;
net.trainParam.delt_dec=0.5;
net.trainParam.delta0=0.07;
```

```

net.trainParam.deltamax=50.0;

[net,tr]=train(net,train_input,ekg_hedef);
atr=sim(net,train_input);% Egitilen YSA' da girisin simüle edilmesi ve
çikislarin üretilmesi

test=sim(net,test_input);

% =====

save test.dat test -ascii % test sonucunun kaydedilmesi

% =====

% Orjinal data ile son data arasindaki hatanin hesaplanmasi
hatatr1=sum(abs(ekg_hedef-atr));
egitimhatasi =((sum(hatatr1))/(size(train_input,2)*size(ekg_hedef,1)))*100

test_hatasi_12 % test hatasinin ve siniflandirma sonucunun bulunmasi

t=toc % program için harcanan CPU süresi

```

EK 4: Tip-2 Bulanık Kümeleme-Temel Bileşen Analizi-Sinir Ağının Matlab Kodları

```
% T2FCM-PCA ve YSA İLE EKG ARITMİLERİNİ SINIFLANDIRMA

clear all
clc;
tic
format long

% =====

% EKG' NİN OKUTTURULMASI

load center_t2fcm2.dat; % FCM ile 84 set'e azaltılmış datalar
load hedeftrain_84.dat;
ekg_inp1=center_t2fcm2;
ekg_hedef=hedeftrain_84;

load ecgtest.dat;
load hedeftest_152.dat;
ekg_test1=ecgtest;

ekg_inp2=ekg_inp1;
ekg_test2=ekg_test1;

% Kovaryans matrisi hesaplanmadan önce her sütundan o sütunun ortalaması
% çıkarılmalıdır.
for i=1:84
    mean_ekg=mean(ekg_inp2(:,i));
    ekg_inp(:,i)=ekg_inp2(:,i)-mean_ekg;
end

for i=1:152
    mean_ekg_test=mean(ekg_test2(:,i));
    ekg_test(:,i)=ekg_test2(:,i)-mean_ekg_test;
end

% =====

% EKG' NİN PCA İLE AZALTILMASI

% EKG' nin [0 1] arası normalizasyonu (hedef matrisin oluşturulması)

giris_say=size(ekg_inp,2);
for i=1:giris_say
    ekg_inp(:,i)=(ekg_inp(:,i)-min(ekg_inp(:,i)))/(max(ekg_inp(:,i))-min(ekg_inp(:,i)));
end

giris_saytest=size(ekg_test,2);
for i=1:giris_saytest
    ekg_test(:,i)=(ekg_test(:,i)-min(ekg_test(:,i)))/(max(ekg_test(:,i))-min(ekg_test(:,i)));
end

% Eigenvektör hesabı
eigvector_n=5;
```

```

ekg_train_test=[ekg_inp ekg_test];

[newdata_inp,eigvector_inp,eigvalue_inp]=pca_r(ekg_train_test,eigvector_n);

% Girise verilecek PCA ile azaltilmis vektörün [0 1] arasi normalizasyonu
(giris matrisinin olusturulmasi)

train_input=eigvector_inp(1:84,:).';
train_input1=eigvector_inp(1:84,:).';
for i=1:84
    train_input(:,i)=(train_input1(:,i)-
min(train_input1(:,i)))/(max(train_input1(:,i))-min(train_input1(:,i)));
end
% train_input=train_input.';

test_input=eigvector_inp(85:236,:);
test_input1=eigvector_inp(85:236,:).';
test_input=test_input.';
for i=1:152
    test_input(:,i)=(test_input1(:,i)-
min(test_input1(:,i)))/(max(test_input1(:,i))-min(test_input1(:,i)));
end
% test_input=test_input.';

% =====

% Yapay sinir agina EKG' nin sunulmasi ve egitme

net=newff(minmax(train_input),[50 12],{'logsig','logsig'},'traingdx');
rand('state',0);
net.trainParam.show = 200;
net.trainParam.epochs = 10000;
net.trainParam.goal = 0;
net.trainParam.time=inf;
net.trainParam.max_fail=5;
net.trainParam.min_grad = 1e-20;
net.trainParam.lr=2.0;
net.trainParam.mc=0.9;
net.trainParam.delt_inc=1.0;
net.trainParam.delt_dec=0.5;
net.trainParam.delta0=0.07;
net.trainParam.deltamax=50.0;

[net,tr]=train(net,train_input,ekg_hedef);
atr=sim(net,train_input);% Egtilen YSA' da girisin simüle edilmesi ve
çikislarin üretilmesi

test=sim(net,test_input);

% =====

save test.dat test -ascii % test sonucunun kaydedilmesi

% =====

% Orjinal data ile son data arasindaki hatanin hesaplanmasi
hatatr1=sum(abs(ekg_hedef-atr));
egitimhatasi =(sum(hatatr1))/(size(ekg_inp,2)*size(ekg_hedef,1))*100

test_hatasi_12 % test hatasinin ve siniflandirma sonucunun bulunmasi

t=toc % program için harcanan CPU süresi

```

```

function [newdata,eigvector,eigvalue]=pca_r(data,eigvector_n)

% data=azaltılacak giriş datası      eigvector_n=azaltılacak sayı,
data=[egitim_giris test_giris]

[eigvector1, d] = eig(data*(data'));% özvektörleri ve diagonal matrisi
hesaplıyor
eigvalue = diag(d);

% =====

%%% sort komutunun kullanılmasının amacı hesaplanan eigen vektörü
içerisindeki
%%% eigen değerlerini büyükten küçüğe doğru sıralayarak en yüksek eigen
değerlerinden
%%% seçmek, böylece principal componentleri belirlemek
[junk, index] = sort(-eigvalue);
eigvalue = eigvalue(index);
eigvector1 = eigvector1(:, index); % Eigenvectors of A*A^T

% =====

eigvector = data'*eigvector1; % Eigenvectors of A^T*A
eigvector = eigvector*diag(1./ (sum(eigvector.^2).^0.5)); % Normalizasyon
newdata = data*eigvector;

if eigvector_n < size(data, 1),
    eigvalue = eigvalue(1:eigvector_n);
    eigvector = eigvector(:, 1:eigvector_n);% ilk eigvector_n adet datayı
eigvector matrisine atıyor. böylece data azaltılmış oluyor
    newdata = newdata(:, 1:eigvector_n);
end

```

EK 5: Telekardiyoloji Sistemi Arayüzlerinin Kodları

(ftp haberleşme-sağlık ocağı için hazırlanan arayüz)

```
function varargout = EKG_Teshis_12sinif2_haberlesme_daq(varargin)
% EKG_TESHIS_12SINIF2_HABERLESME_Daq M-file for
EKG_Teshis_12sinif2_haberlesme_daq.fig
%     EKG_TESHIS_12SINIF2_HABERLESME_Daq, by itself, creates a new
EKG_TESHIS_12SINIF2_HABERLESME_Daq or raises the existing
%     singleton*.
%
%
%     H = EKG_TESHIS_12SINIF2_HABERLESME_Daq returns the handle to a new
EKG_TESHIS_12SINIF2_HABERLESME_Daq or the handle to
%     the existing singleton*.
%
%
% EKG_TESHIS_12SINIF2_HABERLESME_Daq('CALLBACK',hObject,eventData,handles,...)
calls the local
%     function named CALLBACK in EKG_TESHIS_12SINIF2_HABERLESME_Daq.M with
the given input arguments.
%
%     EKG_TESHIS_12SINIF2_HABERLESME_Daq('Property','Value',...) creates a
new EKG_TESHIS_12SINIF2_HABERLESME_Daq or raises the
%     existing singleton*. Starting from the left, property value pairs
are
%     applied to the GUI before
EKG_Teshis_12sinif2_haberlesme_daq_OpeningFunction gets called. An
%     unrecognized property name or invalid value makes property
application
%     stop. All inputs are passed to
EKG_Teshis_12sinif2_haberlesme_daq_OpeningFcn via varargin.
%
%     *See GUI Options on GUIDE's Tools menu. Choose "GUI allows only one
%     instance to run (singleton)".
%
% See also: GUIDE, GUIDATA, GUIHANDLES

% Edit the above text to modify the response to help
EKG_Teshis_12sinif2_haberlesme_daq

% Last Modified by GUIDE v2.5 21-Oct-2008 09:55:57

% Begin initialization code - DO NOT EDIT
gui_Singleton = 1;
gui_State = struct('gui_Name',       mfilename, ...
                  'gui_Singleton',   gui_Singleton, ...
                  'gui_OpeningFcn',  @EKG_Teshis_12sinif2_haberlesme_daq_OpeningFcn, ...
                  'gui_OutputFcn',   @EKG_Teshis_12sinif2_haberlesme_daq_OutputFcn, ...
                  'gui_LayoutFcn',   [] , ...
                  'gui_Callback',    []);
if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end

if nargin
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end
% End initialization code - DO NOT EDIT
```

```

% --- Executes just before EKG_Teshis_12sinif2_haberlesme_daq is made
visible.
function EKG_Teshis_12sinif2_haberlesme_daq_OpeningFcn(hObject, eventdata,
handles, varargin)
% This function has no output args, see OutputFcn.
% hObject    handle to figure
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
% varargin   command line arguments to EKG_Teshis_12sinif2_haberlesme_daq
(see VARARGIN)

% Choose default command line output for EKG_Teshis_12sinif2_haberlesme_daq
handles.output = hObject;

% Update handles structure
guidata(hObject, handles);

% UIWAIT makes EKG_Teshis_12sinif2_haberlesme_daq wait for user response
(see UIRESUME)
% uiwait(handles.figure1);

% --- Outputs from this function are returned to the command line.
function varargout = EKG_Teshis_12sinif2_haberlesme_daq_OutputFcn(hObject,
eventdata, handles)
% varargout  cell array for returning output args (see VARARGOUT);
% hObject    handle to figure
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% Get default command line output from handles structure
varargout{1} = handles.output;

% --- Executes on button press in Kayit.
function Kayit_Callback(hObject, eventdata, handles)
% hObject    handle to Kayit (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
% if(strcmp(handles.aio.running,'On'))
%     return;
% else
%     start(handles.aio);
% end
handles.ai=analoginput('mcc',0); % Kullanılan ürünün Measurement
Computing firmasına ait olduğunun belirlenmesi
chan=addchannel(handles.ai,0); % ai isimli analog giriş
nesnesinde kaç adet giriş kanalı olacağını belirler
set(handles.ai,'SampleRate',360); % Nesnenin örnekleme oranını
belirler
set(handles.ai,'SamplesPerTrigger',10000); % Nesnenin bir tetiklemede kaç
örnek alacağını belirler
start(handles.ai);
[handles.EKG time]=getdata(handles.ai);
guidata(hObject, handles);
ecg=handles.EKG(2000:7000);
plot(ecg);
ecg_put=handles.EKG;
save ecg.dat ecg_put -ascii
stop(handles.ai);

% --- Executes on button press in Siniflandir.
function Siniflandir_Callback(hObject, eventdata, handles)
% hObject    handle to Siniflandir (see GCBO)

```

```

% eventdata reserved - to be defined in a future version of MATLAB
% handles structure with handles and user data (see GUIDATA)
%Sinyalin R-R aralıklarının bulunması

% ECG veri dosyasının okutturulması ----- (DAQ
kartından alınan sinyale göre düzenlenmeli)

% load ECGnsr.dat
% EKG=ECGnsr(2000:52000,2);

%save EKG.dat handles.EKG -ascii
ecg=handles.EKG(1000:4000);

% =====

% Sinyalin ortalamasının atılması
ecg_mean=ecg-mean(ecg);

% =====

% Alçak Geçiren Filtre----30 Hz
[b1,a1] = butter(2,30/180,'low');% örnekleme frekansı 360 sample/s
ecglpf = filter(b1,a1,ecg_mean);
ecglpf1=abs(ecglpf);

%Yüksek Geçiren Filtre----0.1 Hz
[b2,a2] = butter(2,0.09/180,'high');%örnekleme frekansı 360 sample/s
ecghpf = filter(b2,a2,ecglpf);

ecg_hpf=ecghpf-mean(ecghpf);

% =====

% Sinyalin 0-1 arası normalizasyonu
max_ecg=max(ecg_hpf);
min_ecg=min(ecg_hpf);
ecgnorm=(ecg_hpf-min_ecg)/(max_ecg-min_ecg);

% =====

% R tepelerinin bulunması
i=0;
syc=0;

n=3:(length(ecgnorm)-1200);%last 2000 samples are not processed
ecgf(n)=(-2*ecgnorm(n-2)-ecgnorm(n-1)+ecgnorm(n+1)+2*ecgnorm(n+2));

st=0.6*max(ecgf(3:(length(ecgnorm)-1200))); % st:Eşik değeri

i=21;
while i<=length(ecgf)
    if ecgf(i)>=st
        max_ecgnorm=max(ecgnorm((i-20):(i+20)));
        ecgx=ecgnorm((i-20):(i+20));
        tin=find(ecgx==max_ecgnorm);
        syc=syc+1;
        qrs=(i-20)+(tin(1)-1);
        r_yer(syc)=qrs;
        ecgr(syc)=ecgnorm(qrs);
        i=i+50; % i=i+200
        if tin<length(ecgf)-1200
            st=0.6*max(ecgf(tin+1:1200+tin+1));
        end
    end
    i=i+1;

```

```

end

% =====

% Sinyalin R-R aralıklarının yeniden örneklenmesi
k=size(r_yer,2);
sample=200;
ecgnew=zeros(sample,k);

for i=1:(k-1)
    rr_fark=r_yer(i+1)-r_yer(i);
    r_factor=rr_fark./sample;
    ecg_resampled=resample(ecgnorm(r_yer(i):r_yer(i+1)),sample,rr_fark);
    ecgnew(:,i)=ecg_resampled(1:sample);
end

% ECGNEW sinyalinin normalizasyonu
for i=1:(k-1)
    ecgnew(:,i)=(ecgnew(:,i)-min(ecgnew(:,i)))/(max(ecgnew(:,i))-min(ecgnew(:,i)));
end

% =====

% Kaydedilen optimum networke ait parametrelerin çağırılması
load ecg_t2fcwnn_84set.mat

% Sinyal_sonucu' nun wavelet katsayılarının hesaplanması
w=ecgnew;giris_saytest=size(w,2);
CA1_test=zeros(101,giris_saytest);
CD1_test=zeros(101,giris_saytest);
for i=1:giris_saytest
    [CA1_test(:,i),CD1_test(:,i)]=dwt(w(:,i),'db2');
end
CA_test=zeros(52,giris_saytest);
CD_test=zeros(52,giris_saytest);
for i=1:giris_saytest
    [CA_test(:,i),CD_test(:,i)]=dwt(CA1_test(:,i),'db2');
end
test_input1=CA_test;
for i=1:giris_saytest
    test_input(:,i)=(test_input1(:,i)-min(test_input1(:,i)))/(max(test_input1(:,i))-min(test_input1(:,i)));
end
test_input=test_input(:,1:(giris_saytest-1));

% Optimum networkde sinyalin sınıflandırılması
sinyal_sonucu=sim(net,test_input);
save sinyal_sonucu.dat sinyal_sonucu -ascii
test_hatasi_12;

% HATA
str14a=sprintf('%d',Hata);
str14b=findobj(gcf,'Tag','str14');
set(str14b,'String',str14a);

% Normal Sinüs Ritmi
str1a=sprintf('%d',k1);
str1b=findobj(gcf,'Tag','str1');
set(str1b,'String',str1a);

% Sinüs Bradikardisi
str2a=sprintf('%d',k2);
str2b=findobj(gcf,'Tag','str2');
set(str2b,'String',str2a);

```

```

% Ventriküler Taşikardi
str3a=sprintf('%d',k3);
str3b=findobj(gcf,'Tag','str3');
set(str3b,'String',str3a);

% Sinüs Aritmisi
str4a=sprintf('%d',k4);
str4b=findobj(gcf,'Tag','str4');
set(str4b,'String',str4a);

% Atrial Prematüre Kasılması
str5a=sprintf('%d',k5);
str5b=findobj(gcf,'Tag','str5');
set(str5b,'String',str5a);

% Yapay Vuru
str6a=sprintf('%d',k6);
str6b=findobj(gcf,'Tag','str6');
set(str6b,'String',str6a);

% Sağ Dal Bloku
str7a=sprintf('%d',k7);
str7b=findobj(gcf,'Tag','str7');
set(str7b,'String',str7a);

% Sol Dal Bloku
str8a=sprintf('%d',k8);
str8b=findobj(gcf,'Tag','str8');
set(str8b,'String',str8a);

% Atrial Fibrilasyon
str9a=sprintf('%d',k9);
str9b=findobj(gcf,'Tag','str9');
set(str9b,'String',str9a);

% Atrial Flutter
str10a=sprintf('%d',k10);
str10b=findobj(gcf,'Tag','str10');
set(str10b,'String',str10a);

% Atrial Couplet
str11a=sprintf('%d',k11);
str11b=findobj(gcf,'Tag','str11');
set(str11b,'String',str11a);

% Ventriküler Trigeminy
str12a=sprintf('%d',k12);
str12b=findobj(gcf,'Tag','str12');
set(str12b,'String',str12a);

% Sınıflanamayan veri
str13a=sprintf('%d',k13);
str13b=findobj(gcf,'Tag','str13');
set(str13b,'String',str13a);

% Toplam veri
str15a=sprintf('%d',Toplam_veri);
str15b=findobj(gcf,'Tag','str15');
set(str15b,'String',str15a);

% Sınıflama Sonucu Algoritması

```

```

if str1a>str2a & str1a>str3a & str1a>str4a & str1a>str5a & str1a>str6a &
str1a>str7a & str1a>str8a & str1a>str9a & str1a>str10a & str1a>str11a &
str1a>str12a & str1a>str13a
    handles.siniflama_sonucu='Normal Sinüs Ritmi';
end

if str2a>str1a & str2a>str3a & str2a>str4a & str2a>str5a & str2a>str6a &
str2a>str7a & str2a>str8a & str2a>str9a & str2a>str10a & str2a>str11a &
str2a>str12a & str2a>str13a
    handles.siniflama_sonucu='Sinüs Bradikardisi';
end

if str3a>str1a & str3a>str2a & str3a>str4a & str3a>str5a & str3a>str6a &
str3a>str7a & str3a>str8a & str3a>str9a & str3a>str10a & str3a>str11a &
str3a>str12a & str3a>str13a
    handles.siniflama_sonucu='Ventriküler Tasikardi';
end

if str4a>str1a & str4a>str2a & str4a>str3a & str4a>str5a & str4a>str6a &
str4a>str7a & str4a>str8a & str4a>str9a & str4a>str10a & str4a>str11a &
str4a>str12a & str4a>str13a
    handles.siniflama_sonucu='Sinüs Aritmisi';
end

if str5a>str1a & str5a>str2a & str5a>str3a & str5a>str4a & str5a>str6a &
str5a>str7a & str5a>str8a & str5a>str9a & str5a>str10a & str5a>str11a &
str5a>str12a & str5a>str13a
    handles.siniflama_sonucu='Atrial Prematüre Kasılması';
end

if str6a>str1a & str6a>str2a & str6a>str3a & str6a>str4a & str6a>str5a &
str6a>str7a & str6a>str8a & str6a>str9a & str6a>str10a & str6a>str11a &
str6a>str12a & str6a>str13a
    handles.siniflama_sonucu='Yapay Vuru';
end

if str7a>str1a & str7a>str2a & str7a>str3a & str7a>str4a & str7a>str5a &
str7a>str6a & str7a>str8a & str7a>str9a & str7a>str10a & str7a>str11a &
str7a>str12a & str7a>str13a
    handles.siniflama_sonucu='Sag Dal Bloku';
end

if str8a>str1a & str8a>str2a & str8a>str3a & str8a>str4a & str8a>str5a &
str8a>str6a & str8a>str7a & str8a>str9a & str8a>str10a & str8a>str11a &
str8a>str12a & str8a>str13a
    handles.siniflama_sonucu='Sol Dal Bloku';
end

if str9a>str1a & str9a>str2a & str9a>str3a & str9a>str4a & str9a>str5a &
str9a>str6a & str9a>str7a & str9a>str8a & str9a>str10a & str9a>str11a &
str9a>str12a & str9a>str13a
    handles.siniflama_sonucu='Atrial Fibrilasyon';
end

if str10a>str1a & str10a>str2a & str10a>str3a & str10a>str4a & str10a>str5a &
str10a>str6a & str10a>str7a & str10a>str8a & str10a>str9a & str10a>str11a &
str10a>str12a & str10a>str13a
    handles.siniflama_sonucu='Atrial Flutter';
end

if str11a>str1a & str11a>str2a & str11a>str3a & str11a>str4a & str11a>str5a &
str11a>str6a & str11a>str7a & str11a>str8a & str11a>str9a & str11a>str10a &
str11a>str12a & str11a>str13a
    handles.siniflama_sonucu='Atrial Couplet';
end

```

```

if str12a>str1a & str12a>str2a & str12a>str3a & str12a>str4a & str12a>str5a
& str12a>str6a & str12a>str7a & str12a>str8a & str12a>str9a & str12a>str10a
& str12a>str11a & str12a>str13a
    handles.siniflama_sonucu='Ventriküler Trigeminy';
end
if str13a>str1a & str13a>str2a & str13a>str3a & str13a>str4a & str13a>str5a
& str13a>str6a & str13a>str7a & str13a>str8a & str13a>str9a & str13a>str10a
& str13a>str11a & str13a>str12a
    handles.siniflama_sonucu='Siniflanamayan veri';
end

siniflama_sonucu=handles.siniflama_sonucu;
guidata(hObject,handles);
save siniflama_sonucu

function Sikayet_Callback(hObject, eventdata, handles)
% hObject    handle to Sikayet (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% Hints: get(hObject,'String') returns contents of Sikayet as text
%         str2double(get(hObject,'String')) returns contents of Sikayet as a
double
sikayet=get(hObject,'string');
handles.sikayet=sikayet;
if iscellstr(sikayet)
    errordlg('You must enter a string value','Bad Input','modal')
end
guidata(hObject,handles);
save sikayet

% --- Executes during object creation, after setting all properties.
function Sikayet_CreateFcn(hObject, eventdata, handles)
% hObject    handle to Sikayet (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% Hint: edit controls usually have a white background on Windows.
%         See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUiControlBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end

function Yas_Callback(hObject, eventdata, handles)
% hObject    handle to Yas (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% Hints: get(hObject,'String') returns contents of Yas as text
%         str2double(get(hObject,'String')) returns contents of Yas as a
double
yas=get(hObject,'string');
user_string2= str2double(yas);
handles.yas=yas;
if isnan(handles.yas)
    errordlg('You must enter a numeric value','Bad Input','modal')
end

guidata(hObject,handles);
save yas

% --- Executes during object creation, after setting all properties.
function Yas_CreateFcn(hObject, eventdata, handles)

```

```

% hObject      handle to Yas (see GCBO)
% eventdata    reserved - to be defined in a future version of MATLAB
% handles      empty - handles not created until after all CreateFcns called

% Hint: edit controls usually have a white background on Windows.
%           See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUiControlBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end

% --- Executes on button press in Kadin.
function Kadin_Callback(hObject, eventdata, handles)
% hObject      handle to Kadin (see GCBO)
% eventdata    reserved - to be defined in a future version of MATLAB
% handles      structure with handles and user data (see GUIDATA)

% Hint: get(hObject,'Value') returns toggle state of Kadin
if (get(hObject,'Value') == get(hObject,'Max'))
    handles.cinsiyet='Kadin';
    user_string3=cellstr(handles.cinsiyet);
end
guidata(hObject,handles);

% --- Executes on button press in Erkek.
function Erkek_Callback(hObject, eventdata, handles)
% hObject      handle to Erkek (see GCBO)
% eventdata    reserved - to be defined in a future version of MATLAB
% handles      structure with handles and user data (see GUIDATA)

% Hint: get(hObject,'Value') returns toggle state of Erkek
if (get(hObject,'Value') == get(hObject,'Max'))
    handles.cinsiyet='Erkek';
    user_string4=cellstr(handles.cinsiyet);
end
guidata(hObject,handles);

% --- Executes on button press in Bilgileri_kaydet.
function Bilgileri_kaydet_Callback(hObject, eventdata, handles)
% hObject      handle to Bilgileri_kaydet (see GCBO)
% eventdata    reserved - to be defined in a future version of MATLAB
% handles      structure with handles and user data (see GUIDATA)

%
hasta_bilgileri=[handles.yas;handles.cinsiyet;handles.sikayet;handles.sinifl
ama_sonucu];
% save hasta_bilgileri.dat hasta bilgileri -ascii
% save yas.dat handles.yas -ascii
% save cinsiyet.dat handles.cinsiyet -ascii
% save sikayet.dat handles.sikayet -ascii
% save siniflama_sonucu.dat handles.siniflama_sonucu -ascii
cinsiyet=handles.cinsiyet;
save cinsiyet;
%saveas(gcf,'EKG_Kayit_Teshis.bmp')
f = ftp('telekardiyoloji.com','username','password');
mput(f,'ecg.dat');
mput(f,'siniflama_sonucu.mat');
mput(f,'sikayet.mat');
mput(f,'cinsiyet.mat');
mput(f,'yas.mat');

% --- Executes on button press in Uzman_doktor.
function Uzman_doktor_Callback(hObject, eventdata, handles)
% hObject      handle to Uzman_doktor (see GCBO)

```

```

% eventdata reserved - to be defined in a future version of MATLAB
% handles structure with handles and user data (see GUIDATA)
% f = ftp('turksatkablo.net','rahimeceylan','rahime1234');
f = ftp('telekardiyoloji.com','username','password');
mget(f,'message_UD.mat');
load message_UD %.mat;
str16a=sprintf('%s',message_UD);
str16b=findobj(gcf,'Tag','str16');
set(str16b,'String',str16a);

% --- Executes on button press in Saglik_Ocagi.
function Saglik_Ocagi_Callback(hObject, eventdata, handles)
% hObject handle to Saglik_Ocagi (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles structure with handles and user data (see GUIDATA)
str17b=findobj(gcf,'Tag','str17');
message_SO=get(str17b,'String');
save message_SO %.mat message_SO;
f = ftp('telekardiyoloji.com','username','password');
mput(f,'message_SO.mat');

% --- Executes during object creation, after setting all properties.
function str1_CreateFcn(hObject, eventdata, handles)
% hObject handle to str1 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str2_CreateFcn(hObject, eventdata, handles)
% hObject handle to str2 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str3_CreateFcn(hObject, eventdata, handles)
% hObject handle to str3 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str4_CreateFcn(hObject, eventdata, handles)
% hObject handle to str4 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str5_CreateFcn(hObject, eventdata, handles)
% hObject handle to str5 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str6_CreateFcn(hObject, eventdata, handles)
% hObject handle to str6 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str7_CreateFcn(hObject, eventdata, handles)
% hObject handle to str7 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles empty - handles not created until after all CreateFcns called

```

```

% --- Executes during object creation, after setting all properties.
function str8_CreateFcn(hObject, eventdata, handles)
% hObject    handle to str8 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str9_CreateFcn(hObject, eventdata, handles)
% hObject    handle to str9 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str10_CreateFcn(hObject, eventdata, handles)
% hObject    handle to str10 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str11_CreateFcn(hObject, eventdata, handles)
% hObject    handle to str11 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str12_CreateFcn(hObject, eventdata, handles)
% hObject    handle to str12 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str13_CreateFcn(hObject, eventdata, handles)
% hObject    handle to text82 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str14_CreateFcn(hObject, eventdata, handles)
% hObject    handle to str14 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% --- Executes during object creation, after setting all properties.
function str15_CreateFcn(hObject, eventdata, handles)
% hObject    handle to str15 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

function str16_Callback(hObject, eventdata, handles)
% hObject    handle to str16 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% Hints: get(hObject,'String') returns contents of str16 as text
%        str2double(get(hObject,'String')) returns contents of str16 as a
double

% --- Executes during object creation, after setting all properties.
function str16_CreateFcn(hObject, eventdata, handles)
% hObject    handle to str16 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% Hint: edit controls usually have a white background on Windows.

```

```

%         See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end

function str17_Callback(hObject, eventdata, handles)
% hObject    handle to str17 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)

% Hints: get(hObject,'String') returns contents of str17 as text
%        str2double(get(hObject,'String')) returns contents of str17 as a
double

% --- Executes during object creation, after setting all properties.
function str17_CreateFcn(hObject, eventdata, handles)
% hObject    handle to str17 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called

% Hint: edit controls usually have a white background on Windows.
%         See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end

```

EK 6: USB-1408FS veri toplama kartının teknik özellikleri

Analog giriş özellikleri

Parameter	Conditions	Specification
A/D converter type	Successive approximation type	
Input voltage range for linear operation, single-ended mode	CHx to GND	±10 volts (V) max
Input common-mode voltage range for linear operation, differential mode	CHx to GND	.10 V min, +20 V max
Absolute maximum input voltage	CHx to GND	±28 V max
Input impedance	122K Ohms	
Input current (Note 1)	Vin = +10 V	70 microamperes (μA) typ
Vin = 0 V	.12 μA typ	
Vin = .10 V	.94 μA typ	
Number of channels	8 single-ended / 4 differential, software selectable	
Input ranges, single-ended mode	±10 V, G=2	
Input ranges, differential mode	±20 V, G=1 ±10 V, G=2 ±5 V, G=4 ±4 V, G=5 ±2.5 V, G=8 ±2.0 V, G=10 ±1.25 V, G=16 ±1.0 V, G=20 Software selectable	
Throughput (Note 2)	Software paced	250 samples per second (S/s) typ, PC-dependent
Continuous scan	48 kilosamples per second (kS/s)	
Channel gain queue	Up to 16 elements	Software configurable channel, range, and gain.
Resolution (Note 3)	Differential	14-bits, no missing codes
Single-ended	13-bits	
Integral linearity error	±2 least significant bit (LSB) typ	
Differential linearity error	±0.5 LSB typ	
Absolute accuracy long term drift (Note 4)	±20V range	±3LSB typ. (delta t = 1000 hrs)
±4V range	±6LSB typ. (delta t = 1000 hrs)	
±1V range	±8LSB typ. (delta t = 1000 hrs)	
2.5VREF accuracy (pin 16)	±36.25 mV max.	
2.5VREF output current (pin 16)	Source	5 mA max.
Sink	20 μA min, 100 μA typ	
Trigger source	Software selectable	External digital: TRIG_IN

Analog çıkış özellikleri

Parameter	Conditions	Specification
Resolution		12-bits, 1 in 4096
Output range		0 to 4.096 V, 1 mV per LSB.
Number of channels		2
Throughput (Note 5)	Software paced	250 S/s single channel typical, PC dependent
Single channel, continuous scan		10 kS/s
Dual channel, continuous scan, simultaneous update		5 kS/s
Power on and reset voltage		0V, ± 20 mV typ. (initializes to 000h code)
Output drive	Each D/A OUT	± 15 mA
Slew rate		0.8 V/microsecond (μ s) typ

Dijital I/O özellikleri

Digital type	CMOS
Number of I/O	16 (Port A0 through A7, Port B0 through B7)
Configuration	2 banks of 8
Pull-up/pull-down configuration	All pins pulled up to Vs via 47 K resistors (default). Positions available for pull-down to ground. Hardware selectable via zero ohm (Ω) resistors as a factory option.
Input high voltage	2.0 V min, 5.5 V absolute max
Input low voltage	0.8 V max, .05 V absolute min
Output high voltage (IOH = .25 mA)	3.8 V min
Output low voltage (IOL = 2.5 mA)	0.7 V max
Power on and reset state	Input

Sayıcı özellikleri

Pin name (Note 9)	CTR
Counter type	Event counter
Number of channels	1
Input type	TTL, rising edge triggered
Input source	CTR screw terminal
Resolution	32 bits
Schmidt trigger hysteresis	20 mV to 100mV
Input leakage current	± 1 μ A
Maximum input frequency	1 MHz
High pulse width	500 ns min
Low pulse width	500 ns min
Input high voltage	4.0 Vmin, 5.5Vabsolute max
Input low voltage	1.0 Vmax, .05Vabsolute min

Güç Özellikleri

Parameter	Conditions	Specification
Supply current (Note 10)		80 mA
+5V USB power available (Note 11)	Connected to self-powered hub Connected to externally-powered root port hub	4.5 V min, 5.25 V max
Connected to bus-powered hub		4.1 V min, 5.25 V max
Output current (Note 12)	Connected to self-powered hub Connected to externally-powered root port hub	420 mA max
Connected to bus-powered hub		20 mA max

Single-Ended Modda Doğruluk değerleri

Range	Absolute Accuracy 25°C (±mV)	Absolute Accuracy 0 to 50°C (±mV)
±10 V	10.98	49.08

Modlara göre pin ve sinyal isimleri

4-channel differential mode				8-channel single-ended mode			
Pin	Signal Name	Pin	Signal Name	Pin	Signal Name	Pin	Signal Name
1	CH0 IN HI	21	Port A0	1	CH0 IN	21	Port A0
2	CH0 IN LO	22	Port A1	2	CH1 IN	22	Port A1
3	AGND	23	Port A2	3	AGND	23	Port A2
4	CH1 IN HI	24	Port A3	4	CH2 IN	24	Port A3
5	CH1 IN LO	25	Port A4	5	CH3 IN	25	Port A4
6	AGND	26	Port A5	6	AGND	26	Port A5
7	CH2 IN HI	27	Port A6	7	CH4 IN	27	Port A6
8	CH2 IN LO	28	Port A7	8	CH5 IN	28	Port A7
9	AGND	29	GND	9	AGND	29	GND
10	CH3 IN HI	30	PC+5V	10	CH6 IN	30	PC+5V
11	CH3 IN LO	31	GND	11	CH7 IN	31	GND
12	AGND	32	Port B0	12	AGND	32	Port B0
13	D/A OUT 0	33	Port B1	13	D/A OUT 0	33	Port B1
14	D/A OUT 1	34	Port B2	14	D/A OUT 1	34	Port B2
15	AGND	35	Port B3	15	AGND	35	Port B3
16	+2.5VREF	36	Port B4	16	+2.5VREF	36	Port B4
17	GND	37	Port B5	17	GND	37	Port B5
18	TRIGIN	38	Port B6	18	TRIGIN	38	Port B6
19	SYNC	39	Port B7	19	SYNC	39	Port B7
20	CTR	40	GND	20	CTR	40	GND

EK 7: Duyarlılık, Belirlilik ve Ortalama Tanıma Oranı Parametrelerinin Hesaplanması ve tez çalışmasında elde edilen sonuçların bu parametreler ile yorumlanması

Doğru Pozitif (DP): Uzman tarafından hasta (aritmi var) olarak etiketlenmiş bir verinin sınıflayıcı tarafından hasta (aritmi var) olarak sınıflandırılması

Doğru Negatif (DN): Uzman tarafından sağlıklı (aritmi yok) olarak etiketlenmiş bir verinin sınıflayıcı tarafından sağlıklı (aritmi yok) olarak sınıflandırılması

Yanlış Pozitif (YP): Uzman tarafından sağlıklı (aritmi yok) olarak etiketlenmiş bir verinin sınıflayıcı tarafından hasta (aritmi var) olarak sınıflandırılması

Yanlış Negatif (YN): Uzman tarafından hasta (aritmi var) olarak etiketlenmiş bir verinin sınıflayıcı tarafından sağlıklı (aritmi yok) olarak sınıflandırılması

Duyarlılık: Sınıflayıcının hastalığı belirleyebilme oranıdır.

$$\text{Duyarlılık} = \% \frac{DP}{DP + YN}$$

Belirlilik: Sınıflayıcının sağlıklıyı belirleyebilme oranıdır.

$$\text{Belirlilik} = \% \frac{DN}{DN + YP}$$

Ortalama Tanıma Oranı: Duyarlılık ve Belirliliğin ortalamasıdır.

$$\text{Duyarlılık} = \frac{\text{Duyarlılık} + \text{Belirlilik}}{2}$$