

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**PARÇACIK SÜRÜ OPTİMİZASYONUNA DAYALI YENİ BİR ARİTMİ
SINIFLAMA YÖNTEMİ**

**YÜKSEK LİSANS TEZİ
Berat DOĞAN**

Anabilim Dalı : Elektronik ve Haberleşme Mühendisliği

Programı : Biyomedikal Mühendisliği

HAZİRAN 2009

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**PARÇACIK SÜRÜ OPTİMİZASYONUNA DAYALI YENİ BİR ARİTMİ
SINIFLAMA YÖNTEMİ**

YÜKSEK LİSANS TEZİ
Berat DOĞAN
(504061403)

Tezin Enstitüye Verildiği Tarih : 04 Mayıs 2009
Tezin Savunulduğu Tarih : 05 Haziran 2009

Tez Danışmanı : Doç. Dr. Mehmet KORÜREK (İTÜ)
Eş Danışman : Doç. Dr. Mustafa YILDIZ
Diğer Jüri Üyeleri : Prof. Dr. A. Hamdi KAYRAN (İTÜ)
Prof. Dr. Serhat ŞEKER (İTÜ)
Prof. Dr. Tülay YILDIRIM (YTÜ)

HAZİRAN 2009

ÖNSÖZ

“Parçacık sürü optimizasyonuna dayalı yeni bir artımlı sınıflama yöntemi” isimli yüksek lisans tez çalışmamı tamamlamış bulunmaktayım. Bu çalışmanın gerçekleştirilmesinde yardım, destek ve katkılarını eksik etmeyen değerli hocalarıma, arkadaşlarıma ve aileme sonsuz şükranlarımı sunarım.

Tez çalışmamın her aşamasında büyük emeği bulunan, karşılaştığım her türlü sorunu aşmamda sabırla yol gösteren, engin tecrübesi ve özverişi ile bilimsel düşünce ufkumu genişleten danışman hocam Sayın Doç.Dr. Mehmet Korürek’e; değerli fikirleriyle bana yol gösteren Sayın Doç. Dr. Mustafa Yıldız’a; bu tezi hazırlayabilecek bilgi birikiminini kazanmamda büyük emekleri olan saygıdeğer hocalarım Prof. Dr. Tamer Ölmez ve Doç. Dr. Zümray Dokur Ölmez’e sonsuz şükranlarımı sunarım.

Yaşantım boyunca her konuda desteklerini benden esirgemeyen, bugünlere gelmemde en büyük vesile olan sevgili anneme, babama ve kardeşlerime sonsuz şükranlarımı sunarım.

Ayrıca yüksek lisans eğitimim süresince maddi desteğiyle şahsıma katkıda bulunmuş olan TÜBİTAK Bilim İnsanı Destekleme Daire Başkanlığı’na teşekkürü bir borç bilirim.

Haziran 2009

Berat Doğan
(Elektronik Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iii
İÇİNDEKİLER.....	v
KISALTMALAR	vii
ÇİZELGE LİSTESİ.....	ix
ŞEKİL LİSTESİ.....	xi
ÖZET.....	xiii
SUMMARY.....	xvii
1. GİRİŞ	1
1.1 Tezin Amacı.....	1
1.2 Literatür Özeti	2
2. KALP KASININ UYARI VE İLETİM SİSTEMİ	7
2.1 Amaç.....	7
2.2 Hücre Membranında Dinlenme Potansiyeli ve Aksiyon Potansiyelinin Oluşumu.....	7
2.3 Normal Elektrokardiyogram	12
2.3.1 Elektrokardiyogram için normal değerler	13
2.4 Elektrokardiyogram Kaydetme Yöntemleri.....	14
2.4.1 Standart bipolar ekstremite derivasyonlar	14
2.4.1.1 Einthoven üçgeni	15
2.4.1.2 Standart bipolar ekstremite derivasyonları.....	15
2.4.2 Standart göğüs derivasyonları	16
2.4.3 Yükseltilmiş (Augmented) unipolar derivasyonlar	17
2.5 Aritmiler.....	18
2.5.1 Normal sinüs ritmi	19
2.5.2 Uyarı oluşumu bozuklukları.....	20
2.5.2.1 Sinüs bradikardisi	20
2.5.2.2 Sinüs taşikardisi	20
2.5.2.3 Sinüs aritmisi	21
2.5.2.4 Sinüs duraklaması	22
2.5.2.5 Prematür atriyal kontraksiyon	22
2.5.2.6 Paroksismal supraventriküler taşikardi	23
2.5.2.7 Atriyal taşikardi	23
2.5.2.8 Atriyal flutter	23
2.5.2.9 Atriyal fibrilasyon.....	25
2.5.2.10 Prematür ventrikül kontraksiyonları	25
2.5.2.11 Ventrikül taşikardisi	26
2.5.2.12 Ventrikül fibrilasyonu	27
2.5.3 Uyarı iletimi bozuklukları.....	27
2.5.3.1 Atriyoventriküler bloklar	28
1 ⁰ Atriyoventriküler blok	28
2 ⁰ Atriyoventriküler Blok	28
3 ⁰ Atriyoventriküler Blok	29
2.5.3.2 İntraventriküler ileti blokları	30

Sol dal bloğu	30
Sağ dal bloğu	30
2.5.4 Uyarı oluşumunun ve iletiminin karışık bozuklukları	31
2.5.4.1 Füzyon vurumu	31
2.5.5 MIT-BIH aritmi veri tabanı	32
3. ÖN İŞLEMLER VE ÖZNİTELİK ÇIKARTMA	33
3.1 Amaç	33
3.2 İşaretlerden Gürültü ve Taban Hattı Kayması Gibi Etkilerin Giderilmesi.....	34
3.3 QRS Deteksiyonu ve Pan-Tompkins Algoritması	35
3.3.1 Tamsayı katsayılı bant geçiren filtre	37
3.3.1.1 Alçak geçiren filtre	38
3.3.1.2 Yüksek geçiren filtre	39
3.3.2 Diferansiyel işlemi	41
3.3.3 Kare alma işlemi	41
3.3.4 Kayan pencere integratör.....	41
3.3.5 Eşikleme	42
3.4 Öznitelik Çıkartma	45
3.4.1 Normalizasyon işlemi.....	47
3.5 Öznitelik Çıkartma Yöntemleri	49
3.5.1 EKG işaretlerinden şekilsel özniteliklerin çıkartılması.....	49
4. YAPAY SİNİR AĞLARI VE PARÇACIK SÜRÜ OPTİMİZASYONU	55
4.1 Amaç	55
4.2 Yapay Sinir Ağları	55
4.2.1 Yapay sinir ağlarının öğrenme yöntemleri	57
4.2.1.1 Danışmanlı öğrenme.....	57
4.2.1.2 Danışmansız öğrenme	58
4.2.1.3 Takviyeli öğrenme.....	58
4.2.2 Radyal Tabanlı Fonksiyon Yapay Sinir Ağı.....	58
4.2.3 Radyal tabanlı fonksiyon yapay sinir ağının eğitimi.....	61
4.2.3.1 K-Ortalamalar algoritması	62
4.2.3.2 Kohonen ağı.....	63
4.2.4 Radyal tabanlı fonksiyon yapay sinir ağının k-ortalamalar ve Kohonen algoritmaları ile eğitilmesi	66
4.3 Parçacık Sürü Optimizasyonu.....	69
4.3.1 PSO algoritması	71
4.3.1.1 PSO algoritmasındaki parametrelerin incelenmesi ve algoritmanın performansını arttırmaya yönelik düzenlemeler.....	74
Atalet Katsayısı	77
5. RADYAL TABANLI FONKSİYON YAPAY SİNİR AĞININ PARÇACIK SÜRÜ OPTİMİZASYONU İLE EĞİTİLMESİ	79
5.1 Yöntem	79
5.2 PSO-RTFA'nın Fantom Öznitelik Uzayını Bölütlemesi	80
5.3 PSO-RTFA ile EKG Vurularının Sınıflandırılması	83
5.4 Sonuçlar ve Tartışma.....	90
KAYNAKLAR.....	93
EKLER	97

KISALTMALAR

A	: Atrial Prematüre Vuru (Atrial Premature Beat)
Å	: Angstrom
AHA	: The American Heart Association
AV	: Atrioventriküler
ECG	: Electrocardiogram
EKG	: Elektrokardiyogram
EMG	: Elektromiyogram
F	: Ventriküler Füzyon (Ventricular and Normal Beat Fusion)
f	: Yapay ve Normal Vuru Füzyonu (Paced and normal Beat Fusion)
kNN	: k-nearest Neighbour
LBBB	: Left Bundle Branch Block Beat
MIT-BIH	: Massachusetts Institute of Technology - Beth Israel Hospital
N	: Normal Vuru (Normal beat)
PSO	: Parçacık Sürü Optimizasyonu (Particle Swarm Optimization)
PVC	: Premature Ventricular Contraction
R	: Sağ Yan Dal Bloğu (Right Bundle Branch Block Beat)
RAM	: Random Access Memory
RBBB	: Right Bundle Branch Block Beat
RBF	: Radial Basis Function
RTF	: Radyal tabanlı fonksiyon
RTFA	: Radyal Tabanlı Fonksiyon Yapay Sinir Ağı
SOM	: Self Organising Map
SVM	: Support Vector Machine
V	: Premature Venriküler Kontraksiyon
YSA	: Yapay Sinir Ağı

ÇİZELGE LİSTESİ

Sayfa

Çizelge 5. 1: Fantom uzayı bölütlemek için PSO algoritmasında kullanılan parametreler.....	81
Çizelge 5. 2 : EKG vurularını sınıflamak için PSO algoritmasında kullanılan parametreler.....	83
Çizelge 5. 3 : Önerilen yöntemin yapılan bir deneme için vuru bazında sınıflama sonucu	86
Çizelge 5. 4 : PSO-RTFA ile 10 nöron için yapılan on denemenin ortalama sonucu	88
Çizelge 5. 5 : Farklı sınıflayıcıların karşılaştırılması	89

ŞEKİL LİSTESİ

Sayfa

Şekil 2. 1 : Hücre membranında aksiyon potansiyelinin oluşumu [18].....	8
Şekil 2. 2 : Kalbin temel yapısı [18].....	9
Şekil 2. 3 : Kalbin uyarı ve iletim sistemi [18].....	11
Şekil 2. 4 : Fiberler ve iletim mekanizması üzerindeki aksiyon potansiyelinin ulaşım süreleri [18].....	12
Şekil 2. 5 : Normal elektrokardiyogram [18].....	12
Şekil 2. 6 : Standart bipolar ektremite derivasyonları [18].....	14
Şekil 2. 7 : Standart bipolar ektremite derivasyonları ile kaydedilen.....	16
Şekil 2. 8 : Standart göğüs derivasyonları [18].....	16
Şekil 2. 9 : Standart göğüs derivasyonları ile kaydedilen elektrokardiyogram	17
Şekil 2. 10 : Yükseltilmiş unipolar derivasyonlarla kaydedilen normal.....	18
Şekil 2. 11 : Normal sinüs ritmi	19
Şekil 2. 12 : Sinüs bradikardisi	20
Şekil 2. 13 : Akut miyokard iskemisi sırasında ST segment depresyonu ile birlikte seyreden sinüs taşikardisi (150 vuru/dak).....	21
Şekil 2. 14 : Sinüs aritmisi	21
Şekil 2. 15 : Sinüs duraklaması	22
Şekil 2. 16 : Prematüre atriyal erken vurular	22
Şekil 2. 17 : Paroksismal atriyal taşikardi.....	23
Şekil 2. 18 : Atriyal taşikardi	24
Şekil 2. 19 : Atriyal flutter	24
Şekil 2. 20 : Atriyal fibrilasyon.....	25
Şekil 2. 21 : Prematüre ventriküler vurular (PVC).....	26
Şekil 2. 22 : Ventrikül taşikardisi	27
Şekil 2. 23 : Ventrikül fibrilasyonu	27
Şekil 2. 24 : Birinci derece atriyoventriküler blok	28
Şekil 2. 25 : Mobitz tip I (Wenkebach) blok	29
Şekil 2. 26 : Mobitz tip II blok.....	29
Şekil 2. 27 : Üçüncü derece atriyoventriküler blok.....	29
Şekil 2. 28 : Sol dal bloğu	30
Şekil 2. 29 : Sağ dal bloğu	31
Şekil 3. 1 : Taban hattı kayması ve 60 Hz şebeke gürültüsü bileşenine sahip işaret.....	33
Şekil 3. 2 : Taban hattı kayması giderilmiş işaret	34
Şekil 3. 3 : 60 Hz şebeke gürültüsünü gidermek için kullanılan filtrenin frekans- genlik cevabı	35
Şekil 3. 4 : 60 Hz şebeke gürültüsü bastırılmış işaret.....	36
Şekil 3. 5 : QRS belirleme aşamaları.....	36
Şekil 3. 6 : Alçak geçiren filtrenin frekans – genlik cevabı.....	38
Şekil 3. 7 : Yüksek geçiren filtre, alçak geçiren filtrenin bir tüm-geçiren (all-pass)	39
Şekil 3. 8 : Yüksek geçiren filtre a) Genlik cevabı b) faz cevabı.....	40
Şekil 3. 9 : Bant geçiren filtrenin frekans-genlik cevabı	40

Şekil 3. 10 : Türev alma işlemi sonucu EKG kaydı.....	42
Şekil 3. 11 : Kare alma işlemi sonucu EKG kaydı	43
Şekil 3. 12 : Kayan pencere integratör işlemi sonucu EKG kaydı	44
Şekil 3. 13 : Eşikleme sonrasında oluşan kare dalga işaret	44
Şekil 3. 14 : R tepeleri bulunmuş orijinal EKG kaydı	45
Şekil 3. 15 : Örnek bir öznitelik uzayı	46
Şekil 3. 16 : Karar verme mekanizması	47
Şekil 3. 17 : Çeşitli aritmilerde kalp ritmindeki değişim [23]	50
Şekil 3. 18 : RR_{t_n} ve $RR_{t_{n+1}}$ özniteliklerinin elde edilmesi.....	51
Şekil 3. 19 : a) RR_{t_n} öznitelik elemanlarının veri kümesi içindeki dağılımı b).....	52
Şekil 3. 20 : Normalizasyon sonrası QRS_{h_n} öznitelik elemanlarının veri kümesi..	53
Şekil 3. 21 : QRS_{g_n} özniteliğinin veri kümesi içindeki dağılımı	54
Şekil 4. 1 : İşlem elemanının yapısı	56
Şekil 4. 2 : İşlem elemanının eğitimi [25]	57
Şekil 4. 3 : (a) Gaussian fonksiyon (b) Multiquadric fonksiyon	59
Şekil 4. 4 : Sınıf öbekleri için Gaussian fonksiyon modeli	60
Şekil 4. 5 : Radyal tabanlı fonksiyon yapay sinir ağının genel yapısı	61
Şekil 4. 6 : Kohonen ağının yapısı [33].....	65
Şekil 4. 7 : Sabit σ değeri için sınıf dağılımı	66
Şekil 4. 8 : Temel PSO algoritmasının sözde-kodu [37].....	74
Şekil 4. 9 : $v_{\max}$ değeri için bir limitin belirlenmediği durum. Bu durumda, küresel minimum noktasının (0,0) olduğu göz önünde bulundurulursa, 150 iterasyon sonunda parçacıkların bu noktadan bir hayli uzaklaşmış oldukları görülebilir [37].	75
Şekil 4. 10 : $v_{\max} = 2.0$ durumu. Bu durumda parçacıklar daha dar bir alanda gezinmelerine rağmen hala (0,0) küresel minimum değerinden uzaklar [37].	76
Şekil 4. 11 : $v_{\max} = 0.2$ durumu. Bu durumda parçacıklar daha da dar bir alanda gezinmekte ve küresel minimum değeri olan (0,0) noktasına oldukça yakınlar [37]......	76
Şekil 5. 1 : Fantom öznitelik uzayı	81
Şekil 5. 2 : Sınıflamada kullanılan sistemin blok diyagramı.....	83
Şekil 5. 3: PSO-RTFA ile K-ortalamlar algoritmasının karşılaştırılması.....	84
Şekil 5. 4 : Bütün nöronlar için aynı yayılım parametresi kullanıldığı durumda	85
Şekil 5. 5 : Bütün nöronlar için aynı yayılım parametresinin kullanıldığı durum ile	87
Şekil 5. 6 : Girilen bir EKG kaydını sınıflamak için tasarlanan grafik arayüz.....	90
Şekil A. 1 : PSO-RTFA'nın fantom uzayı bölütlemesi.....	98
Şekil A. 2 : PSO-RTFA'nın fantom uzayı bölütlemesi (yayılım parametresi bütün nöronlar için aynı seçildiğinde).....	99
Şekil A. 3 : RTFA – K-Ortalamlar'ın fantom uzayı bölütlemesi.....	100

PARÇACIK SÜRÜ OPTİMİZASYONUNA DAYALI YENİ BİR ARİTMİ SINIFLAMA YÖNTEMİ

ÖZET

Kalbin elektriksel aktivitesi hakkında bilgi veren EKG, kalp hastalıklarının teşhisinde ve tedavi yöntemlerinin belirlenmesinde hayati bir önem arz etmektedir. Klinik ortamda bu kadar öneme sahip olan EKG kayıtlarının analizi çoğu zaman doktorlar açısından oldukça zaman alıcı olabilmektedir. Bu nedenle, hızlı işlem yapabilen bilgisayarların kullanılmaya başlamasından bugüne EKG kayıtlarının dijital ortamda analizi gittikçe yaygınlaşan bir yöntem haline gelmiştir. Geliştirilen algoritmalar vasıtasıyla herhangi bir EKG kaydında var olan anormallikler kolaylıkla ayırt edilebilmektedir.

EKG'deki şekil ve ritm bozukluklarını (aritmileri) tespit etmek amacıyla kullanılan algoritmaların temel prensibi örüntü tanımaya dayanmaktadır. Örüntü tanıma problemlerinde en sık kullanılan yöntemlerden biri de son yıllarda birçok mühendislik probleminin çözümünde kullanılan yapay sinir ağı temelli yaklaşımlardır.

Yapay sinir ağları (YSA), beyin fizyolojisinden yararlanılarak oluşturulan bilgi işleme modelleridir. Bu yapılar herhangi bir problemin çözümü için var olan girdi ve çıktılar arasındaki ilişkiyi, doğrusal olsun veya olmasın, eldeki mevcut örneklerden öğrenir ve karşılaşılan problemlere çözüm üretebilme yeteneği kazanırlar.

Yapay sinir ağlarının eğitiminde kullanılan yaklaşımlar ve giriş verilerinin özellikleri bu ağların karşılaştıkları problemler karşısında genelleme yapabilme yeteneklerini önemli ölçüde etkilemektedir. Bu tez kapsamında son yıllarda birçok uygulamada kullanılan bir yapay sinir ağı modeli olan “Radyal Tabanlı Fonksiyon Yapay Sinir Ağı”, (RTFYSA) kullanılmıştır. Bu ağ yapısı farklı öğrenme algoritmalarıyla eğitilebilmektedir. Tez kapsamında bu ağı eğitmek için son yıllarda ortaya atılan bir evrimsel programlama yöntemi olan “Parçacık Sürü Optimizasyonu” (PSO) kullanılmıştır.

Ağın eğitimi için MIT-BIH aritmi veri tabanından alınan kayıtlar ön işlemden geçirilmiş ve işaretler üzerinde var olan gürültüler, taban hattı kayması gibi etkiler giderilmiştir. Daha sonra bu kayıtlardan ayıklanan altı farklı vuru tipine ait dört adet şekilsel öznitelik çıkartılmıştır. Eğitim kümesi her bir vuru tipinden 50’şer adet olmak üzere toplam 300 adet öznitelik vektöründen oluşmaktadır. PSO algoritması kullanılarak, RTFYSA bu öznitelikler yardımıyla eğitilmiş ve optimum ağ yapısı bulunmaya çalışılmıştır.

Radyal tabanlı fonksiyon yapay sinir ağını eğitmek için önerilen yöntem, geleneksel yöntemler olan K-ortalamlar ve Kohonen yöntemleri ile kıyaslanmış ve sonuçlar yorumlanmıştır. Ayrıca önerilen yöntem çok basit fakat bir o kadar da etkili bir sınıflama yöntemi olan k-en yakın komşuya sınıflama yöntemiyle de kıyaslanmıştır.

Bölüm 1’de EKG aritmilerinin teşhisi için literatürde özellikle son yıllarda kullanılan yöntemlerin kısa bir özetine değinilmektedir. Bu yöntemler birbirlerinden farklılık arz etmekle birlikte çoğunlukla yapay sinir ağına dayalı yöntemlerdir.

İkinci bölümde kalpte elektriksel uyarıların oluşumu ve iletilmesi ile ilgili temel bilgilere değinilmektedir. Normal elektrokardiyogramın özellikleri ve kaydedilme yöntemleri hakkında bilgi verildikten sonra EKG’de meydana gelen şekil ve ritm bozukluklarına değinilmektedir. Son olarak bu çalışmada kullanılan MIT-BIH aritmi veri tabanı hakkında kısa bir bilgi verilmektedir.

Üçüncü bölümde, MIT-BIH aritmi veri tabanından alınan EKG kayıtlarının ön işlemlerden geçirilmesi (gürültülerden arındırılması, taban hattı kaymasının giderilmesi) gibi konulara değinilmektedir. Sonrasında EKG kayıtlarındaki vuruları ayıklayabilmek için R tepelerinin tespiti gerektiğinden bu anlamda en çok kullanılan yöntemlerden biri olan Pan-Tompkins algoritmasına değinilmektedir. Bölüm sonuna doğru tez kapsamında kullanılan özniteliklerden bahsedilmektedir.

Dördüncü bölümde yapay sinir ağları hakkında genel bir bilgi verildikten sonra, radyal tabanlı fonksiyon yapay sinir ağına detaylı bir şekilde değinilmektedir. Radyal tabanlı fonksiyon yapay sinir ağının eğitiminde kullanılan geleneksel yöntemler üzerinde durulmaktadır. Son olarak parçacık sürü optimizasyona detaylı bir şekilde değinilmektedir.

Son bölüm olan beşinci bölümde radyal tabanlı fonksiyon yapay sinir ağının nöron merkezleri ve her bir nöronun yayılım parametresi, parçacık sürü optimizasyonu ile eğitilip optimum ağ yapısı bulunmaya çalışılmaktadır. Aynı işlem sadece nöron merkezlerinin eğitimi için kullanılmakta ve nöron yayılım parametrelerini sabit kabul etmenin sınıflamaya olan etkisi incelenmektedir. Geleneksel eğitim yöntemleriyle önerilen yöntem karşılaştırılmakta ve sonuçlar yorumlanmaktadır. Çizelge 1’de önerilen yöntemin, normal sinüs ritmi (“normal beat, N”), erken karıncık atımları (“premature ventricular contraction”, PVC), karıncık ve normal vuru füzyonu (ventricular and normal beat fusion, F), erken kulakçık atımları (“atrial premature contraction”, A), sağ yan dal bloğu (“right bundle branch block”, R) ve yapay ve normal vuru füzyonu (“paced and normal beat fusion”, f), olmak üzere altı farklı vuru tipini sınıflama başarısı gösterilmektedir. Çizelge 1’de verilen sonuç yapılan 10 farklı denemenin ortalamasıdır.

Çizelge 1 : PSO-RTFA ile on nöron için yapılan on denemenin ortalama sonucu

N				PVC				F				A				R				f						
TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	Duyarlılık	Belirlilik	
1.	809	27	18	1280	571	34	2	1527	233	15	33	1853	160	5	25	1944	145	5	12	1972	126	4	1	2003	95.94	99.15
2.	784	52	17	1281	569	36	5	1524	232	16	68	1818	160	5	11	1958	145	5	14	1970	128	2	1	2003	95.58	98.91
3.	770	66	27	1271	572	33	5	1524	232	16	76	1810	150	15	14	1955	145	5	14	1970	128	2	1	2003	94.34	98.71
4.	789	47	18	1280	569	36	6	1523	231	17	50	1836	159	6	25	1944	147	3	14	1970	124	6	2	2002	95.22	98.92
5.	794	42	18	1280	569	36	2	1527	233	15	63	1823	160	5	12	1957	146	4	12	1972	124	6	1	2003	95.44	98.98
6.	797	39	19	1279	568	37	2	1527	233	15	32	1854	160	5	25	1944	146	4	14	1970	125	5	3	2001	95.60	99.10
7.	802	34	20	1278	553	52	1	1528	234	14	80	1806	155	10	10	1959	146	4	17	1967	116	14	0	2004	93.70	99.41
8.	796	40	17	1281	577	28	4	1525	232	16	45	1841	161	4	12	1957	146	4	14	1970	128	2	2	2002	96.25	99.11
9.	779	57	15	1283	576	29	5	1525	234	14	58	1828	159	6	20	1949	147	3	14	1970	127	3	1	2003	95.80	98.94
10.	762	74	15	1283	567	38	2	1527	234	14	97	1789	159	6	13	1956	148	2	14	1970	121	9	2	2002	94.55	98.66
Ortalama																							95.24	98.99		

A NEW ARRHYTHMIA CLASSIFICATION METHOD BASED ON PARTICLE SWARM OPTIMIZATION

SUMMARY

ECG has a vital importance on the diagnosis and the treatment of many heart disease. Although it has such an importance at clinical trials, it is usually a very time consuming job for the doctors to analyse long ECG records. Therefore, nowadays automatically analysis methods of the ECG records by fast computers is a growing way of the diagnosis of many heart abnormalities. By means of many algorithms, today many heart abnormalities can be diagnosed easily.

The fundamental principle of these algorithms are usually based on pattern recognition methods. One of the most common method for pattern recognition problems is to use artificial neural networks which are widely used to solve many engineering problems.

The methods and the input datas which are used for the training of the artificial neural networks have a major effect on the generalization ability of these networks. Within the context of this thesis, a recently proposed neural network structure, the Radial Basis Function Neural Network (RBFNN) was used. This network can be trained in different methods. In this thesis, a newly proposed evolutionary programming method, the Particle Swarm Optimization (PSO) is used for the training of the RBFNN.

In the training phase, the records which are selected from the MIT-BIH arrhythmia database are preprocessed and the effects such as noise and the baseline drift are removed from the signals. Then, four morphological features were extracted from the records including six types of ECG beats. The training set includes 300 feature vectors, which consists of 50 feature vectors for each type of ECG beat. By means of the PSO algorithm, this datas are used to find optimum RBFNN network structure.

The method which is proposed to evolve the RBFNN is compared with the traditional methods such as K-Means and Kohonen and the results are interpreted. Also, the k-nearest neighbour classifier is used to compare the performance of the network.

In chapter 1, the recent studies about the automatically diagnosis of the hearbeat abnormalities are summarized. These methods are generally different from one another but more often they are based on the artificial neural networks.

Chapter 2 gives a detailed information about the rhythmical excitation system of the heart and the normal electrocardiogram. Then, a brief information about the heart abnormalities is given and the MIT-BIH arrhythmia database is introduced shortly.

Chapter 3 consists of the methods which are used for the preprocessing of the ECG records which are selected from the MIT-BIH arrhythmia database. Then the famous Pan-Tompkins algorithm is introduced for the R peak detection of the ECG beats

within the selected records. The last part of this chapter gives information about the features which are used within the scope of this thesis.

Chapter 4 begins with a general information about the artificial neural networks. Then specifically the RBFNN and the traditional methods of training the RBFNN are introduced. Then a detailed information about the particle swarm optimization is given.

At the last chapter of the thesis, the proposed method for evolving the RBFNN is given. Finally the results of the several experiments with the proposed method and the traditional methods are compared and interpreted. Table 1. lists the classification performance of the proposed method for six types of ECG beats including, normal beat (N), premature ventricular contraction (PVC), fusion of ventricular and normal beat (F), atrial premature beat (A), right bundle branch block beat (R) and the fusion of paced and normal beat (f). The result is the average result of ten different experiments.

Table 1 : Average result of ten experiments with ten neurons PSO-RBFNN

	N				PVC				F				A				R				f					
	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	*Se %	*Sp %
1.	809	27	18	1280	571	34	2	1527	233	15	33	1853	160	5	25	1944	145	5	12	1972	126	4	1	2003	95.94	99.15
2.	784	52	17	1281	569	36	5	1524	232	16	68	1818	160	5	11	1958	145	5	14	1970	128	2	1	2003	95.58	98.91
3.	770	66	27	1271	572	33	5	1524	232	16	76	1810	150	15	14	1955	145	5	14	1970	128	2	1	2003	94.34	98.71
4.	789	47	18	1280	569	36	6	1523	231	17	50	1836	159	6	25	1944	147	3	14	1970	124	6	2	2002	95.22	98.92
5.	794	42	18	1280	569	36	2	1527	233	15	63	1823	160	5	12	1957	146	4	12	1972	124	6	1	2003	95.44	98.98
6.	797	39	19	1279	568	37	2	1527	233	15	32	1854	160	5	25	1944	146	4	14	1970	125	5	3	2001	95.60	99.10
7.	802	34	20	1278	553	52	1	1528	234	14	80	1806	155	10	10	1959	146	4	17	1967	116	14	0	2004	93.70	99.41
8.	796	40	17	1281	577	28	4	1525	232	16	45	1841	161	4	12	1957	146	4	14	1970	128	2	2	2002	96.25	99.11
9.	779	57	15	1283	576	29	5	1525	234	14	58	1828	159	6	20	1949	147	3	14	1970	127	3	1	2003	95.80	98.94
10.	762	74	15	1283	567	38	2	1527	234	14	97	1789	159	6	13	1956	148	2	14	1970	121	9	2	2002	94.55	98.66
Ortalama																									95.24	98.99

*Se Sensitivity (Duyarlılık), *Sp Specificity (Belirlilik)

1. GİRİŞ

Kalbin elektriksel aktivitesi hakkında bilgi veren EKG'nin kalp hastalıklarının teşhisinde ve tedavi yöntemlerinin belirlenmesinde önemi büyüktür. Kalbin elektriksel iletim yollarında veya kalp kasını besleyen damarlarda meydana gelen herhangi bir anormallik elektrokardiyogram işaretinin normal formunun dışına çıkmasına sebep olabilmektedir. Herhangi bir hastadan alınan EKG kaydını inceleyerek doktorlar, kalpteki anormallikleri teşhis edebilmektedir. Bununla beraber EKG vurularının normal formunun ne zaman dışına çıkacağı daha doğrusu hastalık belirtisinin ne zaman meydana geleceği önceden kestirilemeyebilir. Bu durumda hastanın uzun süreli EKG kaydının yapılması gerekmektedir. Hasta normal yaşantısına devam ederken bir yandan da “Holter EKG” cihazı yardımıyla hasta kalbinin elektriksel aktivitesi kaydedilebilmektedir. Kısa bir EKG kaydı içerisinde bile onlarca EKG vurusunun olduğu göz önünde bulundurulursa, uzun süreli bu kaydın incelenmesinin ne kadar zaman alıcı bir iş olduğu anlaşılabilir. Bu yüzden bilim insanları bu kayıtların bilgisayarlar yardımıyla otomatik olarak analiz edilebilmesini amaçlayan yöntemler geliştirmişlerdir.

1.1 Tezin Amacı

EKG vurularındaki anormalliklerin otomatik teşhisine yönelik araştırmalar özellikle son yıllarda yapay zeka uygulamalarının gelişmesiyle birlikte hız kazanmıştır. Bu uygulamalar insanın karar verme mekanizmasını, doğadaki canlıların birbirleriyle olan etkileşimlerini vb. inceleyerek geliştirilen uygulamalardır. Bu tez kapsamında da insan beyin fizyolojisinin bir modeli olarak tanımlanabilecek yapay sinir ağlarının bir çeşidi olan radyal tabanlı fonksiyon yapay sinir ağları, kuş ve balık sürülerinin incelenmesiyle geliştirilen, görece yeni bir optimizasyon tekniği olan, parçacık sürü optimizasyonu yöntemiyle eğitilmiş ve yukarıda bahsi geçen EKG vurularındaki anormalliklerin eğitilen bu ağ ile tespit edilmesi amaçlanmıştır.

1.2 Literatür Özeti

Literatürde EKG vurularındaki anormalliklerin otomatik teşhisine yönelik birçok çalışma mevcuttur. Bu çalışmalar çoğunlukla yapay sinir ağlarına dayalı örüntü tanıma yaklaşımları olmakla birlikte farklı yöntemleri de içermektedir. Özellikle farklı tipteki vuruları çok boyutlu uzayda birbirlerinden ayırt edebilmek için kullanılan öznitelik çıkartma yöntemleri ve farklı sınıflayıcı yapıları, çalışmaları birbirlerinden farklı kılan temel belirleyicilerdir. Bu anlamda literatürde son yıllarda öne sürülen ve farklı sayılabilecek yeni yöntemler üstünde durulmuştur. Şüphesiz bu konuda yapılan çalışma örneklerini çoğaltmak mümkündür.

Yinelemeli yapay sinir ağlarının Levenberg-Marquardt algoritması ile eğitilip EKG vurularını sınıflama başarısını değerlendiren bir çalışmada, dört tip EKG vurusu (normal vuru, cengestive heart failure beat, ventriküler taşiaritmi vurusu, atrial fibrilasyon) Physiobank veri tabanından alınarak analiz edilmiştir [1]. Karar üretme iki aşamada yapılmıştır: öz vektör yöntemi ile öznitelik çıkartma ve RNN ile sınıflama. RNN' ler istatistiksel öznitelikler ile EKG vurularını sınıflamak için gerçekleştirilmişlerdir. Sınıflama sonuçlarından bu yöntemin sınıflama için uygun olduğu görülmüştür. Diğer bir çalışmada, hata düzeltici çıkış kodu ile çok sınıflı destek vektör makinaları yöntemine dayalı yeni bir EKG vuru sınıflama yöntemi öne sürülmüştür [2]. Physiobank veri tabanından alınan dört tip EKG vurusu analiz edilmiştir. Öznitelik elemanları olarak dalgacık katsayıları kullanılmıştır. Çalışmanın amacı EKG vurularını wavelet dönüşümü ve çok sınıflı destek vektör makinalarını kullanıp sınıflamaktır. Sınıflama sonucunda yöntemin yüksek bir sınıflama başarısı verdiği gözlenmiştir. EKG aritmilerinin teşhisi için önerilen bir başka yöntemde, EKG vuruları Tip-2 bulanık c-ortalamlar öbekleştirme algoritması ve yapay sinir ağı kullanılarak sınıflandırılmaktadır [3]. Tip-2 bulanık c-ortalamlar öbekleştirme algoritması yapay sinir ağının performansını arttırmak için kullanılmaktadır. MIT-BIH aritmi veri tabanından derlenen on tip vuru analiz edilmiştir. Test aşamasında 92 hastaya ait (ortalama yaşları 39.75 ± 19.06 olan 40 erkek, 52 dişi) EKG kayıtları kullanılmıştır. Yöntem yapay sinir ağı ve bulanık öbekleştirmeli yapay sinir ağı ile karşılaştırılmıştır. Yöntemin % 99 başarı verdiği gözlemlenmiştir. Başka bir çalışmada EKG vurularını sınıflamak için yeni bir hibrid yapay sinir ağı sunulmuştur [4]. İki farklı öznitelik çıkarma yöntemi, fourier ve wavelet dönüşümü karşılaştırılmıştır. Çok katmanlı ağı, sınırlı Coloumb enerjisi (RCE) ağının ve

önerilen yeni ağın performansları, sınıflama başarıları, eğitim süresi ve kullanılan düğüm sayıları baz alınarak karşılaştırılmıştır. Sınıflama başarısını yükseltmek ve kullanılan düğüm sayısını azaltmak için sunulan ağ genetik algoritma ile eğitilmiştir. MIT-BIH veri tabanı ve gerçek zamanlı bir EKG ölçüm sisteminden alınan on farklı EKG vurusu sınıflandırılmıştır. Önerilen yöntemin % 96 başarı verdiği gözlemlenmiştir. EKG vurularını sınıflamak için bulanık yapay sinir ağlarının kullanıldığı bir diğer çalışmada ise yüksek seviyeli istatistik ile EKG vurularına ait öznitelikler çıkartılmıştır [5]. Kullanılan hibrid ağ, bulanık bir alt ağdan ve çok katmanlı ağdan oluşmaktadır. Bulanık alt ağ için c-ortalamalar ve Gustafson-Kessel algoritmaları kullanılmıştır. Sınıflama sonucunda önerilen ağın iyi sonuçlar verdiği gözlemlenmiştir. Başka bir çalışmada, sekiz tip EKG vurusunu, bağımsız bileşenler analizi yardımıyla çıkartılan öznitelikleri ve EKG vurularının RR aralığı kullanılarak, yapay sinir ağı yardımıyla sınıflandırılmıştır [6]. Yapılan denemeler sonucunda önerilen yöntemin % 98.37 doğrulukla EKG vurularını sınıfladığı gözlemlenmiştir. EKG vurularını sınıflamak için evrimleştirilebilen blok tabanlı yapay sinir ağlarını önerildiği diğer bir çalışmada öznitelik çıkartma yöntemi olarak hermit dönüşüm katsayıları ve iki ardışık EKG vurusu arasındaki zaman aralığı (RR aralığı) kullanılmıştır [7]. MIT-BIH aritmi veri tabanından ayıklanan vurular sınıflandırılmıştır ve ventriküler ektopik odak vuruları için % 98.1, supraventriküler ektopik odak vuruları için % 96.6 gibi bir sınıflama başarısı elde edilmiştir. EKG vurularını sınıflandırmak için birleşik yapay sinir ağları kullanıldığı başka bir çalışmada, öznitelik vektör elemanları dalgacık katsayılarından ve istatistiksel özniteliklerden oluşmaktadır [8]. Ağı ilk seviyesinde öznitelik elemanı olarak ağı girişlerine istatistiksel öznitelikler uygulanmıştır. İkinci seviyedeki ağ birinci seviyenin çıkışlarını giriş olarak kullanmaktadır. Physiobank veri tabanından alınan dört adet vuru tipi % 96.94 doğrulukla sınıflandırılmıştır. Birleşik yapay sinir ağının sınıflama başarısının normal yapay sinir ağına göre daha yüksek olduğu gözlemlenmiştir. Diğer bir çalışmada, EKG vurularını sınıflamak için bulanık hibrid bir yapay sinir ağı modeli kullanmıştır [9]. Öznitelik elemanı olarak AR katsayıları, yüksek seviyeli istatistik ve wavelet dönüşümü kullanılmıştır. MIT-BIH aritmi veri tabanından alınan dört tip EKG vurusu sınıflandırılmış ve önerilen yöntemin diğer sınıflayıcılara nazaran daha iyi sonuçlar verdiği gözlemlenmiştir. Yakın zamanda yapılan diğer bir çalışmada, QRS komplekslerinin öbekleştirilmesi için yeni bir yöntem önerilmiştir [10]. Karınca koloni algoritmasına dayalı bu yeni yöntemde,

MIT-BIH aritmi veri tabanından ayıklanan altı aritmi tipi ön işleminden geçirildikten sonra algoritma yardımıyla öbekleştirilmiş ve k-en yakın komşu sınıflayıcıyla sınıflandırılmıştır. Algoritmanın performansını karşılaştırmak için yapay sinir ağı kullanılmıştır. Yapılan denemeler sonucunda önerilen yöntemin hızda ve doğrulukta daha iyi sonuçlar verdiği gözlenmiştir.

Radyal tabanlı fonksiyon yapay sinir ağının EKG vurularını sınıflamada kullanımı çok yaygın olmamakla birlikte son yıllarda artış göstermektedir. EKG vurularına ait şekilsel özniteliklerin kullanıldığı bir çalışmada sınıflama yapay sinir ağları ile yapılmıştır [11]. MIT-BIH veri tabanından seçilen dört farklı EKG vurusu sınıflanmıştır. Eğitim işlemini hızlandırmak için, EKG vurularından altı farklı şekilsel öznitelik çıkartılmıştır. Çok katmanlı ağ, radyal tabanlı fonksiyon yapay sinir ağı ve destek vektör makinaları ayrı ayrı eğitilerek EKG vuruları sınıflandırılmıştır. Sınıflama sonucu çok katmanlı ağ % 99.65 ile en iyi sınıflama başarısını verirken, radyal tabanlı fonksiyon yapay sinir ağı % 99.1 ve destek vektör makinaları % 99.5 lik bir sınıflama başarısı vermiştir. EKG aritmilerini sınıflamak için önerilen diğer bir yöntemde öznitelik elemanları bağımsız bileşenler analizi ve dalgacık dönüşümü ile elde edilmiştir [12]. MIT-BIH veritabanından alınan vuruları sınıflamak için çok katmanlı ağ, radyal tabanlı fonksiyon yapay sinir ağı ve k-en yakın komşu sınıflayıcı kullanılmıştır. Sınıflama sonucunda Levenberg-Marquardt algoritması ile eğitilen çok katmanlı ağın % 98.5'lik bir doğru sınıflama başarısı verdiği gözlemlenmiştir. PVC'ye ait farklı formdaki QRS komplekslerinin ve normal vuruya ait QRS komplekslerinin, radyal tabanlı fonksiyon yapay sinir ağını kullanarak sınıflandırıldığı başka bir çalışmada, öznitelik olarak Hermit fonksiyonlarla temsil edilen QRS kompleks katsayıları kullanılmıştır [13]. Çalışma sonucunda radyal tabanlı fonksiyon yapay sinir ağının performansının yeterli olduğu görülmüştür. Diğer bir çalışmada, radyal tabanlı fonksiyon yapay sinir ağı kullanılarak hayati öneme sahip aritmiler sınıflandırılmıştır [14]. Üç farklı kaynaktan alınan 159 aritmi dosyasından ayıklanan EKG kayıtlarının wavelet dönüşümü ile öznitelikleri çıkartılmıştır. Sınıflama sonucunda sınıflayıcının, ventriküler fibrilasyon, atrial fibrilasyon ve ventriküler taşikardi gibi hayati önem arz eden aritmileri % 97.5 gibi bir doğrulukla sınıfladığı tespit edilmiştir. Normal vuru ve PVC vurularını sınıflamak için MIT-BIH ve AHA veritabanlarından alınan EKG vurularından çıkartılan 13 şekilsel öznitelik elemanının kullanıldığı diğer bir çalışmada, radyal tabanlı

fonksiyon yapay sinir ağına da içeren 7 farklı yöntemle EKG vuruları sınıflandırılmış ve bu yöntemler birbirleriyle karşılaştırılmıştır [15]. Yakın zamanda yapılan bir diğer çalışmada, EKG vurularını sınıflamada destek vektör makinalarının genelleştirme kabiliyetini ortaya koymak ve destek vektör makinalarının sınıflama performansını arttırmak için yeni bir yöntem olan parçacık sürü optimizasyonu önerilmiştir [16]. Çalışma için MIT-BIH veri tabanından alınan beş farklı aritmi türü ve normal vuru kullanılmıştır. Destek vektör makinalarının sınıflama başarısı radyal tabanlı fonksiyon yapay sinir ağı ve k-en yakın komşu sınıflayıcı ile kıyaslanmıştır. Sınıflama sonucunda elde edilen sonuçlar, destek vektör makinalarının üstünlüğünü ortaya koymuştur. Önerilen yöntemin destek vektör makinalarının performansını arttırdığı gözlemlenmiştir. PSO-SVM ile 20 hastanın alınan kayıtlardan ayıklanan 40438 test vurusu, % 89.72, SVM ile % 85.98, kNN ile % 83.70 ve RBF ile % 82.34 doğrulukla sınıflandırılmıştır.

2. KALP KASININ UYARI VE İLETİM SİSTEMİ

2.1 Amaç

Kalpte oluşan elektriksel potansiyelleri anlamak açısından kalbin uyarı ve iletim sistemine değinmek faydalı olacaktır. Bu nedenle bu bölüm, kalp hakkında kısa bir bilgi verdikten sonra, kalbin elektriksel uyarı ve iletim sistemine değinip, kalbin elektriksel potansiyellerinin oluşumunu anlamaya yardımcı olmayı amaçlamaktadır. Ardından kalp kasının kasılıp gevşemesi sonucu oluşan elektrokardiyogram (EKG) işareti hakkında bilgi verilecektir. EKG işaretinin kalp hastalıklarının teşhisindeki önemine değinilecek ve farklı kalp hastalıklarında EKG işaretinin değişimi incelenecektir. Tıp literatüründe aritmi olarak ifade edilen EKG işaretindeki şekil ve ritm bozuklukları hakkında bir bilgi verildikten sonra, bu çalışmada EKG kayıtlarının temin edildiği MIT-BIH aritmi veritabanı hakkında kısa bir bilgi verilecektir.


2.2 Hücre Membranında Dinlenme Potansiyeli ve Aksiyon Potansiyelinin Oluşumu

Hücre, canlıların bağımsız olarak yaşamını sürdürebilen en küçük parçasıdır. Hücre “nucleus” olarak isimlendirilen çekirdek, sitoplazma denilen hücre gövdesi ve sitoplazmayı çevreleyen bir hücre membranından (zarından) oluşur. Membran, ortasında lipidlerin yer aldığı 75-100 Å kalınlığında çift lipid tabakasından oluşan dinamik bir yapıdır. Hücreye gelen tüm kimyasal (hormonal) ve elektriksel (sinirsel) enformasyon membran yolu üzerinden hücreye ulaşır [17].

Vücudumuzdaki hücrelerin tümüne yakınının zarında membran potansiyeli oluşur. Hücrenin elektriksel aktivitesi açısından bakıldığında hücrenin dışında ve içinde yer alan sıvı bileşimleri arasındaki temel fark, hücre dışında Na^+ (sodyum) ve Cl^- (klor) iyonları sayısının hücre içine nazaran fazla, K^+ (potasyum) iyonları sayısının ise az olmasıdır. Uyarılabilen hücrelerin membranları K^+ ve Cl^- iyonlarının hücre

içerisine geçmesine izin vermesine rağmen, Na^+ iyonlarının geçişine engel olur. Na^+ iyonunun hücre içerisine kolay geçmemesi sonucu iki durum ortaya çıkar:


- Hücre içindeki Na^+ iyonu yoğunluğu dışarıdakinden çok azdır ve Na^+ iyonları pozitif yüklü olduğundan hücre içi dışına göre daha pozitif olacaktır.
- Elektriksel yük dengesini sağlamak amacıyla pozitif yüklü K^+ iyonlarının hücre içine girmeleri, hücre içi K^+ yoğunluğunun hücre dışına göre artmasına neden olur. İyon akışı denge durumuna ulaşınca membran içi dışına göre negatif ve iyon konsantrasyon farkıyla belirlenen bir gerilim oluşur. Bu membran potansiyeline, dinlenme potansiyeli denir ve membran uyarılana kadar sabit kalır. Mikroelektrodlarla yapılan ölçümlerde hücre dışı pozitif olmak üzere membranın içi ve dışı arasında değeri -90 mV olan ve 60 mV ile -100 mV arasında değişen bir gerilim ölçülür [17].



Şekil 2. 1 : Hücre membranında aksiyon potansiyelinin oluşumu [18]

Sinir ve kas hücreleri gibi uyarılabilen özellikteki hücrelerin membranının bir bölümü, iyonik akım darbesi veya dışarıdan uygulanan enerji ile belirli bir eşik değerinin üstünde uyarıldığında, membranın Na^+ iyonlarına olan geçirgenliği artar ve Na^+ iyonları hücre içine akmaya başlar. Na^+ iyonlarının hücre içine doğru akışı, bir iyon akımı doğurur ve membranın sodyuma gösterdiği direnç daha da azalır. Na^+ iyonları hücre içine akarken potasyum iyonları da dışarı çıkarlar, fakat onların

hareketi Na^+ iyonlarına göre oldukça yavaştır. Sonuç olarak hücre içi dışına göre biraz pozitif olur (+20 mV kadar). Bu potansiyel değişimine aksiyon potansiyeli, hücreye depolarize hücre ve olaya da depolarizasyon denir. (Şekil 2.1) Yeni bir kararlı durum sağlanıp sodyum iyonlarının membrandan geçişi durduktan sonra, artık sodyuma karşı membran direncini kırarak bir iyon akımı mevcut değildir. Membran, tekrar seçici iletken duruma ve Sodyum Pompası adı verilen aktif bir iyon pompası yardımıyla da hücre tekrar dinlenme durumuna döner. Bu olaya repolarizasyon adı verilir [17].



Şekil 2. 2 : Kalbin temel yapısı [18]

Kalp, kanı akciğerlere pompalayan sağ kalp ve kanı çevresel organlara pompalayan sol kalpten oluşur. Gerçekte her iki kalp, atrium ve ventriküllerden oluşan iki odacıklı ritmik uyaran gösteren birer pompa gibi modellenebilir. Her bir atrium kanın ventriküllere dolabilmesi için öncü bir zayıf pompa görevi üstlenir. Ventriküller, sonrasında asıl pompa görevini üstlenerek kanın ya sağ ventrikül tarafından pulmoner dolaşıma ya da sol ventrikül tarafından çevresel dolaşıma katılmasını sağlar [18]. Şekil 2.2’de kalbin temel yapısı gösterilmektedir.


Kalp üç temel kalp kasından oluşur: atrial kas, ventriküler kas ve kalbin özelleşmiş uyarıcı ve iletici kas fiberleri. Atrium ve ventriküler kasları, kasılı kalma sürelerinin

uzun olması haricinde iskelet kaslarıyla aynı şekilde kasılırlar. Bunun tersine özelleşmiş uyarıcı ve iletili fiberler, daha az kasılabilir fiber içerdikleri için oldukça zayıf kasılırlar. Bunun yerine, aksiyon potansiyelleri şeklinde ritmik elektriksel deşarjlar sergileyerek, aksiyon potansiyelinin kalp boyunca iletilmesini sağlayıp kalbin ritmik vurularını kontrol eden bir uyarı mekanizması oluştururlar. Diğer kaslardan farklı olarak kalp kasının ritmik uyarılarının kendiliğinden oluşmasını sağlayan bu mekanizmaya kalbin uyarı ve ileti sistemi adı verilmektedir [18].

Kalp hücrelerinin özelleşmesi ile oluşan bu sistem, kalbin elektriksel uyarılarını kendi kendine üretmesini ve hızla kalp boyunca yayılmasını sağlar. Bu sistemin normal işleyişinde, atriumlar ventriküllerden saniyenin altıda biri kadar önce kasılarak, ventriküllerin kanı ciğerlere ve çevresel dolaşım sistemine pompalamadan önce kanla dolmasını sağlar. Bu sistemin önemli bir diğer özelliği de ventriküllerin neredeyse eş zamanlı kasılmasını sağlayarak gereken yüksek basıncın oluşumunu sağlamasıdır.

Şekil 2.3'te kalp kasılmalarını kontrol eden kalbin bu özelleşmiş uyarı ve iletim sistemi gösterilmektedir. Şekilde ritmik uyarıların üretildiği sinüs düğümü (sinoatrial düğüm veya S-A düğüm); uyarıları sinüs düğümünden atrioventriküler (A-V) düğüme ileten düğümler arası yollar; uyarıların atriumdan ventriküllere geçmeden önce geciktirilmesini sağlayan A-V düğüm; uyarıların atriumdan ventriküllere iletilmesini sağlayan A-V demet; ve uyarıların ventriküllerin bütün yüzeyine iletilmesini sağlayan A-V demetinin sağ ve sol dalı ile Purkinje fiberleri gösterilmektedir.


Kalbin normal çalışmasında uyarıların çıktığı yer S-A düğümüdür. Bu nedenle S-A düğüm pacemaker olarak tanımlanır. Pacemaker, hareketi başlatan, hareketin hızını belirleyen anlamına gelmektedir. S-A düğümde kendi kendine oluşan aksiyon potansiyeli, depolarizasyon dalgası halinde tüm kalbe yayılır. Kalp hücreleri arasındaki geçiş ise hücrelerarası alçak direnç bölgelerini oluşturan geçit bölgeleri üzerinden olur. S-A düğüm sağ atrium arka duvarında yer alan (3x10 mm boyutunda) özelleşmiş kalp hücrelerinden oluşmuştur [17].




Şekil 2.3 : Kalbin uyarı ve iletim sistemi [18]

SA düğümünde oluşan aksiyon potansiyeli, atriumlar üzerindeki iletim yolları üzerinden hızlı bir şekilde yayılarak atriumların kasılmasını sağlar ve buradaki kan ventriküllere basılır. Atriumlarda aksiyon potansiyelinin hızı, 30 cm/s kadardır. S-A ve A-V düğümleri arasındaki özel iletim hatlarında ise hız 45 cm/s kadardır. S-A düğümde oluşan aksiyon potansiyeli 30-50 ms sonra A-V düğüme ulaşır. Bu süre, atriumların içlerindeki kanı tümüyle ventriküllere doldurmaları için yeterli değildir. Bu nedenle ventriküllerin kasılmasının bir süre sonra yapılması gereklidir. Bu işlem, bir geciktirme elemanı gibi çalışan A-V düğümde, aksiyon potansiyelinin 110 ms kadar geciktirilmesiyle sağlanır. Atriumlarla ventriküller arasındaki yağlı septum bölge elektriksel izolasyonu sağlar ve kalbin bu iki bölgesi arasındaki iletim sadece iletim sistemi üzerinden yapılabilir.

Ventriküllerin uyarılması purkinje fiberleri ile olur. Bunlarda aksiyon potansiyelinin hızı 2-4 m/s kadardır. Bu fiberler ve tüm iletim mekanizması üzerindeki aksiyon potansiyelinin ulaşım süreleri, saniye cinsinden, Şekil 2.4'te gösterilmiştir. Purkinje fiberleri yardımıyla uyarılan miyokardium kasılır ve buradaki kan arterlere basılır. Kalp kasının aynı anda kasılması sonucu genliği oldukça büyük bir elektriksel işaret oluşur (Şekil 2.5). Elektrokardiyogram (EKG) olarak isimlendirilen bu işaret vücut üzerinden algılanabilir [17].



Şekil 2. 4 : Fiberler ve iletim mekanizması üzerindeki aksiyon potansiyelinin ulaşım süreleri [18]



Şekil 2. 5 : Normal elektrokardiyogram [18]

2.3 Normal Elektrokardiyogram

Normal elektrokardiyogram (Şekil 2.5), P dalgası, QRS kompleksi ve T dalgası olmak üzere üç ayrı kısımdan oluşur. QRS kompleksi her zaman olmamakla birlikte genellikle Q, R ve S dalgalarından oluşur. P dalgası, atriumların kasılmadan önce depolarizasyonu sonucu oluşan elektriksel potansiyellerden kaynaklanmaktadır. QRS kompleksi de benzer şekilde ventriküllerin kasılmadan önce depolarizasyonu sonucu meydana gelen işarettir. Bu yüzden P dalgası ve QRS kompleksi depolarizasyon dalgaları olarak anılmaktadır.

T dalgası ventriküllerin depolarizasyon fazından çıkması sonucu oluşan potansiyellerden kaynaklanmaktadır. Bu işlem ventriküler kasta genellikle depolarizasyondan 0.25 - 0.35 sn sonra meydana gelmektedir ve T dalgası repolarizasyon dalgası olarak bilinir.

Elektrokardiyogram depolarizasyon ve repolarizasyon dalgalarından meydana gelir. Elektrokardiyografide depolarizasyon ve repolarizasyonun birbirinden ayırt edilmesi oldukça önemlidir [18].

2.3.1 Elektrokardiyogram için normal değerler

Normal elektrokardiyogramda kaydedilen dalgaların voltaj değerleri, elektrodların vücut yüzeyine ne şekilde yerleştirildiğine ve kalbe ne ölçüde yakın olduğuna bağlı olarak değişiklik gösterir. Bir elektrod direkt olarak ventriküller üzerine yerleştirilip diğer elektrod kalpten uzak vücudun herhangi bir yerine yerleştirildiğinde, QRS kompleksinin değeri 3 – 4 milivolt büyüklüğünde olabilmektedir. Bu voltaj kalp kası hücrelerinin zarından direkt monofazik olarak ölçülen 110 milivolt ile kıyaslandığında oldukça küçüktür. Elektrokardiyogram iki koldaki elektrotlardan veya bir koldaki bir ayaktaki elektrotlardan kaydedildiğinde, QRS kompleksinin voltajı genellikle R dalgasının başından S dalgasının sonuna 1 - 1.5 milivolt kadar olmaktadır. P dalgasının voltajı 0.1 – 0.3 milivolt arası ve T dalgasının voltajı 0.2 - 0.3 milivolt olarak ölçülmektedir.

P-Q veya P-R aralığı; P dalgasının başlangıcı ile QRS kompleksinin başlangıcı arasındaki zamanı ifade eder. Bu da atriumların elektriksel olarak uyarılmaya başlanması ile ventriküllerin uyarılmaya başlanması arasındaki zaman aralığına denk düşer. Normal P-Q aralığı yaklaşık olarak 0.16 sn. kadardır. (Bu aralık sıklıkla P-R aralığı olarak da ifade edilir çünkü Q dalgası mevcut olmayabilir.)

Q-T aralığı; Ventrikül kasılması neredeyse Q dalgasının başından (eğer Q dalgası yoksa R dalgası) T dalgasının sonuna kadar tamamlanır. Bu aralık Q-T aralığı olarak ifade edilir ve normalde 0.35 sn civarındadır.


Kalbin vuru hızı elektrokardiyogramdan kolayca tespit edilebilir. Eğer iki EKG vurusu arasındaki zaman aralığı, zaman ölçekli çizgilerden 1 sn olarak tespit edildiyse kalp dakikada 60 kere çarpıyor denir. Yetişkin bir insanda iki QRS

kompleksi arasında geçen süre genelde 0.83 sn'dir. Bu ise dakikada 72 vuruşa karşı düşer.

2.4 Elektrokardiyogram Kaydetme Yöntemleri

2.4.1 Standart bipolar ekstremite derivasyonlar

Şekil 2.6'da standart bipolar ekstremite derivasyonu için hastanın kolları ve elektrokardiyografi cihazı arasındaki bağlantılar gösterilmektedir. Buradaki bipolar terimi elektrokardiyogramın kalbin iki tarafında yerleştirilmiş iki elektrodan kaydedildiğini ifade eder.



Şekil 2. 6 : Standart bipolar ekstremite derivasyonları [18]

Birinci derivasyon ile elektrokardiyografi cihazının negatif terminali sağ kola ve pozitif terminali de sol kola bağlanır. Bu yüzden sağ kolun göğse bağlandığı nokta, sol kolun göğse bağlandığı noktaya göre elektriksel olarak negatif olduğunda, elektrokardiyograf pozitif olarak kayıt yapar bu da elektrokardiyogramda sıfır voltaj çizgisinin üstüne karşılık düşer. Tersi durumda ise elektrokardiyograf çizginin altına kaydeder.

İkinci derivasyon ile elektrokardiyografin negatif terminali sağ kola, pozitif terminali sol bacağına bağlanır. Bu yüzden sağ kol sol bacağına göre negatif olduğunda, elektrokardiyograf pozitif kayıt yapar.


Üçüncü derivasyon ile elektrokardiyografin negatif terminali sol kola, pozitif terminali sol bacağına bağlanır. Bu yüzden sol kol sol bacağına göre negatif olduğunda elektrokardiyograf pozitif kayıt yapar.

2.4.1.1 Einthoven üçgeni

Şekil 2.6'daki üçgen Einthoven Üçgeni olarak adlandırılır. Şekilden de görüldüğü gibi iki kol ve sol bacak bu üçgeni oluşturmaktadır. Üçgenin üst kenarı, iki kol arasındaki bölgenin akışkanlar tarafından birbirine bağlandığını temsil eder. Benzer şekilde üçgenin alt ucuna bağlı diğer iki kenar da kollar ile sol bacak arasındaki akışkanları temsil etmektedir. Einthoven yasasına göre, herhangi bir anda şayet üç derivasyondan herhangi ikisi biliniyorsa, üçüncü derivasyon matematiksel olarak diğer iki derivasyon toplanıp kolayca bulunabilir. Örneğin Şekil 2.6'daki durumu göz önünde bulunduralım. Şekilde sağ kolda ölçülen voltaj -0.2 milivolt, sol kolda ölçülen voltaj 0.3 milivolt ve sol bacakta ölçülen voltaj 1.0 milivolt olarak görülmektedir. Bu yüzden I. derivasyonda pozitif 0.5 milivolt, II. derivasyonda pozitif 1.2 milivolt ve III. derivasyonda pozitif 0.7 milivolt ölçülmektedir. Dikkat edileceği üzere II. derivasyonda okunan değer I. ve III. derivasyonlarda okunan değerlerin toplamıdır. Bu da bipolar ekstremite derivasyonları için Einthoven yasasını matematiksel olarak doğrular.


2.4.1.2 Standart bipolar ekstremite derivasyonları

Şekil 2.7'de I, II ve III. derivasyonlarla kaydedilen elektrokardiyogram kayıtları gösterilmektedir. Bu şekilden de açıkça görüldüğü gibi her üç derivasyonda kaydedilen kayıtlar birbirine benzemektedir. Çünkü her üç derivasyonda da P dalgası, T dalgası ve QRS kompleksinin büyük bir kısmı pozitifdir. Her üç derivasyonda kaydedilen kayıtlar birbirine benzediği için, farklı aritmi tiplerini teşhis etmek isteyen bir kişinin hangi derivasyona baktığının pek bir önemi yoktur. Çünkü aritmi teşhisi çoğunlukla farklı dalga şekilleri arasındaki zaman ilişkisine dayanmaktadır. Fakat ventriküler veya atrium kasında veya purkinje iletim sistemindeki herhangi bir hasarı teşhis etmek isteyen bir kimse kaydın hangi derivasyonda alındığına dikkat etmelidir. Çünkü kalp kasındaki iletim bozuklukları bazı derivasyonlardaki elektrokardiyogram şeklini değiştirirken bazılarını etkilemeyebilir.



Şekil 2. 7 : Standart bipolar ektremite derivasyonları ile kaydedilen elektrokardiyogram [18]

2.4.2 Standart göğüs derivasyonları




Şekil 2. 8 : Standart göğüs derivasyonları [18]

Elektrokardiyogram genellikle göğsün ön yüzeyinde Şekil 2.8’de gösterilen herhangi bir noktaya bir elektrodun yerleştirilmesiyle direkt kalp üzerinden kaydedilir. Bu elektrod, elektrokardiografin pozitif terminaline bağlıdır. Negatif elektrod

(indiferant elektrod) ise şekilde gösterildiği gibi eşit direnç değerleriyle, sağ kol, sol kol ve sol bacağa bağlanır. Genellikle altı standart göğüs derivasyonu birden kaydedilir. Göğsün ön yüzeyinden Şekil 2.8'deki noktalara elektrodlar yerleştirilerek ölçülen bu derivasyonlar sırasıyla V_1 , V_2 , V_3 , V_4 , V_5 ve V_6 olarak isimlendirilir.

Kalp yüzeyi göğüs duvarına yakın olduğu için her bir derivasyon kalp kasının elektriksel potansiyelini elektrod vasıtasıyla hemen kaydedebilmektedir. Bu yüzden özellikle ventrikülün ön yüzeyinde meydana gelen bir anormallik göğüs derivasyonlarında belirgin değişikliklere neden olabilmektedir. Şekil 2.9'da göğüs derivasyonları ile kaydedilen elektrokardiyogram işaretleri gösterilmektedir.




Şekil 2. 9 : Standart göğüs derivasyonları ile kaydedilen elektrokardiyogram

Ventriküllerin depolarizasyonu sırasında kalbin uç (apex) kısmına uzak olan bölgeler elektriksel olarak negatif olduğu için V_1 ve V_2 derivasyonları negatif olmaktadır. Buna zıt olarak V_3 , V_4 , V_5 ve V_6 derivasyonları kalbin uç (apex) kısmına yakın oldukları için ventriküler depolarizasyon esnasında elektriksel olarak pozitif olmaktadır. Bu yüzden bu derivasyonlarda kaydedilen elektrokardiyogram işaretleri pozitifdir.

2.4.3 Yükseltilmiş (Augmented) unipolar derivasyonlar

Elektrokardiyogram işaretlerini kaydetmek için sıklıkla kullanılan bir diğer yöntem de yükseltilmiş unipolar derivasyonlar ile elektrokardiyogram kaydetmedir. Bu yöntemde, hastanın iki uzvu dirençler vasıtasıyla elektrokardiyografin negatif terminaline bağlanır. Bir diğer uzvuna da elektrokardiyografin pozitif terminali bağlanır. Pozitif terminal sağ kolda olursa, buna aVR derivasyonu; sol kolda olursa,

aVL derivasyonu; sol bacakta olursa, aVF derivasyonu denir. Şekil 2.10'da bu derivasyonda kaydedilen elektrokardiyogram işaretleri gösterilmektedir.



Şekil 2. 10 : Yükseltilmiş unipolar derivasyonlarla kaydedilen normal elektrokardiyogram [18]

2.5 Aritmiler

Sözlükteki karşılığının üstünde ve dışında bir anlam yüklenen aritmi terimi ile uyarının odağına, hızına ve düzenine ilişkin normal dışı nitelikler ile uyarı iletimindeki bozukluklar anlatılmak istenir. Başka bir deyiş ile aritmileri oluşturan temel etmenler, uyarının oluşumundaki ve/veya iletimindeki bozukluklardır [19].

Uyarı oluşumunu bozan mekanizmalar, otomatiklik ve tetikli etkinlik (triggered activity)'tir. Uyarı iletimini etkileyen nedenler ise blok ve tek yönlü blok eşliğindeki “yeniden giriş (reentry)” olarak adlandırılır. Bununla birlikte “yeniden giriş“, uyarı oluşumunu bozan bir etmen olarak da nitelendirilebilir [19].

Otomatiklik, SA düğümünde, kimi atriyum kesimlerinde, AV kavşağında ve His-Purkinje sisteminde yer alan hücrelerin normal bir özelliğidir. Daha önceki bölümlerde de bahsedildiği gibi bu hücreler kendiliğinden depolarizasyon yapabilen hücrelerdir. Kalbin bu otomatiklik mekanizmasındaki bozukluk sonucu oluşan aritmiler otomatik aritmi başlığı altında toplanır.

Repolarizasyon sürecini izleyerek membran potansiyeli'nde oluşan dalgalanmalara ard depolarizasyon (after depolarization) adı verilir. Ard depolarizasyon'a ilişkin dalga genliğinin eşik potansiyeli düzeyine ulaşabildiği durumlarda, ard arda gelen yeni depolarizasyon'ların tetiği çekilmiş olur. Böylece başlatılan aritmiler tetikli aritmi adı ile nitelendirilirler [19].

Uyarı iletimini belirleyen temel etmenler, depolarizasyon'un hızı, aksiyon potansiyeli'nin genliği ve uyarının taşındığı dokuların uyarılabilirlikleri, diğer bir ifadeyle uyarılabilirlik düzeyleridir. SA düğümünden kaynaklanan normal uyarı, kalp iplikleri sıra ile depolarizasyon durumuna geçinceye dek yayılır ve tüm miyokard uyarılıp kesin refrakter döneme girdiğinde gidecek yer bulamayıp söner. İzleyen aşamada kalp, yeni bir sinüs uyarısı beklemeye başlar. Kimi durumlarda uyarı, refrakter dönemi uzun olan belirli bir miyokard kesiminde yayılamaz. Böylesi bir koşulun varlığında uyarı, öbür bölgelerde uzun refraktör dönemli kesim derlenip uyarılabilir oluncaya dek tükenmeden oyalanabilirse, bu bölgeyi köprü gibi kullanarak, ilk yayılımı sırasında etkinleştirilen, ancak aradan geçen yeterli süre sonunda derlenme süreçlerini tamamlayan miyokard kesimlerine bir kez daha girerek uyarır. Bu olay yeniden giriş (reentry), kısır döngü (circus movement), iki yönlü gidiş (reciprocation) ve yansıma (echo) olarak adlandırılır. Yeniden giriş ile oluşturulan aritmilere yeniden girişli aritmi denir [19].

Uyarının oluşumundaki ve/veya iletimindeki bozukluklara bağlı olarak ortaya çıkan aritmiler, kökenlerini aldıkları kalp kesimine bakılarak, değişik türlere ayrılırlar.

2.5.1 Normal sinüs ritmi

Kalp 1 dakikada erişkin bir kişide 60-100 kere atar. Bu hızın 60'ın altına düşmesi durumunda bradikardiden, 100'ün üzerine çıkması durumunda ise taşikardiden bahsedilir.

Normal kalp ritminin EKG kriterleri aşağıdaki gibidir:

- Hız: 60-100 vuru/dk
- Ritm: Düzenli.
- Uyarı odağı: Her uyarı SA düğümünden çıkar
- P dalgası: Her vuruda aynı görünümündedir, tümü SA düğümünden çıkar.
- PR aralığı: 120-200 msn
- QRS: 80-120 msn.



Şekil 2. 11 : Normal sinüs ritmi

(<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>)

2.5.2 Uyarı oluşumu bozuklukları

2.5.2.1 Sinüs bradikardisi

Uyarı çıkaran odak sinüstedir (SA düğüm). Fakat kalp hızı normalden daha azdır. Özellikle yaşlılarda olmak üzere sağlıklı insanlarda sık görülen bir aritmi tipidir. Genellikle benign (iyi huylu) bir aritmi tipi olarak kabul edilir ve diyastol süresini uzattığı, ventrikül doluşunu arttırdığı için yararlı olduğu söylenebilir.

Sinüs bradikardisinin EKG kriterleri aşağıdaki gibidir:

- Hız: 40-60 vuru/dk
- Ritm: Genellikle düzenli. Sinüs aritmisi eşlik edebilir.
- Uyarı odağı: Her uyarı SA düğümünden çıkar
- P dalgası: Her vuruda aynı görünümündedir, tümü SA düğümünden çıkar.
- PR aralığı: < 200 msn ve sabit
- QRS: 80-120 msn.
- P dalgaları ve QRS kompleksleri arasında 1:1 ilişki sürmektedir. Her QRS kompleksinin öncesinde bir P dalgası görülür.




Şekil 2. 12 : Sinüs bradikardisi

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2.5.2.2 Sinüs taşikardisi

Uyarı çıkaran odak sinüs düğümündedir, fakat hızı normalden daha fazladır (> 100/dk). Bebeklerde ve çocuklarda sık karşılaşılr.



Şekil 2. 13 : Akut miyokard iskemisi sırasında ST segment depresyonu ile birlikte seyreden sinüs taşikardisi (150 vuru/dak)
<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2.5.2.3 Sinüs aritmisi


Sinüs döngüsünün uzunluğunda fazik değişiklikler ile karakterize bir aritmi tipidir. Uyarı çıkaran odak sinüs düğümündedir, ancak ritm yavaşlayan ve hızlanan dönemlerle karakterizedir.

Sinüs aritmisi iki temel biçimde görülür. Solunumsal şeklinde başlıca vagal tonusun refleks baskılanmasına bağlı olarak kalp hızı soluk alma ile artar (R-R aralığı kısalmır), soluk verme ile azalır (R-R aralığı uzar). Soluğun tutulması ile bu sıklık değişiklikler kaybolur.

Kalp hızı 60-100 vuru/dk arasındadır. Ritm düzenlidir. PR aralığı sabit, P dalgası, QRS kompleksi ve T dalgası normaldir. P:QRS ilişkisi 1:1'dir. Sık olarak görülen ve tedavi gerektirmeyen normal bir ritmdir. Erişkinlerden çok çocuklarda ve gençlerde görülür.

Solunumsal olmayan tipinde ise kalp hızı, erişkinlerde 100/dk'nın üzerindedir, özellikle yüksek derece ateşi olanlarda 170/dk'ya ulaşabilir. Genellikle yavaş başlar ve yavaş sonlanır.


Ritm düzenlidir. P:QRS ilişkisi 1:1'dir. P dalgası ve QRS kompleksleri normaldir. Kalp hızındaki ileri derecede artışlara oluşan miyokard iskemisi nedeniyle ST segment değişiklikleri eşlik edebilir.



Şekil 2. 14 : Sinüs aritmisi
<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2.5.2.4 Sinüs duraklaması

Sinüs ritmindeki bir duraklama ile tanınır. P dalgası ya bir vuruş için ya da sürekli olarak yoktur.




Şekil 2. 15 : Sinüs duraklaması

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2.5.2.5 Prematür atriyal kontraksiyon

Sağ veya sol atriymdaki ektopik bir odaktan çıkan bir uyarı ile erken bir atriyal kontraksiyon (PAC) gelişir. P dalgasının şekli sinüs düğümünden çıkan normal P dalgasından farklıdır, ters dönmüş olabilir. PR aralığı, uyarı çıkan odağın yerine ve AV düğümün yanıtsızlığına bağlı olarak normalden kısa veya uzun olabilir. PAC yalnızca AV düğüm ve ventrikül ileti sistemi üzerinden değil aynı zamanda geriye doğru atriyumlar üzerinden SA düğümüne doğru da yayılır. Bu nedenle bir prematür atriyal kontraksiyonu izleyen duraklama normalde olduğu kadardır (kompansatuar duraklama yoktur).

Kalp hızı PAC sıklığına bağlı olarak değişkenlik gösterebilir. Ritm düzensizdir. P:QRS ilişkisi genellikle 1:1'dir. P dalgasının şekli değişkenlik gösterir ve bazan QRS kompleksi ya da T dalgası içinde kaybolabilir. Seyrek olarak P dalgası çok erken çıktığında ventrikülü yanıtsız döneminde bulabilir ve ventrikülü uyaramadığından QRS kompleksi oluşmaz. Ventrikül aberasyonu bulunmadıkça QRS kompleksinin şekli normaldir.




Şekil 2. 16 : Prematüre atriyal erken vurular

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2.5.2.6 Paroksizmal supraventriküler taşikardi

Paroksizmal supraventriküler taşikardi (PSVT) genellikle dar QRS komplekslerinin olduğu normal P dalgalarının ise görülmediği hızlı ve düzenli bir ritmdir. Genellikle birden başlayan ve birden sonlanan bir ritmdir. Düzensiz bir ritm olan atriyal fibrilasyondan ve flutter dalgalarının görülebildiği atriyal flutterdan ayırt edilmesi kolaydır.

Kalp hızı 150-250/dk arasındadır. Uyarı farklı atriyal odaklardan çıkmadığı sürece ritm düzenlidir. P:QRS ilişkisi genellikle 1:1 şeklindedir, sık olarak P dalgasının QRS kompleksi içine girmesi ile bu ilişki bozulabilir. QRS kompleksi aberan ileti olmadığı sürece normaldir ancak iskemiye bağlı olarak ST ve T değişiklikleri gözlemlenebilir.



Şekil 2. 17 : Paroksizmal atriyal taşikardi

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>


2.5.2.7 Atriyal taşikardi

Atriyum hızı genellikle 150-200 vuru/dk arasındadır. P dalgasının şekli normal sinüs P dalgasından farklıdır. Atriyum hızı aşırı yüksek olmadığında AV ileti de deprese değilse her P dalgası ventriküle iletilebilir. Atriyum hızı arttığında ise AV ileti bozulabilir, Wenkebach (Mobitz Tip I) ikinci derece AV blok gelişebilir. Sık olarak prematür ventrikül kontraksiyonları ile birliktedir. Olguların yarısında atriyum hızı düzensizdir. Atriyal flutterın aksine P dalgaları arasındaki intervallerde izoelektrik hat tüm derivasyonlarda görülebilir.

2.5.2.8 Atriyal flutter

Atriyumdaki iritabl bir odaktan atriyal taşikardiye kıyasla daha hızlı uyarı çıkmasına bağlı olarak görülen bir ritmdir. Çok hızlı bir ritm olduğundan genellikle AV blok ile birliktedir. Testere dişi görünümündeki P dalgaları (F dalgaları) ile karakterizedir. F

dalgaları en iyi V1, II ve özofageal derivasyonlarda görülür ve bu derivasyonlarda genellikle pozitifdir.



Şekil 2. 18 : Atriyal taşikardi

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

İki tipte olabilir. Klasik ya da tip 1 atriyal flutterda atriyum hızı genellikle 250-350/dk civarındadır. Ventrikül hızı 2:1 veya 3:1 AV blok nedeniyle 150/dk civarındadır. Atriyal ritm düzenlidir. Ventrikül ritmi de AV blok sabit ise düzenli, değişken blok olduğunda ise düzensizdir. P:QRS ilişkisi genellikle 2:1 kadardır ancak 2:1 ile 8:1 arasında değişebilir. Kinidin ve amiodaron gibi antiaritmiklerin kullanımı ile atriyum hızının 200 vuru/dk'ya indirilmesi ventrikül hızının atriyum hızına eşitlenmesine neden olabilir. QRS kompleksi normaldir ancak T dalgaları F dalgalarının içinde kaybolur.

İkinci tipteki atriyal flutterda atriyum hızı 350-450 vuru/dk kadardır. Sürekli bir elektriksel aktivite olduğundan flutter dalgaları arasında izoelektriksel hattın görülmesi mümkün olmaz.

Atriyal flutter atriyal fibrilasyondan daha az görülen bir aritmi tipidir. Bu ritm genellikle altta yatan ciddi bir kalp hastalığını gösterir.




Şekil 2. 19 : Atriyal flutter

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2.5.2.9 Atriyal fibrilasyon

EKG’de P dalgalarının görümediği düzensiz, çok hızlı fibrilatuar aktivitelerden oluşan bir atriyal ritmdir. Atriyumun elektriksel aktivitesi EKG’de küçük, düzensiz izoelektrik hat oynamaları şeklindedir ve değişken amplitüd ve formda hızlı f dalgalarından oluşmaktadır.

Atriyum hızı 350-500/dk arasında, ventrikül hızı ise 60-170/dk arasındadır. WPW sendromu olan hastalarda ise ventrikül hızı 300 vuru/dk’yı aşarak VF gelişmesine neden olabilir. Ritm ileri derecede düzensizdir. P dalgası olmadığından P:QRS ilişkisi değerlendirilemez. QRS kompleksleri normaldir.




Şekil 2. 20 : Atriyal fibrilasyon

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2.5.2.10 Prematür ventrikül kontraksiyonları

PVC’lar, AV kavşak altındaki bir ektopik odaktan çıkan uyarılar ile oluşur. Miyokard veya ileti sisteminin herhangi bir yerinde oluştuğu ve iletildiği için geniş (0.12 sn) ve acayip şekilli bir QRS kompleksi oluşur. ST segmenti genellikle QRS kompleksinin aksi yöndedir. PVC’ye P dalgasının eşlik etmediği ancak atriyumların geriye doğru depolarizasyonu ya da bir sinüs vurusunun bloke olduğu durumda tanıda karışıklık olabilir. En büyük karışıklık aberan ventriküler ileti gösteren PAC’larındadır.

Bir PVC, sinüs düğümüne ulaşır ve onun normal sinüs ritmini bozar. SA düğümün izleyen depolarizasyonu bloke edilirken bir sonraki sinüs vurusu zamanında oluşur (erken gelen QRS kompleksinin öncesindeki ve sonrasındaki ilk normal QRS kompleksleri arasındaki süre iki normal QRS kompleksi arasındaki sürenin tam iki katıdır). Sonuçta kompensatuar bir duraklama (PVC ile beklenen fakat AV düğümde bloke edilen normal QRS arasındaki aralık ile normal sinüs aralığının toplamı) oluşur.



Şekil 2. 21 : Prematüre ventriküler vurular (PVC)

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

PVC'lar yaşın ilerlemesi ile artar. Anestezi sırasında sık (%15) görülen bir aritmi tipidir. Önceden kalp hastalığı bulunanlarda ise çok daha sıktır.

Kalp hızı sinüs hızına ve PVC'lerin sıklığına bağlı olarak değişir. Ritm düzenlidir. P:QRS ilişkisi, P dalgası olmadığından yoktur. QRS kompleksi geniş (>0.12 sn) ve anormal şekillidir.


Yeni ortaya çıkan PVC'ler, VT ve VF'a ilerleyebileceğinden yaşam tehdit edici aritmiler olarak kabul edilmelidir. Çok sayıdaki, farklı odaklardan çıkan, ikili gelen, bir önceki depolarizasyonun hassas dönemine denk gelen (R on T) PVC'ler özellikle tehlikelidir.

2.5.2.11 Ventrikül taşikardisi

Ventrikülden yineleyerek çıkan ektopik vurulardan oluşan hızlı ve yaşam tehdit edici bir ritmdir. Birden ya da yavaş bir şekilde başlayabilir.

Kalp hızı 70-250 vuru/dk'dır. Ritm genellikle düzenlidir ancak ventrikül taşikardisi paroksizmal ise düzensiz de olabilir.

P:QRS ilişkisi sabit değildir. P dalgası genellikle ayırt edilemez. QRS kompleksi geniştir (>0.12 sn).




Şekil 2. 22 : Ventrikül taşikardisi

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2.5.2.12 Ventrikül fibrilasyonu

Ventriküldeki bir ya da birkaç odaktan peşi sıra çıkan uyarıların oluşturduğu düzensiz bir ritmdir. Ventrikül kontraksiyonları düzensizdir ve EKG’de değişen şekil ve konfigürasyonlarda paternler gözlenir. P dalgası yoktur.



Şekil 2. 23 : Ventrikül fibrilasyonu

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

Kalp hızı yüksek ve sıklıkla değişkendir. Ritm tamamen düzensizdir. P:QRS ilişkisi görülemez. QRS kompleksleri, ST segmenti ve T dalgaları yoktur.

Etkili bir kardiyak debi olmadığından yaşam yapay yöntemler ile sürdürülmelidir.

2.5.3 Uyarı iletimi bozuklukları

İleti defektleri ya da kalp blokları geçici veya kalıcı olarak anatomik ya da işlevsel bir bozukluk sonucunda uyarı oluşumundaki veya iletimindeki bozukluklardır. Cerrahide, pulmoner arter kateterizasyonu sırasında ya da miyokard iskemisine bağlı olarak da gelişebilen iletim defektleridir.

2.5.3.1 Atriyoventriküler bloklar


SA düğümünden çıkan uyarının ventriküllere iletimindeki kusurlardan oluşan ileti bozukluklarıdır. Üç tipte görülebilir.

- 1⁰ AV blok
- 2⁰ AV blok (Mobitz tip I ve Mobitz tip II)
- 3⁰ AV blok (tam kalp bloğu)

1⁰ Atriyoventriküler blok

SA blok, sinüs düğümünde oluşur. Atriyal eksitasyon (uyarılma) oluşmadığından EKG’de P dalgası görülmez. İzleyen vuru ise normal bir sinüs vurusu, nodal kaçış vurusu veya ventriküler ektopik bir vuru olabilir.

PR aralığının 0.21 sn.den daha uzun olması ile karakterizedir. Tüm atriyumdan çıkan uyarılar AV düğüm üzerinden Purkinje sistemine iletilir. Genellikle tedavi gerektirmeyen bir ileti bozuklukluğudur.



Şekil 2. 24 : Birinci derece atriyoventriküler blok


<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2⁰ Atriyoventriküler Blok

İkinci derece AV kalp bloğunda atriyumlardan çıkan uyarıların tümü AV düğüme ve Purkinje sistemine iletilememektedir.

İki alt tipi bulunur.


1. Mobitz tip I’de (Wenkebach) blok PR aralığının giderek uzaması ve sonuçta bir P dalgasının olmayışı ile karakterizedir Bu blok tipi nispeten benigndir ve sıklıkla kendiliğinden kaybolur, pacemaker gereksinimi doğurmaz.



Şekil 2. 25 : Mobitz tip I (Wenkebach) blok

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2. İkinci derece kalp bloğunun diğer tipi Mobitz tip 2 AV kalp bloğudur. Bu daha az görülen ama daha ciddi bir bloktur. PR aralığında herhangi bir artış olmaksızın bir P dalgası birdenbire kaybolur. Sıklıkla tam kalp bloğuna ilerlediğinden ciddi bir blok tipidir ve pek çok majör cerrahi girişim öncesinde pacemaker konulmasını gerektirir.




Şekil 2. 26 : Mobitz tip II blok

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

3⁰ Atriyoventriküler Blok

Üçüncü derece kalp bloğu tam kalp bloğu olarak da adlandırılır. Atriyumdan çıkan elektrik aktivitesi Purkinje sistemine iletilemediğinde oluşur. Atriyal ve ventriküler kontraksiyonların birbiriyle ilişkisi kaybolmuştur. İki sistemin de ritmi düzenli olabilir. Ventrikül hızı yaklaşık 40 vuru /dk kadardır. Uyarı çıkaran odak AV düğümde olduğunda QRS kompleksinin şekli normaldir. Fakat uyarı ventrikülden çıkıyorsa genellikle 0.12 sn.den geniştir.



Şekil 2. 27 : Üçüncü derece atriyoventriküler blok


<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2.5.3.2 İntraventriküler ileti blokları

İleti kusuru, ventriküllerdeki ileti dallarındadır. Sol dal bloğu, sağ dal bloğu ya da hemiblok şeklinde sınıflandırılır.

Sol dal bloğu

Sol dal bloğu, intraventriküler ileti bozuklukları içinde en ciddi olanıdır. Uyarılar sol ventriküle sağ dal üzerinden ulaştığından QRS kompleksi geniştir (>0.12 sn), I, aVL ve V6'da geniş ve çentikli bir P dalgası vardır. Bir LBBB paterni daima ciddi bir kalp hastalığına eşlik eder.




Şekil 2. 28 : Sol dal bloğu

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

Sağ dal bloğu

Sağ dal bloğunda (RBBB) QRS kompleksi 0.11 sn.den geniştir ve V1-V3 derivasyonlarda geniş bir rSR' kompleksi, I ve V6'da ise geniş S dalgaları ile karakterizedir .



Şekil 2. 29 : Sağ dal bloğu

<http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm>

2.5.4 Uyarı oluşumunun ve iletiminin karışık bozuklukları

2.5.4.1 Füzyon vurumu

Ayrı odaklardan kaynaklanan ve birbirine yaklaşılarak ilerleyen iki uyarının AV kavşağı düzeyinde karşılaşmaları ile AV disosiyasyonu, atriyumda ya da ventrikülde karşılaşmaları ile atriyum ya da ventrikül füzyonu oluşur. Atriyum ya da ventrikül füzyonunda, atriyumların ya da ventriküllerin belirli bir kesimi bir uyarı, geride kalan kesimi ise öbür uyarı tarafından eş zamanlı olarak etkinleştirilir. Daha kısa bir tanımla, füzyon atriyumların ya da ventriküllerin iki ayrı uyarı tarafından eşzamanlı depolarizasyonuna verilen addır. P dalgasının QRST bileşiği üzerine rastlaması füzyon olarak yorumlanmamalıdır.

Atriyumlara eş zamanda gelen iki ayrı uyarının oluşturdukları depolarizasyona atriyum füzyonu vurumu denir. Atriyum füzyonu elektrokardiyogramda, füzyona ilişkin P dalgasının, uyarıların tek başlarına gerçekleştirdikleri P dalgalarına kıyasla bir ara biçim ya da melez görünüm oluşturması nitelikselidir.

Ventriküllere eş zamanda gelen iki ayrı uyarının oluşturdukları depolarizasyon ise ventrikül füzyon vurumu olarak adlandırılır. Ventrikül füzyonu elektrokardiyogramda füzyonu yansıtan QRS bileşiğinin, uyarıların tek başlarına gerçekleştirdikleri QRS bileşiklerine göre ara biçim ya da melez görünüm oluşturdukları saptanır.

2.5.5 MIT-BIH aritmi veri tabanı

MIT-BIH aritmi veri tabanı 1975 yılından bugüne Boston Beth Israel Hospital ve MIT işbirliği ile yapılan aritmi analizi çalışmalarının bir ürünüdür [url2]. Veri tabanı 1980’de tamamlanmıştır ve dağıtılmaya başlanmıştır. Veri tabanı uzun bir süre boyunca aritmi detektörlerinin geliştirilmesi ve kalp dinamiklerinin araştırılması gibi konularda başvurulabilecek olan tek materyaldi.


MIT-BIH aritmi veri tabanı 1975 ve 1979 yılları arasında BIH aritmi laboratuvarlarında 47 hastadan alınan, 48 yarım saatlik çift kanal EKG kayıtlarından oluşmaktadır. Hastalardan 25’i 32-89 yaşları arasındaki erkeklerden ve 22 tanesi 23-89 yaşları arasındaki kadınlardan oluşmaktadır.

Kayıtlar saniyede 360 örnekle ve 10 mV sahasında her kanal için 11-bit çözünürlükle sayısallaştırılmıştır. İki veya daha fazla kardiyologtan oluşan bir grup kayıtları incelemiş ve aritmileri not etmişlerdir.

3. ÖN İŞLEMLER VE ÖZNİTELİK ÇIKARTMA

3.1 Amaç

Sınıflama işleminden önce MIT-BIH aritmi veritabanından seçilen EKG kayıtlarının bir ön işlemden geçirilip gürültü ve taban hattı kayması gibi etkilerin giderilmesi sonrasında her bir vurunun ayıklanması gerekmektedir. Ayıklanan vurulardan daha sonra EKG işaretine ait öznitelikler çıkartılacaktır. EKG vurularını ayıklamak için genelde kullanılan yöntem, EKG vurularının R tepesi referans alınarak, ilgili vurunun sağından ve solunda belirli sayıda örnek almaktır. Bu nedenle seçilen EKG kayıtlarındaki vurularının her biri için R tepesi tespit edilmelidir. Bu bölümde, kayıtlardan gürültü ve taban hattı kayması gibi etkilerin giderilmesi için kullanılan yöntemler ile EKG kayıtlarından R tepesini belirleyebilmek için tezde kullanılan yöntem hakkında bilgi vermek amaçlanmıştır. Son olarak EKG vurularından çıkartılan özniteliklere değinilmiştir.




Şekil 3. 1 : Taban hattı kayması ve 60 Hz şebeke gürültüsü bileşenine sahip işaret

3.2 İşaretlerden Gürültü ve Taban Hattı Kayması Gibi Etkilerin Giderilmesi

EKG işaretleri kayıt esnasında bir takım gürültülere ve istenmeyen etkilere maruz kalabilmektedir. EKG için en çok bilinen gürültü kaynakları, 50-60 Hz şebeke gürültüsü, taban hattı kayması ve yüksek frekanslı EMG gürültüleridir. İleriki aşamalara geçmeden önce işaretler üzerindeki bu bozucu etkilerin giderilmesi gerekmektedir.

Taban hattı kayması ve 60 Hz şebeke gürültüsüne sahip bir EKG kaydı Şekil 3.1’de verilmektedir. Öncelikle işaret üstündeki taban hattı kayması giderilecektir. Bunun için en çok kullanılan yaklaşım bir medyan filtre kullanmaktır. Şekil 3.2’de medyan filtre çıkışı gösterilmektedir. Şekilden de görüldüğü gibi medyan filtre taban hattı kaymasını gidermektedir.



Şekil 3.2 : Taban hattı kayması giderilmiş işaret

İşaretteki 60 Hz şebeke gürültüsünü bastırmak için tez kapsamında kullanılan filtrenin fark denklemi aşağıdaki gibi verilebilir [20].

$$y = F(b,a,x) \quad (3.1)$$

$$y(n) = b(1)*x(n) + \dots + b(nb+1)*x(n-nb) - \dots - a(na+1)*y(n-na) \quad (3.2)$$


$$b = [1 \ 0 \ 0 \ 0 \ 0 \ 0 \ -1] \quad (3.3)$$

$$a = [1 \ -1] \quad (3.4)$$

Bu durumda fark denkleminin z dönüşümü aşağıdaki gibidir:

$$Y(z) = \frac{1 - z^{-6n}}{1 - z^{-n}} X(z) \quad (3.5)$$

Bu filtrenin frekans-genlik cevabı Şekil 3.3'te görülmektedir. Bu filtre P, QRS ve T dalgalarını geçirirken işaret üstündeki istenmeyen etkileri gidermektedir




Şekil 3. 3 : 60 Hz şebeke gürültüsünü gidermek için kullanılan filtrenin frekans-genlik cevabı

Şekil 3.4'de filtre çıkışı gösterilmektedir. Görüldüğü gibi filtre 60 Hz şebeke gürültüsünü bastırmıştır.

3.3 QRS Deteksiyonu ve Pan-Tompkins Algoritması


QRS kompleksinin yerini belirlemek için farklı yöntemler bulunmakla birlikte en çok billinen ve kullanılan yöntemlerden birisi Pan-Tompkins algoritmasıdır [21]. Pan ve

Tomkins 1985 yılında geliştirdikleri algoritmada eğim, genlik ve genişlik bilgilerini kullanarak QRS bulma algoritmasını geliştirmişlerdir.



Şekil 3.4 : 60 Hz şebeke gürültüsü bastırılmış işaret

Şekil 3.5 QRS belirleme işleminde kullanılan aşamaları göstermektedir. Gürültüyü bastırmak için EKG işareti yüksek ve alçak geçiren filtrelerden oluşan bir bant geçiren filtre ile süzülür. Daha sonra işaretin diferansiyeli, karesi ve zaman ortalaması alınır.



Şekil 3.5 : QRS belirleme aşamaları

Pan ve Tompkins çalışmalarında tamsayı katsayılarından oluşan özel bir bant geçiren filtre tasarlamışlardır. Katsayıların tamsayı olarak seçilmesinin sebebi, çalışmanın gerçek zamanlı bir çalışma olmasıdır. Kullanılan mikroişlemciler tamsayılar üzerinden işlem yaptığı için gerçek zamanda daha hızlı sonuçlar elde edebilecektir. Bu özelliğe sahip bir bant geçiren filtreyi tasarlamak kolay olmadığı için, kaskat

yapıda alçak geçiren ve yüksek geçiren filtreler kullanılmıştır. Tasarlanan bu filtre 10 Hz'de merkezlenmiş baskın QRS enerjisini izole etmekte, düşük frekanstaki P ve T dalgalarını ve taban hattını bastırmakta, ayrıca elektromiyografik gürültülerden kaynaklanan yüksek frekans bileşenleri ile güç hattı gürültüsünü de bastırmaktadır.

Diferansiyel alma işleminde QRS kompleksini EKG'nin diğer bileşenlerinden ayıran yüksek eğimli bölgeler bulunmaya çalışılmaktadır. Bu aşamaya kadar bütün işlemler doğrusal sayısal filtrelerle gerçekleştirilmektedir.

Bir sonraki işlemde EKG'deki her bir örneğin integral işlemi öncesinde karesi alınmaktadır. Böylelikle bütün örneklerin pozitif olması sağlanmıştır. Bunun yanı sıra QRS kompleksini oluşturan yüksek frekanslı bileşenler de kare alma işlemi sonucunda daha belirgin hale gelecektir.

Karesi alınan işaret bir kayan pencere integratörden (moving window integrator) geçirilir. İntegratör 150 ms lik bir zaman aralığı içerisindeki karesi alınmış işaretin alanını toplamaktadır. Pencere genişliği QRS kompleksinin tamamını içerecek genişlikte olmalıdır, fakat T dalgasını içerecek kadar uzun olmamasına da dikkat edilmelidir.

Bu aşamadan sonra Pan-Tompkins algoritmasından farklı olarak adaptif bir eşik değeri seçmek yerine çalışmamızda sabit bir eşik değeri kullanılmıştır. Eşikğin üstündeki değerler belirli bir sabite eşitlenmiştir. Bu işlem sonucunda bir kare dalga işaret elde edilir. Çalışmanın ana amacı QRS kompleksini belirlemek olmadığı için bu yöntem kullanılmıştır. Kullanılan yeni yöntemle QRS kompleksinin yeri, işarete belirli miktarda gürültü eklenmesine rağmen yine de başarılı bir şekilde tespit edilebilmiştir.

Tez kapsamında Şekil 3.1'de verilen işaretin R tepeleri bulunmaya çalışılacaktır. İşaret hali hazırda zaten filtrelenmiş olduğundan (Şekil 3.4) Pan-Tompkins algoritmasında kullanılan bant geçiren filtreden sadece bahsedilecektir. Sonrasında Şekil 3.4'te gösterilen bozucu etkileri giderilmiş işaret kullanılarak R tepeleri bulunmaya çalışılacaktır.

3.3.1 Tamsayı katsayılı bant geçiren filtre

Tasarlanan bant geçiren filtre EKG sinyal spektrumunun ortalamasını alarak işarettaki gürültüyü azaltmaktadır. İşaret bu filtreyle süzülerek, kas gürültüsü, 60 Hz

güç hattı gürültüsü, taban hattı gürültüsü ve T dalgası karışımı bastırılır. Filtrenin geçirme bandında (5-15 Hz aralığı) QRS kompleksinin enerjisi maksimize edilir. Bu algoritmayla gerçekleştirilen rekürsif tamsayı katsayılı filtrede, kutuplar birim çember üzerindeki sıfırları yok edecek şekilde yerleştirilir. Daha önceden de bahsedildiği gibi bant geçiren filtre, bir alçak geçiren filtre ve bir yüksek geçiren filtrenin kaskat çalışmasıyla tasarlanmıştır.

3.3.1.1 Alçak geçiren filtre

İkinci dereceden alçak geçiren filtrenin transfer fonksiyonu,


$$H(z) = \frac{(1 - z^{-6})^2}{(1 - z^{-1})^2} \quad (3.6)$$

eşitliği ile verilmektedir. Bu filtrenin fark denklemi aşağıdaki gibidir:

$$y(nT) = 2y(nT - T) - y(nT - 2T) + x(nT) - 2x(nT - 6T) + x(nT - 12T) \quad (3.7)$$

Filtrenin kesim frekansı yaklaşık olarak 11 Hz, gecikmesi 5 örnek, ve kazancı 36'dır. Saturasyondan kurtulmak için, çıkış filtre kazancı 36'ya en yakın tamsayı (ikili sistemde ifade edilebilen tamsayı) olan 32'ye bölünür.

Şekil 3.6' da alçak geçiren filtrenin frekans-genlik cevabı verilmiştir. Filtre tamamen lineer faz cevabına sahiptir.



Şekil 3. 6 : Alçak geçiren filtrenin frekans – genlik cevabı

3.3.1.2 Yüksek geçiren filtre

Çalışmada kullanılan yüksek geçiren filtre 1. dereceden bir alçak geçiren filtreden bir tüm-geçiren (all-pass) filtrenin çıkarılmasıyla elde edilmiştir. Alçak geçiren filtre, transfer fonksiyonu aşağıdaki gibi olan bir tamsayı katsayılı filtredir.

$$H_{lp}(z) = \frac{Y(z)}{X(z)} = \frac{1 - z^{-32}}{1 - z^{-1}} \quad (3.8)$$

Filtrenin fark denklemi,

$$y(nT) = y(nT - T) + x(nT) - x(nT - 32T) \quad (3.9)$$


eşitliği ile verilmektedir. Filtre dc 32 kazanca ve 15.5 örnek gecikmeye sahiptir. Yüksek geçiren filtre, alçak geçiren filtrenin çıkışının, filtrenin dc kazancı olan 32 ile bölünüp orijinal işaretten çıkartılmasıyla elde edilir. Yüksek geçiren filtrenin transfer fonksiyonu,

$$H_{hp}(z) = \frac{P(z)}{X(z)} = z^{-16} - \frac{H_{lp}(z)}{32} \quad (3.10)$$

eşitliği ile verilir. Bu durumda filtrenin fark denklemi,

$$p(nT) = x(nT - 16T) - \frac{1}{32} [y(nT - T) + x(nT) - x(nT - 32T)] \quad (3.11)$$


eşitliği ile verilir.




Şekil 3. 7 : Yüksek geçiren filtre, alçak geçiren filtrenin bir tüm-geçiren (all-pass) filtreden gecikme ile çıkartılmasından elde edilir

Bu filtrenin alçak kesim frekansı yaklaşık 5 Hz, gecikmesi 16T ve kazancı 1'dir. Şekil 3.8'te yüksek geçiren filtrenin karakteristiği verilmiştir.

Şekil 3.9’da alçak geçiren ve yüksek geçiren filtrenin birleşiminden oluşan bant geçiren filtrenin genlik cevabı gösterilmektedir. Bant geçiren filtrenin merkez frekansı 10 Hz’dedir. Bu filtre genel olarak QRS kompleksinin frekans karakteristiğini geçirirken alçak ve yüksek frekans bileşenlerini bastırmaktadır.



Şekil 3. 8 : Yüksek geçiren filtre a) Genlik cevabı b) faz cevabı



Şekil 3. 9 : Bant geçiren filtrenin frekans-genlik cevabı

3.3.2 Diferansiyel işlemi

Filtrelenen işaret daha sonra QRS kompleksinin şekil bilgisini çıkarabilmek amacıyla türevlenir. Bu işlem için transfer fonksiyonu aşağıdaki gibi olan beş noktalı türev alınır.

$$H(z) = 0.1(2 + z^{-1} - z^{-3} - 2z^{-4}) \quad (3.12)$$

Bu türev aşağıdaki fark denklemiyle gerçekleştirilebilir.

$$y(nT) = \frac{2x(nT) + x(nT - T) - x(nT - 3T) - 2x(nT - 4T)}{8} \quad (3.13)$$

1/8 kesri, 0.1 olan kazancın yaklaşığıdır. Böylelikle denklem 2'nin kuvvetleri şekline getirilerek gerçek zamanda çalışma işlemi kolaylaştırılmaktadır.

Şekil 3.10 'da türev alma işleminden sonra EKG kaydının şekli gösterilmektedir. Bu işlemle P ve T dalgaları daha da bastırılırken QRS kompleksine bağlı olarak işaretin tepeden tepeye değeri artmıştır.

3.3.3 Kare alma işlemi

Daha önceki işlemler ve kayan pencere integratör (moving window integrator) işlemi QRS belirleme aşamalarının lineer işlemleri iken kare alma işlemi lineer olmayan bir işlemdir. Bu işlemi gerçekleyen fonksiyon,

$$y(nT) = [x(nT)]^2 \quad (3.14)$$


eşitliği ile verilmektedir. Bu işlem işarettaki bütün dataları pozitif yaparken, diferansiyel alma işlemi sonucunda oluşan işareti de non-lineer kuvvetlendirmektedir. Ayrıca bu işlem sonucunda QRS kompleksi gibi yüksek frekanslı bölgeler daha da belirgin hale gelmektedir. Şekil 3.11'de kare alma işlemi sonucunda oluşan işaret gösterilmektedir.

3.3.4 Kayan pencere integratör

Genellikle tek başına R dalgası şekil bilgisinin kullanılması, genliği ve genişliği normalden çok daha farklı olabilen birçok anormal QRS kompleksini belirlemede yeterli olamamaktadır. Bu yüzden QRS kompleksini belirleyebilmek için çoğu zaman daha fazla bilgiye ihtiyaç duyulmaktadır. Kayan pencere integratör işlemi ile

R dalgasının yanı sıra diğer bazı öznitelikler açığa çıkarılmaktadır. Bu işlem aşağıdaki fark denklemiyle ifade edilmektedir.

$$y(nT) = \frac{1}{N} [x(nT - (N-1)T) + x(nT - (N-2)T) + \dots + x(nT)] \quad (3.15)$$




Şekil 3. 10 : Türev alma işlemi sonucu EKG kaydı

Burada N, kayan pencere içerisindeki örneklerin sayısını ifade etmektedir. Bu değer çok dikkatli seçilmelidir. Şekil 3.12’de kayan pencere integratör işlemi sonrasında EKG kaydı gösterilmiştir.


3.3.5 Eşikleme

Daha önceden de belirtildiği gibi bu aşamada Pan-Tompkins algoritmasından farklı bir yöntem uygulanmıştır. Şekil 3.12’de verilen Kayan Pencere Integratör çıkışı da göz önünde bulundurularak, belirli bir eşik değerinin üstü sabit bir sayıya eşitlenerek çıkışın bir kare dalgaya benzemesi hedeflenmiştir. Böylelikle bu kare dalga içinde maksimum değer aranarak R tepesinin konumuna ulaşılabacaktır. Şekil 3.13’ te eşikleme işlemi sonrasında oluşan kare dalga işaret gösterilmektedir.




Şekil 3. 11 : Kare alma işlemi sonucu EKG kaydı


Oluşan kare dalga işaret işlenerek her bir kare dalga için yükselen ve düşen kenarların koordinatları kaydedilmiştir. Şekil 3.13'te de görüldüğü gibi orijinal EKG kaydı ile oluşan kare dalga işaret örtüştürüldüğü için, elde edilen yükselen ve düşen kenar koordinatları arasında maksimum değer aranmış ve her bir EKG vurusu için R tepesinin koordinatı belirlenmiştir. Çalışma, işarete belirli bir oranda gürültü eklenerek tekrarlanmış ve algoritmanın R tepesini yine de başarılı bir şekilde belirlediği gözlemlenmiştir. Şekil 3.14'te R tepeleri bulunmuş EKG kaydı gösterilmektedir.



Şekil 3. 12 : Kayan pencere integratör işlemi sonucu EKG kaydı



Şekil 3. 13 : Eşikleme sonrasında oluşan kare dalga işaret




Şekil 3. 14 : R tepeleri bulunmuş orijinal EKG kaydı

3.4 Öznitelik Çıkartma

Karar verme amacıyla bilgisayarlarda geliştirilen algoritmalarından çevremizde gelişen tüm olaylara insan gibi cevap vermesini bekleyemeyiz. Makine öğrenmesinde, eğitim ve tanıma işlemine başlamadan önce örüntülerin doğasına bağlı olarak çevremizde gelişen olayları gruplandırmamız gerekir. Ses işaretinden konuşmacıları tanıma, konuşulan kelimeleri tanıma, kamera karşısındaki objeleri tanıma işlemlerinin her biri ayrı bir konu olarak ele alınacaktır. Karar verme amacıyla geliştirilen algoritmalar, genellikle seçilen bir konu içindeki örüntüler hakkında karar üretecektir. Örüntü uzayı; tanıma işleminde seçilen konuyu (amaç), bu uzaydaki örüntüler ise varlığı sorgulanan bilgileri temsil etmektedir [22].

Örüntü uzayını ve örüntüleri birlikte açıklamak amacıyla birkaç örnek verelim: konuşma tanıma işlemi, “açıl, kapan” gibi komutlar; biyolojik işaretlerin tanınması işlemi, normal ve hastalık belirtisi içeren işaretler, yürüyen hat üzerindeki cisimlerin kamera ile tanınması işlemi, “somun, vida” gibi cisimler; tarayıcı ile oluşturulan doküman görüntüsünden karakter tanıma işlemi, “rakamlar ve harfler”, örüntü uzayı ve bu uzaydaki örüntüleri temsil etmektedir. Dikkat edilecek olursa her bir konuda amaç farklıdır.




Şekil 3.15 : Örnek bir öznitelik uzayı

Bilgisayarların örüntüleri algılayabilmesi için bu uzaydaki her bir örüntünün, bilgisayarın işleyebileceği vektörel bir format ile temsil edilmesi gerekmektedir. İncelenen her konu için vektörler, farklı bir dönüşüm yöntemi kullanılarak oluşturulacaktır. Örüntüler, dönüşüm yapıldıktan sonra bilgisayarın işleyebileceği forma gelmektedir. Dönüşüm işlemini yaparken, kategorileri birbirinden ayıran ve kendi kategorisini en iyi temsil eden verilerin oluşturulması hedeflenmektedir. Dönüşüm işlemi sonucunda oluşan veriler, “öznitelik” ler olarak adlandırılmaktadır. Dönüşüm işlemi ise, “öznitelik çıkartma yöntemi” olarak adlandırılmaktadır. Öznitelik çıkartma işlemi sonucu oluşan özniteliklerin tamamı öznitelik uzayını oluşturmaktadır [22]. Uzay içerisinde her bir kategoriye (sınıfa) ait öznitelikler belirli bir dağılıma sahiptirler. Şekil 3.15’te örnek bir öznitelik uzayı gösterilmektedir.

Şekil 3.15’te iki boyutta verilen örnek öznitelik uzayı incelendiğinde her bir sınıfa ait özniteliklerin bir araya toplandığı görülmektedir. Böyle bir sınıf dağılımı ideal bir dağılımı temsil etmektedir. Uygulanan bir öznitelik çıkartma yöntemi sonucunda böyle bir dağılımın oluşması sınıflama işleminin başarımını artıracaktır. Bununla birlikte gerçek dünyada öznitelikler, öznitelik uzayında her zaman böyle ideal bir şekilde dağılmayabilir. Üzerinde çalışılan problem için, veri çeşitliliği arttıkça özniteliklerin uzaydaki dağılımı ideal şeklinden uzaklaşacak, farklı sınıflara ait

öznitelik elemanları birbiri içerisine geçecektir. Bu ise sınıflama işleminin başarımını düşürecektir. Şekil 3.16'da basit bir karar verme mekanizmasının diyagramı gösterilmektedir.



Şekil 3. 16 : Karar verme mekanizması

Karar verme mekanizmasını temel olarak üç blok şeklinde düşünebiliriz: Normalizasyon işlemi, öznitelik çıkartma işlemi ve sınıflama işlemi. Yukarıda anlatılan dönüşüm işlemi, normalizasyon ve öznitelik çıkartma işlemlerinin birleşimi olarak ele alınmıştır. Şekil 3.14'te normalizasyon ve öznitelik çıkartma işlemlerinin sırası bazı durumlarda değişebilmektedir.

Genellikle karar verme mekanizmasına ait parametrelerin belirlenmesinde az sayıda vektör içeren bir alt küme kullanılmaktadır. Bu nedenle öznitelik uzayında sınıfların dağılımının matematiksel ifadesini tam olarak çıkartmak mümkün değildir ve bulunması için de bir uğraş verilmez. Alt küme içinde vektörlerin sayısı ne kadar fazla ise öznitelik uzayındaki dağılımın temsili o kadar iyi olacaktır. Karar verme mekanizmasının genelleme yeteneği, alt küme dışındaki vektörler (örüntüler) için Şekil 3.16'daki bloğun doğru cevap verme sayısı olarak tanımlanmaktadır. Karar verme mekanizmasının genelleme yeteneğini arttırmak için genellikle alt kümenin büyütülmesi yolu tercih edilmektedir [22].

3.4.1 Normalizasyon işlemi

Örüntülere ait bilginin, öznitelik uzayındaki vektörlere direkt olarak aktarılmasını engelleyen üç sebep vardır [22].

- i. Örüntüleri temsil eden vektör elemanlarının sayısının değişimi
- ii. Elemanların vektör içindeki pozisyonunun değişmesi (elemanların vektör içinde kayması)

- iii. Aynı kategoriden örüntüler için vektör elemanlarının genliğinin öznitelik uzayında büyük bir değişim göstermesi. Vektör elemanları üzerindeki bu bilgi taşımayan anlamsız etkiler, sınıflamadan önce normalizasyon işlemi ile ayarlanmalı ve sabitlenmelidir.

Çalışmamızı göz önünde bulundurarak normalizasyon işleminin neden gerekli olduğunu anlamaya çalışalım. EKG vurularını sınıflandırma işleminde kabaca, normal ve aritmili vuru olmak üzere iki kategorinin bulunduğunu düşünelim. Burada her vuru bir örneği temsil eder ve normal ya da anormal (aritmili) bilgisini taşır. Öznitelik çıkartma yöntemi olarak EKG vurularının sabit bir pencere içindeki (pencere, sadece bir vuruya ait verileri içerecek şekilde seçilsin) genlik değerlerinin direkt olarak kullanıldığını düşünürsek, öznitelik vektörünün elemanları EKG işaretinin zaman içindeki ayırık genlik değerlerinden meydana gelecektir. Vektörlere aktarılan bilgiyi bozan anlamsız etkiler yukarıda verilen sıra ile aşağıdaki gibi maddelenebilir [22]:

- i. Atım sayısı (bir EKG periyodunun süresi) yaşa, cinsiyete ve kişinin o andaki fiziksel durumuna bağlı olarak bir değişim göstermektedir. Örnekleme frekansını sabit düşünelim. Bu durumda bir vuru periyodu içindeki veri sayısı her denek için farklı olacaktır. (Öznitelik vektörünün boyutunun değişimi)
- ii. Vektörün ilk elemanını oluşturmak için bir yol belirlenmelidir. Aksi takdirde her oluşturulan vektör için vektör elemanları farklı genlik değerleri alacak, elemanların vektör içindeki pozisyonu kayacaktır.
- iii. EKG vurularının genlik değerleri yaşa ve cinsiyete göre değişmektedir. EKG vurularının genlik değerleri bazı deneklerde, benzer sağlık durumunda olmalarına rağmen, düşük olurken, bazılarında ise son derece yüksek olabilmektedir. Bu durum vektör elemanları üzerinde yanıltıcı bir etki olarak gözlenecektir.

Öznitelik çıkartma yöntemi son derece basit olmasına karşın vektörler üzerinde yukarıda maddelenen yanıltıcı (sınıfları ayırıcı bilgi taşımayan) etkiler oluşmaktadır. Bu etkiler, normalizasyon işlemi ile öznitelik vektörü üzerinden kaldırılmalıdır.

Sınıflayıcı yapılarında öznitelik uzayının boyutu sabit olduğu için vektör elemanlarının sayısı önceden uygun bir değere getirilmelidir. Vektör elemanlarının

kendi içerisinde sırası önemli değildir; ancak elemanların diğer vektörlerdeki elemanlara göre sırası aynı olmalıdır.

Bazı durumlarda alt kümeye ait tüm vektörlerin bazı elemanlarının diğer elemanlara göre daha küçük değerler aldığı gözlenebilir. Bir vektör elemanının tüm vektörler için küçük değerler alması, o elemanın vektörden çıkartılması anlamına gelmemelidir. Boyut azaltmak için bu elemanı tüm vektörlerden çıkartmak yerinde, bu elemanın değeri, sabit bir katsayı ile çarpılarak diğer elemanlarla aynı seviyeye getirilmelidir. Öznitelik uzayındaki sınıf dağılımı, alt kümedeki tüm vektörlerin sabit bir k katsayısı ile çarpılması sonucu değiştirilmiş olmamaktadır. Aynı kural vektörlerin tüm elemanları yerine bazı elemanlarına uygulandığı zaman da geçerlidir. Bu kural ile vektör elemanlarının kendi içinde normalize edilebilmesi sağlanmaktadır. Ancak vektör elemanlarının normalizasyonunda, tüm vektörler aynı işleme tabi tutulmalıdır [22].

3.5 Öznitelik Çıkartma Yöntemleri

Özniteliklerin çıkartılması işlemi, isminden de anlaşılacağı üzere sadece bir kategoriye (sınıfa) ait olan ve diğer kategorilerde bulunmayan karakteristik bilgilerin tespit edilmesi işlemidir. Kategorileri birbirinden ayıran doğru özniteliklerin tespit edilmesi, sınıflama performansının artması üzerinde olumlu bir etki oluşturacaktır. Seçilen her konu için doğru özniteliklerin bulunmasına yönelik matematiksel bir yöntem yoktur ve çoğu durumda kullanılacak öznitelik çıkartma yöntemi tasarımcının sezgisine bağlı olarak tespit edilir [22].

Normal EKG vurularının aritmili vurulardan ayırt edilebilmesinde en çok kullanılan yöntemlerden biri EKG virusunun şekilsel özelliklerini kullanmaktır. Bu anlamda tez kapsamında da EKG virusuna ait bazı morfolojik (şekilsel) özniteliklerin çıkartılması yoluna gidilmiştir. Şekilsel öznitelikler zaman domeni öznitelikleri olup bunun dışında literatürde kullanılan frekans domeni öznitelikleri de mevcuttur.

3.5.1 EKG işaretlerinden şekilsel özniteliklerin çıkartılması

Bu tez kapsamında 4 adet şekilsel öznitelik kullanılmıştır. Şekil 3.18’de tez kapsamında kullanılan öznitelikler gösterilmektedir.


Teorik olarak, normal bir EKG vurusu uzun bir zaman dilimi içerisinde periyodik kabul edilmektedir. Aritmili EKG kayıtları için böyle bir kabulde bulunmak mümkün olmayacaktır. Çünkü birçok aritmi türünde iki ardışık vuru arasında geçen süre değişebilmektedir. Şekil 3.17’de bu daha ayrıntılı olarak görülebilmektedir. Buradan hareketle aritmili bir vurunun teşhisinde, aritmili vurudan bir önceki vuru ile bir sonraki vuru arasındaki süreyi öznitelik olarak kullanmak uygun bir yöntem olarak görülmektedir.

Bölüm başında EKG kaydındaki R tepesi konumlarının Pan-Tompkins algoritması ile bulunduğundan bahsetmiştik. R tepeleri bulunan EKG kaydı içerisinde, ilgili vurudan bir önceki ve bir sonraki vuruların R tepelerinin konumları baz alınarak, RR_{t_n} ve $RR_{t_{n+1}}$ öznitelikleri kolaylıkla bulunabilmektedir. İlgilenilen her bir vuru için bu değerler kaydedilmektedir.

	RR aralığı					
Normal sinus ritmi						
Bradikardi						
Taşikardi						
Asistol						
Eksik Atım						
PVC						
T üzerinde R						
Bigemini						
Trigemini						

Şekil 3. 17 : Çeşitli aritmilerde kalp ritmindeki değişim [23]

Normalizasyon işlemi için ilgili vurudan önceki ardışık sekiz adet normal vurunun RR_t ve RR_{t+1} değerlerinin ortalaması alınır. İlgili vurunun RR_{t_n} ve $RR_{t_{n+1}}$ değerleri, ardışık sekiz adet normal vurunun RR_t ve RR_{t+1} değerlerinin ortalamasına bölünerek normalize edilir. Normalizasyon sonrası öznitelik vektörleri RR_{t_n} ve $RR_{t_{n+1}}$ veri kümesi içinde Şekil 3.19’daki gibi dağılmaktadır.



Şekil 3. 18 : RR_{t_n} ve $RR_{t_{n+1}}$ özniteliklerinin elde edilmesi


$$RRx(t) = \frac{\sum_{i=t-7}^t RRx(i)}{8}; \quad RRx(t) \in 'Normal EKG' \quad (3.16)$$

$$QRSx(t) = \frac{\sum_{i=t-7}^t QRSx(i)}{8}; \quad QRSx(t) \in 'Normal EKG' \quad (3.17)$$


Şekil 3.19'dan görüldüğü gibi RR_{t_n} ve $RR_{t_{n+1}}$ özniteliği aritmileri ayırt etmede yardımcı olmaktadır.

Bir diğer ayırt edici şekilsel öznitelik ise, QRS kompleksinin taban hattından itibaren yüksekliği, yani taban hattı ile R tepesi arasındaki mesafedir. Özellikle karıncık füzyonu ve PVC aritmilerini ayırt etmede bu öznitelik faydalı olmaktadır.

Bu özniteliği normalize etmek için de yine ilgili vurudan önceki ardışık sekiz adet normal vurunun QRS_h değeri toplanır ve ortalaması alınır. Daha sonra ilgili vurunun QRS_h değeri bulunan bu ortalama değere bölünerek normalize edilir. Normalizasyon sonrası QRS_{h_n} öznitelik elemanları veri kümesi içinde Şekil 3.20'deki gibi dağılmaktadır.




a)



b)

Şekil 3. 19 : a) RR_{t_n} öznitelik elemanlarının veri kümesi içindeki dağılımı b) $RR_{t_{n+1}}$ öznitelik elemanlarının veri kümesi içindeki dağılımı




Şekil 3. 20 : Normalizasyon sonrası QRS_{h_n} öznitelik elemanlarının veri kümesi içindeki dağılımı

Tez kapsamında kullanılan sonuncu şekilsel öznitelik ise QRS genişliğidir. QRS genişliği özellikle PVC aritmisini ayırt edici bir özniteliktir. Çünkü PVC aritmisinde QRS genişliği, diğer tip vurulara göre çok daha fazla olmaktadır.

QRS_g özniteliğini normalize etmek için de diğer şekilsel özniteliklerde olduğu gibi ilgili vurudan önceki ardışık sekiz normal vuru göz önünde bulundurulmuştur. Ardışık sekiz normal vurunun QRS_g değerlerinin ortalaması bulunmuş daha sonra ilgili vurunun QRS_g değeri bulunan bu ortalama değere bölünerek normalize edilmiştir. Şekil 3.21’de QRS_{g_n} özniteliğinin veri kümesi içindeki dağılımı gösterilmektedir.

Yukarıdaki şekillerden de görüldüğü gibi kullanılan şekilsel öznitelikler vuru tiplerini birbirinden ayırt etmede büyük ölçüde yardımcı özniteliklerdir.



Şekil 3. 21 : QRS_{g_n} özniteliğinin veri kümesi içindeki dağılımı

4. YAPAY SINIR AĞLARI VE PARÇACIK SÜRÜ OPTİMİZASYONU

4.1 Amaç

Bu bölümde birçok mühendislik probleminin çözümünde yaygın olarak kullanılan yapay sinir ağları hakkında kısa bir bilgi verildikten sonra, radyal tabanlı fonksiyon yapay sinir ağı hakkında detaylı bir bilgi verilecektir. Sonrasında RTFA'yı eğitmek için kullanılan parçacık sürü optimizasyonuna değinilecektir.

4.2 Yapay Sinir Ağları


Yapay sinir ağları (YSA) beyin fizyolojisinden yararlanılarak oluşturulan bilgi işleme modelleridir. Bu yüzden YSA ile ilgili yapılan ilk çalışmalar, insan beyninin matematiksel bir modelini elde etmeye yönelik çalışmalardır. Fakat bugün gelinen noktada YSA'lar birçok mühendislik probleminin çözümünde kullanılmaktadır.

Hecht-Nielsen, YSA'yı aşağıda belirtilen tanımlamaları ve sınırlamaları içeren paralel bilgi işleme özelliğine sahip yönlü bir graf olarak tanımlamıştır [24].

- Yönlü grafın düğümleri *işlem elemanı* olarak tanımlanır.
- Yönlü dallar bağlantılara karşılık düşer ve tek yönlü işaret iletim yolu olarak çalışırlar.
- Her bir işlem elemanı, belirli bir sayıda giriş bağlantısına sahiptir.
- Her bir işlem elemanı, belirli bir sayıda çıkış bağlantısına sahiptir. Ancak çıkış işaretlerinin değeri aynı olmalıdır.
- İşlem elemanları yerel belleklere sahip olabilir.
- Her işlem elemanı, giriş işaretini ve yerel belleği kullanan bir transfer fonksiyonuna sahiptir. Bu fonksiyon işlem elemanının çıkış değerini oluşturur. Transfer fonksiyonu sürekli veya ayrık olarak çalıştırılabilir. Ayrık çalıştırma modunda fonksiyon, bir aktif işareti ile kontrol edilir.

- Yönlü bağlantı ve işlem elemanlarının bir araya gelmesi ile oluşan yapıya, yapay sinir ağı (YSA) ismi verilir. Bu yapı, dış çevreden giriş bağlantıları yolu ile işaret alır ve çıkış alır ve işaret gönderir.

Bir işlem elemanın iç yapısı Şekil 4.1’de gösterilmektedir. Bir işlem elemanın $x_1, x_2, \dots, x_n$, ile belirtilen n tane giriş verisi vardır. Bu veriler, diğer elemanlardan ya da dış ortamdaki bağlantılar üzerindeki ağırlıklardan (işlem elemanın yerel belleğinden) işlem elemanına giren verilerdir.




Şekil 4. 1 : İşlem elemanının yapısı

Burada x_i , giriş vektörünün i . elemanını; w_i , yerel belleğin i . elemanını; n , boyutu; $f(y)$, ise kırpıcı adı verilen ve lineer olmayan transfer fonksiyonunu temsil etmektedir.

Eğitim işlemi ile algılayıcıdaki sadece w_i yerel bellek elemanları değiştirilir. Bu elemanlar çoğu zaman sinir hücresinin *ağırlık vektörü* olarak tanımlanır. Hücresinin ağırlıkları önceden belirlenen amaç ölçütünü sağlaması için bir eğitim algoritması kullanılarak değiştirilir. Öğrenme işlemini, bu amaç ölçütünü en iyi sağlayan w_i ağırlık vektörünü bulmaya doğru adım adım yaklaşma olarak tanımlayabiliriz .

Şekil 4.2’de iki boyutlu uzayda eşit sayıda örnekleri bulunan farklı iki sınıfın dağılımı gösterilmektedir. İşlemci eleman eğitim aşamasında, her bir sınıftan eşit sayıda örnek alarak, iki sınıfı birbirinden ayıracak, şekildeki doğruyu oluşturan optimum w değerlerini araştırır. Şekil 4.2’de verilen dağılım için bu ayrımı gerçekleyen w değerlerinden oluşan bir doğru bulunabilmiştir. Fakat farklı dağılımlar

için tek bir nöron kullanarak böyle bir doğru her zaman bulunamayabilir. Bu nedenle, ağın incelenecek problem yapısına göre uygun ölçüde tasarlanmış olması gerekmektedir.



Şekil 4.2 : İşlem elemanının eğitimi [25]

4.2.1 Yapay sinir ağlarının öğrenme yöntemleri

Öğrenme, gözlem ve eğitimin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır [11]. Ağdaki ağırlıkların değiştirilmesi de bu anlamda bir takım metot ve kurallara göre ağın sergilediği davranış değişikliği, bir diğer ifadeyle öğrenme olarak nitelendirilebilir. Öğrenme algoritmaları, öğrenme işleminin eldeki problemin yapısına göre YSA'ya nasıl adapte edilebileceğini belirler. Literatürde kullanılan en genel üç öğrenme yönteminden söz edilebilir.

4.2.1.1 Danışmanlı öğrenme

Bu öğrenme yönteminde YSA'ya ağın üretmesi gereken doğru çıkış değeri verilir. Ağ, girilen veri değerleri sonucu elde ettiği çıkışı istenilen çıkış değeri ile karşılaştırarak bir hata değeri üretir. Bu hata değerine göre ağın ağırlıkları iteratif olarak güncellenir ve ağın verilen girişlere karşı minimum hata değerini üretmesi hedeflenir. Widrow ve Hoff [27] ve Rumelhart ve McClelland [28] tarafından geliştirilen delta kuralları veya geriye yayılım algoritması danışmanlı öğrenmeye örnek olarak verilebilir.

4.2.1.2 Danışmansız öğrenme

Danışmansız öğrenme yönteminde, girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu yöntemde, istenilen çıkış değerinin bilinmesine gerek yoktur. Öğrenme sürecinde ağa sadece giriş bilgileri verilir. Ağ bağlantılarını aynı özelliği gösteren patternleri oluşturmak üzere günceller. Kohonen [29] tarafından geliştirilen SOM yapısında bu danışmansız öğrenme metotları kullanılmaktadır [30].

4.2.1.3 Takviyeli öğrenme

Bu öğrenme yöntemi danışmanlı öğrenmeye benzer bir yöntemdir. Yalnız bu yöntemde, ağa hedef bir çıkış verilmemekte fakat elde edilen çıkışın girişe karşılık uyumluluğunu değerlendiren bir kriter kullanılmaktadır. GA takviyeli öğrenmeye örnek olarak verilebilir.

4.2.2 Radyal Tabanlı Fonksiyon Yapay Sinir Ağı

Radyal tabanlı fonksiyon yapay sinir ağı (RTFA) ilk kez Broomhead ve Lowe (1988) tarafından ortaya atılmıştır [31]. RTFA, giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmandan oluşan doğrusal olmayan hibrid bir ağ modelidir. RTFA'nın gizli katmanında bulunan nöronlar, radyal tabanlı fonksiyon (RTF) olarak adlandırılan aktivasyon fonksiyonlarına sahiptirler. Radyal tabanlı fonksiyonlar, merkezden uzaklaştıkça çıkışları monolitik olarak azalan veya artan özel fonksiyonlardır.

Sınıflama problemlerinde ve diğer birçok problemde sıklıkla kullanılan Gaussian fonksiyon en çok bilinen RTF'lardandır. Eşitlik 4.1'de skaler bir x girişi için Gaussian fonksiyona ait çıkış ifadesi verilmektedir.


$$h(x) = \exp\left(-\frac{(x-\mu)^2}{\sigma^2}\right) \quad (4.1)$$

Burada, μ , Gaussian fonksiyonunun merkezini, σ ise yayılım parametresini (varyansı) temsil etmektedir. Eşitlik 4.1'den Gaussian fonksiyonun çıkışının merkezden uzaklaştıkça, ki bu $(x-\mu)$ 'nin artması anlamına gelir, azalacağı görülebilmektedir. Bunun tersine, bir diğer RTF olan Multiquadric fonksiyonun

çıkışı merkezden uzaklaştıkça artmaktadır. Eşitlik 4.2’de Multiquadric fonksiyona ait çıkış ifadesi verilmektedir.

$$h(x) = \frac{\sqrt{(\sigma^2 + (x - \mu)^2)}}{\sigma} \quad (4.2)$$

Şekil 4.3 (a) ve (b)’de Gaussian ve Multiquadric fonksiyonlar gösterilmektedir. Herhangi bir sınıflama probleminde her bir sınıfa ait öznitelik vektörleri uzayda öbekleşmiş halde bulunmaktadır. İdeal durumda, her bir öbeğin sınıf içi dağılımının küçük, sınıflar arası dağılımının yüksek olması istenir. Bu her bir sınıfa ait öznitelik vektörlerinin kendi içinde öbekleşmiş olması anlamına gelir. Bunun sınıflama açısından önemi yüksektir. Böylelikle iki boyutlu uzay için her bir sınıfın öbek merkezi bulunarak, o sınıf r yarıçaplı bir daire olarak modellenenabilir. Şimdi Şekil 4.4’de bir göz atalım.




Şekil 4.3 : (a) Gaussian fonksiyon (b) Multiquadric fonksiyon

<http://www.anc.ed.ac.uk/rbf/intro/node7.html>

Şekil 4.4’den açıkça görüleceği üzere, sınıfı bulunmak istenen bir öznitelik vektörünün sınıf öbeğine olan aitliği, sınıf merkezinden uzaklaştıkça azalmaktadır. Daha önce Eşitlik 4.1’deki Gaussian fonksiyonu için yazılan ifade için de benzer şeyler söylenmiştir. Bu bize sınıflama problemlerinde neden RTFA’nın nöronlarının aktivasyon fonksiyonu olarak Gaussian fonksiyonun kullanıldığını açıklamaktadır. Dahası, Gaussian fonksiyon doğrusal olmayan yapısı sayesinde nöron merkezinden uzaklaştıkça ilgili sınıf merkezine olan aitliğin daha da düşmesini sağlamaktadır.

Yani tersi bir ifadeyle, sınıf merkezine yakın yerlerde bu değer 1'e yaklaşırken uzaklaştıkça belirgin bir şekilde düşecektir.



Şekil 4.4 : Sınıf öbekleri için Gaussian fonksiyon modeli


<http://www.dtreg.com/rbf.htm>

Böylelikle gizli katmandaki Gaussian fonksiyon tabanlı her bir nöronun merkezi uygun algoritmalar ile bulunarak, herhangi bir giriş için, ilgili girişin ilgili nöronun temsil ettiği öbeğe olan aitliği bulunabilir.

Şekil 4.5'te RTFA'nın genel yapısı gösterilmektedir. Ağın girişine uygulanan herhangi bir öznitelik vektörü ile ağın nöron merkezleri arasında Euclidian cinsinden uzaklık hesaplanarak çıkışlar üretilir. Bu çıkışlar nöronların aktivasyon fonksiyonlarından geçirilerek gizli katmandaki nöronların nihai çıkışları elde edilir. Nihai çıkışlar, ilgili öznitelik vektörünün nöron merkezlerine ne ölçüde ait olduğunun bilgisini taşır. Daha sonra çıkış katmanında, nihai nöron çıkışları lineer olarak ağırlıklandırılıp toplanır ve sınıf kararı üretilir. Gaussian fonksiyon için ağın çıkış ifadesi bu durumda,

$$c_j(x) = \sum_{i=1}^k \omega_{ji} \exp \left(-\frac{\|x - \mu_i\|^2}{2\sigma_i^2} \right) \quad (4.3)$$

eşitliği ile verilir. Burada ω_{ji} , gizli katmanla çıkış katmanı arasındaki ağırlıkları temsil etmektedir. x , μ_i ve σ_i ise sırasıyla, ağın girişini, ağın nöron merkezlerini ve her bir nöronun yayılım parametresini temsil etmektedir.



Şekil 4.5 : Radyal tabanlı fonksiyon yapay sinir ağının genel yapısı

Eşitlik 4.3'ten RTFA'nın çıkışının ağın toplam nöron sayısı k , ve ağın diğer parametreleri olan μ nöron merkezleri, σ yayılım parametreleri ve ω_{ji} ağırlıklarına bağlı olduğu kolaylıkla görülebilir. Ağın sınıflama performansı bu parametrelerin optimum seçimine bağlıdır. Uygun eğitim algoritmaları kullanılarak bu parametreler bulunabilmektedir. Bir sonraki bölümde RTFA'nın eğitiminde kullanılan geleneksel eğitim algoritmalarına ve bu çalışmada kullanılan algoritmaya detaylı bir şekilde yer verilecektir.

4.2.3 Radyal tabanlı fonksiyon yapay sinir ağının eğitimi

Radyal tabanlı fonksiyon yapay sinir ağının eğitimini başlıca iki ana kısımda ele almak mümkündür. Bunlar;

- 1) Nöron merkezlerinin ve her bir nöronun yayılım parametrelerinin bulunması
- 2) Gizli katman ile çıkış katmanı arasındaki ağırlıkların bulunması

Nöron merkezlerinin tespiti aslında çok bilinen öbek merkezini belirleme problemiyle benzeşmektedir. Bu şüphesiz ağın nöronlarının öznitelik uzayında, öznitelik vektörleri arasında bir yere konumlanmış olduğu kabulünden hareketle

ortaya atılan bir önermedir. Ancak bu önerme her zaman doğru olmayabilir. Bir başka ifadeyle, nöron merkezleri öznitelik vektörleri içerisinde konuşlanmış olmayabilir.

Literatürde kullanılan öbekleştirme algoritmaları yardımıyla nöron merkezlerini bulmak mümkündür. Bilindiği gibi bu algoritmaların birçoğu danışmansız öğrenme yapısına sahip algoritmalarlardır. Dolayısıyla ağdaki nöron sayısı öbekleştirme algoritmasının bulunduğu öbek sayısına eşit olacaktır. Buradan hareketle öncelikle literatürde sık kullanılan öbekleştirme algoritmalarından olan K-Ortalamlar (K-Means) ve Kohonen (SOM) algoritmalarına değinilecektir. Bu algoritmalar RTFA'nın nöron merkezlerini bulmada sıklıkla kullanılan algoritmalarlardır.

4.2.3.1 K-Ortalamlar algoritması

K-Ortalamlar algoritması (MacQueen, 1967) danışmasız öğrenmeye dayalı bilinen en basit öbekleştirme algoritmalarından biridir [32]. Bu algoritmayla, bir veri kümesi için önceden belirlenen K adet öbek merkezi araştırılır. Öbek merkezlerinin düzgün bulunması önemlidir. Genellikle öbek merkezlerinin birbirinden mümkün olduğunca uzak olması istenir.

K-ortalamlar algoritması aşağıdaki adımlardan oluşmaktadır [22].

Adım 1) K adet $\underline{z}_1(1), \underline{z}_2(1), \dots, \underline{z}_K(1)$ başlangıç öbek merkezlerini seç. Bunlar keyfi değerlerdir ve çoğunlukla verilen örnek kümesindeki ilk K öznitelik vektörü olarak seçilirler.

Adım 2) l –inci iterasyonda, $\{\underline{x}\}$ vektörlerini, K adet öbek arasında aşağıdaki bağıntı uyarınca paylaşır.

$$\underline{x} \in S_j(l) \text{ eğer } \|\underline{x} - \underline{z}_j(l)\| < \|\underline{x} - \underline{z}_i(l)\| \quad (4.4)$$

her $i, j = 1, 2, \dots, K$ için $i \neq j$ ve $S_j(l)$, öbek merkezi $\underline{z}_j(l)$ olan vektörlerin kümesidir.

Adım 3) $S_j(l)$ 'deki tüm vektörlerin yeni öbek merkezine olan mesafelerinin karelerinin toplamı minimum olacak şekilde adım 2'den elde edilen sonuçlarla $\underline{z}_j(l+1)$ ($j = 1, 2, \dots, K$) yeni öbek merkezlerini hesapla. Diğer bir anlatımla,

aşağıdaki başarıım indeksi minimum olacak şekilde $z_j(l+1)$ yeni öbek merkezlerini hesapla.

$$J_j = \sum_{\underline{x} \in S_j(l)} \|\underline{x} - \underline{z}_j(l+1)\|^2, \quad j = 1, 2, \dots, K \quad (4.5)$$

Başarıım indeksini minimize eden $\underline{z}_j(l+1), S_j(l)$ 'nin örnek ortalamasıdır. Bu nedenle yeni öbek merkezi aşağıdaki şekilde verilebilir.

$$\underline{z}_j(l+1) = \frac{1}{N_j} \sum_{\underline{x} \in S_j(l)} \underline{x} \quad j = 1, 2, \dots, K \quad (4.6)$$

$N_j, S_j(l)$ 'deki örnek vektör sayısıdır. 'K-ortalamlar' ismi, öbek merkezlerinin ardışıl olarak güncellenmesinden kaynaklanan bir ifadedir.

Adım 4) $j = 1, 2, \dots, K$ için $\underline{z}_j(l+1) = \underline{z}_j(l)$ ise algoritma yakınsamış demektir, işlemler sonlandırılır. Aksi takdirde adım 2'ye git.

K-ortalamlar algoritmasının davranışını etkileyen birkaç faktör mevcuttur: (i) Başlangıçta belirlenen öbek merkezinin adedi, (ii) başlangıç öbek merkezlerinin seçimi, (iii) vektörlerin alınış sırası ve (iv) vektörlerin öznitelik uzayındaki dağılımları. Her ne kadar yakınsamaya ait genel bir ispat mevcut değilse de bu algoritmanın, karakteristik cepler oluşturan bir küme için iyi sonuçlar vermesi beklenmektedir. Pratikte, optimum çözüme ulaşmak için K 'nın çeşitli değerleri ve farklı başlangıç öbek merkezleri ile denemeler yapılması gerekmektedir.

4.2.3.2 Kohonen ağı

Kohonen'in öz düzenlemeli haritaları beyin bilgiyi mantıksal bir çerçevede organize edişini örnekleyen yapılardır. Yapılan araştırmalarda beyin korteksinin fonksiyonel alt bölümlerden oluştuğunu göstermiştir. Bunlardan en önemlileri motor korteks, duyu korteksi, görsel korteks ve işitsel kortektir. Bu korteksler de fonksiyonel açıdan kendi aralarında alt bölümlere ayrılmaktadır. Korteksin bu alt bölümlerini bilinçsel fonksiyonları yerine getirebilmek için birbirleriyle etkileşim halindedirler. Kohonen'in öz düzenlemeli haritası da korteksin bu yapısını örnekleyerek topolojik

olarak birbirlerine yakın olan nöronların bilgiyi kendi içerisinde sürdürmelerini sağlamaktadır [url3].

Kohonen'in öz düzenlemeli haritaları bir, iki veya çok boyutta organize olmuş nöronlardan oluşmaktadır.

Kohonen ağı'nın eğitimi yarışmacı öğrenmeye örnektir. Ağı girişine uygulanan bir öznitelik vektörünün nöronlara olan uzaklığı hesaplanarak, bu girişe en yakın ağırlıklara sahip düğümün bulunması amaçlanmaktadır. En yakın nöron kazanan nörondur. Sonrasında bu nöronun komşuluğunda bulunan nöronların ağırlıkları ilgili nörona olan uzaklıklarıyla ters orantılı olarak güncellenir.

Şekil 4.6'da Kohonen ağı'nın yapısı gösterilmiştir [29]. Kohonen ağı iki katmandan meydana gelir. Ağdaki nöronların girişlerine uygulanan öznitelik vektörlerinin nöron ağırlıklarına benzerliklerini Eşitlik 4.7 ile verilen işlemle belirlerler.

$$D_j = \sum_{i=1}^n (x_i - w_{ji}(k))^2 \quad E_e = \begin{cases} 1 & D_e = \min_j \{D_j\} \\ 0 & \text{aksi takdirde} \end{cases} \quad (4.7)$$


$$\text{Çıkış katmanı} = C_c = \sum_e E_e \cdot T_{ec}$$

E_e , birinci katmandaki nöronların çıkışını; T_{ec} , ise sadece 0 veya 1 değerini alan OR'lama işlemini gerçekleyen bağlantı katsayısını gösterir.

İlk katmanda, nöron ağırlıkları ile giriş vektörü arasında mesafe hesaplanarak en yakın mesafeyi veren nöron bulunur. İkinci katman, ağdaki nöronların ait oldukları sınıfı belirlemek için kullanılır. İkinci katmandaki ağırlıklar, eğitim sonrasında gerçekleştirilen bir etiketleme işlemi ile belirlenir.

Kohonen ağı'nın eğitiminde sadece kazanan nöronun ağırlığı değil, o nöronun belirlenen bir komşuluğundaki nöronun ağırlıkları da değiştirilir. Öğrenme esnasında bu komşuluğun sınırları zamanla lineer olmayacak şekilde azaltılır. Aşağıda Kohonen ağı'nın eğitim algoritması verilmiştir [33].

Başlangıçta, ağ topolojisine bağlı olarak nöron sayısı, komşuluğun zamanla değişimi ve iterasyon sayısı belirlenir. Ağı tüm nöronlarının ağırlıklarına rastgele değerler verilir.



Şekil 4. 6 : Kohonen ağıının yapısı [33]

Adım 1) Eğitim kümesinden rasgele bir vektörü ağı giriş olarak ver.

Adım 2) Giriş vektörü ile ağı düğümleri arasındaki mesafeleri Eşitlik 4.8 ile hesapla.

$$D_j = \sum_{i=1}^n (x_i - w_{ji}(k))^2 \quad (4.8)$$

x_i , giriş vektörünü; w_{ji} ise j . çıkışın ağırlık vektörünü temsil etmektedir.

Adım 3) Minimum uzaklığa sahip J^* çıkışını bul.

Adım 4) J^* çıkışını ve komşularının ağırlıklarını Eşitlik 4.9 ile değiştir.

$$w_{ji}(k+1) = w_{ji}(k) + \eta(t) \cdot (x_i - w_{ji}(k)) \quad (4.9)$$

Kazanç terimi olarak ifade edilen $\eta(t)$, 0 ile 1 arasında ve zamanla azalacak şekilde değer alır.

Adım 5) İterasyon sayısını azalt. İterasyon sayısı sıfıra eşit değil ise adım 1'e git. Aksi takdirde eğitim algoritmasını durdur.

Eğitim sonrasında nöronların sınıf etiketlerini belirlemek için her bir nörona sınıf sayısı kadar bellek gözü atanır. Eğitim kümesindeki vektörler ile ağıdaki nöronlar arasında mesafe hesaplanarak vektörlerin hangi çıkış nöronuna yakın olduğu araştırılır. İncelen giriş vektörüne en yakın nöronun sınıf etiket gözü, giriş vektörünün sınıfı ile ilişkili olarak artırılır. Eğitim kümesindeki tüm vektörler için bu


işlem tekrarlanır. İşlem tamamlandıktan sonra etiket gözü içinde en yüksek değeri veren sınıf araştırılır. Bulunan sınıf, ilgili nöronun sınıf etiketi olarak atanır.

4.2.4 Radyal tabanlı fonksiyon yapay sinir ağının k-ortalamlar ve Kohonen algoritmaları ile eğitilmesi

RTFA'nın eğitiminin iki ana kısımda ele alınabileceğinden söz etmiştik. Hatırlanacağı gibi bunlar, ağın nöron merkezleri ve her bir nöronun yayılım parametrelerinin bulunması ve ağın gizli katmanı ile çıkış katmanı arasındaki ağırlıkların bulunmasıydı. Ağın nöron merkezleri yukarıda anlatılan K-ortalamlar veya Kohonen algoritmalarından biri yardımıyla bulunur. Tez kapsamında bahsedilmeyen herhangi bir öbekleşme algoritması kullanılarak da RTFA'nın nöron merkezleri bulunabilir. Bu durumda nöron sayısı öbekleşme algoritmasının bulduğu öbek merkezi sayısına eşit olacaktır. Bir sonraki adım her bir nöronun yayılım parametresi σ 'nın tespit edilmesidir. Literatürde her bir nöronun σ yayılım parametresi genellikle sabit kabul edilmektedir ve Eşitlik 4.10 ile verilmektedir .

$$\sigma = \frac{d_{\max}}{\sqrt{2k}} \quad (4.10)$$

Burada $d_{\max}$, iki nöron arasındaki maksimum mesafeyi, k ise toplam nöron sayısını temsil etmektedir. σ yayılım parametresini sabit kabul etmek şüphesiz bazı sakıncaları da beraberinde getirmektedir. Şimdi Şekil 4.7'ye bir göz atalım.



Şekil 4. 7 : Sabit σ değeri için sınıf dağılımı

Sabit σ değerine sahip iki nöron, Şekil 4.7’den görüldüğü gibi iki boyutlu öznitelik uzayında eşit yarıçaplı daireler oluşturacaktır. Bu durumda, Şekil 4.7’deki birinci sınıfa ait bir öznitelik vektörünü sınıflamak istediğimizi düşünelim. Dairelerin r yarıçapları eşit olduğu için ve $d_1 > d_2$ olduğundan, ilgili öznitelik vektörünün her iki nöronun sınıf merkezine olan Euclidian mesafesi hesaplandığında, ilgili öznitelik vektörü birinci sınıfa uzak, ikinci sınıfa yakın olarak bulunacaktır. Eşitlik 4.1’den ilgili öznitelik vektörünün her bir sınıfa olan aitliği hesaplanmak istendiğinde, dairelerin r yarıçapları, bir diğer ifadeyle nöronların σ yayılım parametreleri, sabit kabul edildiğinden öznitelik vektörünün ikinci sınıfa olan aitliği daha fazla olacaktır. Bu ise sınıflayıcının yanlış karar üretmesi anlamına gelmektedir. σ yayılım parametresi değerinin birinci sınıf için daha fazla olduğu durumu düşünelim. Bu durumda, birinci sınıfa ait dairenin yarıçapı r ’den büyük olacaktır. Euclidian mesafesi bakımından bir değişiklik olmamasına rağmen, birinci sınıfın öznitelik uzayını çevrelediği r yarıçapı büyüdüğü için Eşitlik 4.1’den, ilgili öznitelik vektörünün birinci sınıfa olan aitliğinin artacağı görülebilmektedir.

Bu tez kapsamında öncelikle σ yayılım parametresinin sabit olduğu kabul edilip K-ortalamlar ve Kohonen algoritmalarıyla her bir nöronun merkezi bulunacaktır. İlerleyen aşamalarda σ yayılım parametresini ve nöron merkezlerini daha optimum bir şekilde belirlemek için öne sürülen algoritmaya değinilecektir. Fakat ondan önce, gizli katman ve çıkış katmanı arasındaki w ağırlıklarını bulmada kullanılan yöntemlere değinilecektir.

Literatürde w ağırlıklarını bulmak için kullanılan en temel iki yöntem mevcuttur. Bu yöntemleri kabaca matris işlemlerinden faydalanarak w ağırlıklarını bulma ve herhangi bir algoritma yardımıyla w ağırlıklarını bulma olarak ikiye ayırabiliriz. Bu yöntemlerin her ikisi de danışmalı öğrenmeye dayalı yöntemlerdir. Bu açıdan bakıldığında RTFA, hem danışmansız öğrenme hem danışmanlı öğrenme yönteminin bir arada kullanıldığı bir ağ yapısıdır.

Bu yöntemlerden ilki sözde-ters (pseudo-inverse) yöntemi olarak bilinen yöntemdir. Bu yöntem, basitçe gizli katman çıkışlarında elde edilen aktivasyon değerlerinin tersinin istenen çıkış değeri ile çarpılması esasına dayanır.

Verilen bir giriş vektör kümesi için, ağ çıkışını Eşitlik 4.11 ile verelim. Bu durumda ağın çıkışı,

$$y(x_i) = w_1 \varphi_1(\|x_i - \mu_1\|) + \dots + w_{j1} \varphi_{j1}(\|x_i - \mu_{j1}\|) \quad (4.11)$$

olarak verilir. Burada φ , aktivasyon fonksiyonunu temsil etmektedir. Eğitim aşamasında ağ çıkışının $y(x_i) = d_i$ gibi bilinen bir çıkış olduğu kabulü ile Eşitlik 4.11 düzenlenirse,

$$w_1 \varphi_1(\|x_i - \mu_1\|) + \dots + w_{j1} \varphi_{j1}(\|x_i - \mu_{j1}\|) = d_i \quad (4.12)$$

eşitliği elde edilir. Eşitliği matris formunda düzenlersek,

$$\begin{bmatrix} \varphi_1(\|x_1 - \mu_1\|) \dots \varphi_{j1}(\|x_1 - \mu_{j1}\|) \\ \dots \\ \varphi_1(\|x_N - \mu_1\|) \dots \varphi_{j1}(\|x_N - \mu_{j1}\|) \end{bmatrix} [w_1 \dots w_{j1}]^T = [d_1 \dots d_N]^T \quad (4.13)$$

elde edilir. Eşitlik 4.13'ün solundaki ilk matrisi Eşitlik 4.14'te

$$\Phi = \begin{bmatrix} \varphi_1(\|x_1 - \mu_1\|) & \dots & \varphi_{j1}(\|x_N - \mu_{j1}\|) \\ \dots & \dots & \dots \\ \varphi_1(\|x_N - \mu_1\|) & \dots & \varphi_{j1}(\|x_N - \mu_{j1}\|) \end{bmatrix} \quad (4.14)$$

olarak kabul edebiliriz. Bu durumda Eşitlik 4.13 yeniden düzenlenirse,

$$\Phi \begin{bmatrix} w_1 \\ \dots \\ w_{j1} \end{bmatrix} = \begin{bmatrix} d_1 \\ \dots \\ d_N \end{bmatrix} \quad (4.15)$$

elde edilir. Sözde-ters yöntemiyle Φ matrisinin, sözde tersi Φ^+ bulunabilir. Bu durumda ağın gizli katmanı ile çıkış katmanı arasındaki ω ağırlıkları Eşitlik 4.16 ile elde edilir.

$$[w_1 \dots w_{j1}]^T = \Phi^+ [d_1 \dots d_N]^T \quad (4.16)$$

Bu tez kapsamında ω ağırlıkları yukarıda anlatılan sözde-ters yöntemiyle matris işlemlerinden faydalanarak bulunmuştur. Bunun dışında ω ağırlıklarını çok bilinen en küçük karesel ortalama (least-mean square) algoritması, gradyan düşümü algoritması veya herhangi bir algoritma yardımıyla da bulmak mümkündür. Tez kapsamında bu yöntemler kullanılmadığı için ayrıca değinilmeyecektir.

Bir sonraki aşamada ağın nöron merkezlerini ve her bir nöronun yayılım parametrelerini daha optimum şekilde belirlemek için, son yıllarda birçok uygulamada kullanılmaya başlayan bir optimizasyon algoritması olan Parçacık Sürü Optimizasyonu'na ayrıntılı bir şekilde yer verilecektir.

4.3 Parçacık Sürü Optimizasyonu

İlk bilgisayarın icadından bugüne bilim insanları bir bilgisayar ile insan aklı arasındaki farkı sorgulamaya başlamışlardır. Örneğin bilgisayarlar da tıpkı insan beyni gibi önermelerden sonuç üretebilmekte, bilgi depolayıp gerekli olduğunda tekrar kullanabilmekte vs. gibi insan aklının sahip olduğu becerilere sahiptirler. Buradan hareketle bilim insanları, akıl bir zekaya sahip ise, bilgisayarların da sahip olmaması için bir neden olmamalı, çıkarımını yapmışlardır.

İlk yapay zeka araştırmacıları, zekanın ölçütü olarak, herhangi bir problemi mümkün olan en kısa zamanda çözebilmeyi referans almışlardır. Bir problem birçok çözüme sahip olabilir. Bilim insanları var olan birçok çözüm içerisinde bilgisayarların en iyi çözümü nasıl bulabilecekleri konusunda çalışmalar yapmışlardır.

1950'li yılların ortalarına gelindiğinde bilgisayarlar artık insan aklı tarafından çözülmesi çok güç olan matematiksel problemleri çözme yetisine sahipti. Fakat sonraları fark edildi ki, bilgisayarlar üstün hesaplama ve hafıza yeteneklerine rağmen basit şeyleri gerçeklemede oldukça yetersizlerdi. Örneğin bir yapay zeka algoritması, herhangi bir yüz tanıma problemini çözemiyordu. Halbuki bu insan aklının kolaylıkla yapabildiği bir şeydi. Algoritmaların karar mekanizmalarına yeni değişkenler eklenerek aynı problemler tekrarlandı. Ancak görüldü ki algoritmaların ürettiği çözümler, o anki sıcaklığa, ışık şiddetine, tanınmak istenen objenin tozlu olup olmamasına vs. gibi ortam şartlarına oldukça bağlıydılar.

Yakın zamanda yapay zeka araştırmacıları daha önce vurgulanmamış, değinilmemiş bir konuya temas ettiler. Bu araştırmacılara göre bilinç, tek bir bireyin kafasının içinde cereyan eden işlemlerin bütünüydü. Bu savdan hareketle, tıpkı bir insan gibi problemleri işleyen bir yapay zeka algoritması geliştirdiler. Yalnız insanı insan yapan en önemli şeyi atlıyorlardı. İnsan bir birey olarak karar verme yetisine sahipti ama çevresinde olan bitene oldukça bağımlıydı, yani insan sosyal bir varlıktı.

Günübirlik kararlar alırken, bunları uygulamaya koyarken, hayatının belki her anında sürekli başka insanlarla ve çevreyle etkileşim halindeydi.

Varlıkların birbiri ile olan bu etkileşimi belirli problemler karşısında en iyi çözümü bulabilmelerine yardımcı olmaktadır. Bir etkileşim sonrası her bir birey kendi doğrusunu güncellerken aynı zamanda bütün toplumun mutlak doğruya ulaşmasına yardımcı olmaktadır. İnsanlar ve toplum açısından olaya baktığımızda, örneğin bugün toplumsal doğruların bütünü aslında bireylerin kendi doğrularından yola çıkarak ve çevrelerindeki bireylerle etkileşerek ürettikleri toplumsal mutlak doğrulardır. Bir bireyin toplumsal mutlak doğruya ulaşma süreci ise topluma adaptasyon süreci olarak nitelendirilebilir. Kennedy ve Eberhart adaptasyonu üç ana kısımda incelemişlerdir.

- Bireyler yerel olarak komşularından öğrenirler. İnsanlar komşularıyla etkileştiklerinin farkındadırlar ve onlardan bir şeyler kaparken onlara bir şeyler aktarırlar. Yerel sosyal öğrenme kolaylıkla ölçülebilir ve iyi dökümente edilmiş bir fenomendir.
- Sosyal öğrenme ile bilginin yayılımı grup seviyesinde gelişmekte olan bir prosestir. Bu fenomenin sosyolojik, ekonomik veya politik seviyeleri, inançlarda, düşünce ve davranışlarda toplumsal bazda düzenlemeyi doğurur.
- Kültür, bilinci optimize eder. Etkileşimler yerel olmasına rağmen, etkileri kültür sayesinde uzak bireylere taşınır. Bunun da ötesinde, farklı etkileşimlerin birleşimi sonucu daha güçlü yöntemler doğabilir. Bu global etki toplum içerisinde bundan faydalanan her bir birey açısından fazlasıyla anlamlıdır.

Bütün bunlardan hareketle varlıkların kendileri arasında cereyan eden olayları ve varlıklar arasındaki ilişkileri inceleyerek toplumsal bir doğruya ulaşılabilceği sonucuna varılabilir. Son yıllarda bilim insanları bu farkındalık sayesinde hayvanların birbirleri ile olan etkileşimlerini de incelemeye başlamışlardır. Çünkü onlara göre hayvanlar da nesillerini sürdürebilmek için üremenin dışında, ortak bir probleme çözüm aramak için birbirleri ile etkileşim halinde olmalılar. Örneğin bir balık sürüsünde, tek bir balığın fark ettiği yaklaşan bir tehlike, diğer balıkları da alarma geçirip hayatta kalmalarını sağlar veya bir kuş sürüsünde tek bir kuşun bulduğu bir yiyecek kaynağı diğer kuşların da bu yiyekten faydalanabilmelerini

sağlar. Karıncalar bir yiyecek kaynağına giden en kısa yolu her seferinde bulabilir. Bilim insanları işte bu gerçeklerden faydalanarak sürü halinde yaşayan hayvanların bir sürü zekasına sahip olduklarını tespit etmişlerdir. Hayvanların sahip olduğu bu sürü zekasından faydalanarak çeşitli algoritmalar geliştirmişlerdir. Bugün gelinen noktada geliştirilen bu algoritmalar sayesinde, herhangi bir mühendislik probleminin muhtemel çözümleri arasında en optimumu en kısa sürede bulunabilmektedir.

Son yıllarda ortaya atılan sürü zekasına dayalı algoritmalarından biri de Parçacık Sürü Optimizasyonudur (PSO). Kennedy ve Eberhart, kuş sürülerinin davranışlarını inceleyerek bir optimizasyon tekniği geliştirmişlerdir [34]. Parçacık sürü optimizasyonunun benzer algoritmalarla göre en avantajlı yanı kolay gerçekleştirilebilir olması ve gradyan bilgisine ihtiyaç duymuyor olmasıdır. Algoritmanın bu özelliği, türevlenebilir olmayan veya türevi hesaplanması güç olan fonksiyonlar için de kullanılabilir olmasını sağlamaktadır.

4.3.1 PSO algoritması

PSO algoritmasında her bir parçacık bir optimizasyon problemi için çözüm uzayında potansiyel bir çözümü temsil etmektedir. n elemanlı bir parçacık sürüsünün her bir i parçacığı aşağıda verilen karakteristik özelliklere sahiptir:

x_i : Parçacığın şimdiki konumu;

v_i : Parçacığın şimdiki hızı;

p_i : Parçacığın şimdiki en iyi bireysel konumu.

Parçacığın en iyi bireysel konumu parçacığın şimdiki konumu olan x_i konumuna gelinceye kadar ziyaret ettiği en iyi konumu ifade eder. Parçacıkların ziyaret ettikleri en iyi konum bir uygunluk fonksiyonu aracılığıyla belirlenir. Eğer bir en-azlama (minimizasyon) problemiyle uğraşıyorsak bu uygunluk değeri, parçacığın ziyaret ettiği konumların uygunluk fonksiyonunu minimize etme yetenekleri ile ölçülür. Fonksiyonu en iyi minimize eden konum, en yüksek uygunluk değerine sahiptir. Bu tez kapsamında uygunluk fonksiyonu f ile temsil edilecektir. Buna göre bir i parçacığının bireysel en iyi konumu p_i Eşitlik 4.17 ile güncellenir [35].

$$p_i(t+1) = \begin{cases} p_i(t), & f(x_i(t+1)) \geq f(p_i(t)) \text{ ise} \\ x_i(t+1), & f(x_i(t+1)) \leq f(p_i(t)) \text{ ise} \end{cases} \quad (4.17)$$

Parçacıkların hızları v_i 'ler ise eşitlik 4.18 ile güncellenir. v_i 'ler aslında her bir parçacığın iterasyon başına ne ölçüde konum değiştirdiğini ifade eder. Yani v_i 'ler aslında Δx_i 'ler olarak ifade edilebilir. Ancak algoritmanın anlaşılabilirliği açısından bu yer değiştirme hızı olarak ifade edilmiştir. Eşitlik 4.18'deki $r_1 \sim U(0,1)$ ve $r_2 \sim U(0,1)$ rasgele değişkenleri algoritmanın stokastik yapısını etkilemek için kullanılan katsayılardır. r_1 ve r_2 değerlerine çarpan olarak gelen $0 \leq c_1, c_2 \leq 2$ katsayıları ivmelendirme katsayıları olarak bilinir ve bir parçacığın tek bir iterasyonda değiştirebileceği maksimum konumu etkiler.

$$v_i(t+1) = v_i(t) + c_1 r_1 (p_i(t) - x_i(t)) + c_2 r_2 (p_g(t) - x_i(t)) \quad (4.18)$$

Eşitlik 4.18'deki $p_g(t)$ ifadesi sürünün şimdiki en iyi küresel (global) konumunu temsil eder. Bu değer sürü içerisindeki bütün parçacıkların bireysel en iyilerinin arasından, en yüksek uyumluluk değerini veren parçacığın konumu olarak seçilir. Bu durumda, c_1 katsayısının bireysel en iyi konumu, c_2 katsayısının ise küresel en iyi konumu düzenlediği sonucuna varılabilir. Parçacıkların konumu ise Eşitlik 4.19 ile güncellenir.

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (4.19)$$

Başlangıçta parçacıkların her birine çözüm uzayında bir ilk konum, ilk hız ve en iyi bireysel konum değeri atanır. Daha sonra parçacıkların her biri için bulundukları konumun uyumluluk değeri hesaplanır. Eğer yeni konumları bireysel en iyi konumlarından iyiye, Eşitlik 4.17 yardımıyla her bir parçacığın bireysel en iyi konumu güncellenir. Daha sonra Eşitlik 4.18 ile parçacıkların hızları güncellenir. Burada dikkat edilmesi gereken nokta, parçacıkların hızları güncellenirken hem her bir parçacığın bireysel en iyi konumunun göz önünde bulundurulması hem de küresel en iyi konumun göz önünde bulundurulmasıdır. Bu nedenle hız güncellemesi yapılmadan önce sürünün küresel en iyi konumu da bulunmalıdır. Sonrasında Eşitlik 4.19 ile her bir parçacığın konumu güncellenir. Böylelikle diğer parçacıklar çözüm uzayında bir parçacığın bulunduğu küresel en iyi konuma doğru kendi bireysel en iyi

konumlarını da dikkate alarak ivmelenenlerdir. Bu konum değişikliği sonrasında her bir parçacık ayrıca daha iyi bir küresel en iyi konumu belirleme şansına sahip olacaktır. Bu durumda diğer parçacıklar bulunan yeni küresel iyi konumuna doğru ilerleyeceklerdir.

Parçacıklar problem uzayı boyunca uçarken çözüm uzayından uzaklaşma riskiyle karşı karşıyadırlar. Bu nedenle parçacıkların hızlarını sınırlama yoluna gidilmiştir. Parçacıkların hızı güncellenirken her bir parçacığın hızı belirlenen bir $[-V_{\max}, V_{\max}]$ aralığına sınırlandırılır [36]. Böylelikle parçacığın çözüm uzayından uzaklaşmasının önüne geçilmiş olunur.

Algoritmanın adım adım açıklaması aşağıdaki gibidir. Şekil 4.8’de temel algoritmanın sözde kodu verilmektedir.

Adım 1) Her parçacık için $[-x_{\max}, x_{\max}]$ aralığında rasgele $x_{i,j}$, konum değerlerini ata ($i \in 1...n$, $j \in 1...d$). Burada n , parçacık sayısı, d ise uzayın boyutudur. Böylelikle parçacıklar uzayda rasgele pozisyonlara konuşturulmuş olur. Algoritmanın yakınsama hızı açısından, eğer çözüm aralığı tahmin edilebiliyorsa $[-x_{\max}, x_{\max}]$ değerlerini tahmin edilen çözüm aralığında vermek faydalı olacaktır.

Adım 2) Her parçacık için $[-v_{\max}, v_{\max}]$ aralığında rasgele $v_{i,j}$, parçacık hızlarını ata ($i \in 1...n$, $j \in 1...d$). Burada n , parçacık sayısı, d ise uzayın boyutudur. $v_{i,j}$ hızları başlangıç olarak sıfır da seçilebilir. Çünkü başlangıç konumları zaten rasgele verilmiştir.

Adım 3) Her x_i parçacığına p_i , en iyi konum bilgisini rasgele ata. Bu değer minimizasyon problemleri için genellikle sonsuz olarak atanır.

Adım 4) Her parçacığın belirlenen uygunluk fonksiyonuna göre uygunluk değerini hesapla.

Adım 5) Eşitlik 4.17 yardımıyla her bir parçacığın bireysel en iyi konumunu güncelle. Sürünün küresel en iyi konumu p_g ’yi ilk iterasyonda, sürü içerisinde en yüksek uygunluk değerini veren parçacığın konumu olarak ata. p_g ’yi sonraki iterasyonlarda, bir önceki iterasyondaki en yüksek uygunluk değerini baz alarak Eşitlik 4.17’dekine benzer bir şekilde güncelle.

Adım 6) Eşitlik 4.18 ve 4.19 yardımıyla her bir parçacığın hızını ve konumunu güncelle. Parçacıkların hızı eğer $[-v_{\max}, v_{\max}]$ aralığının dışına çıktıysa, hızlarını belirlenen limit değerleri ile sınırla. İterasyon sayısını bir arttır.

Adım7) İterasyon sonlandıysa dur, aksi taktirde Adım 4'e git.

```

Loop
  For  $i = 1$  to number of individuals
    if  $G(\vec{x}_i) > G(\vec{p}_i)$  then do           //G() evaluates fitness
      For  $d = 1$  to dimensions
         $p_{id} = x_{id}$                      //pid is best so far
      Next  $d$ 
    End do

     $g = i$                                //arbitrary
    For  $j =$  indexes of neighbors
      If  $G(\vec{p}_j) > G(\vec{p}_g)$  then  $g = j$     //g is index of best performer
                                          in the neighborhood

    Next  $j$ 
    For  $d = 1$  to number of dimensions
       $v_{id}(t) = v_{id}(t-1) + \varphi_1(p_{id} - x_{id}(t-1)) + \varphi_2(p_{gd} - x_{id}(t-1))$ 
       $v_{id} \in (-V_{\max}, V_{\max})$ 
       $x_{id}(t) = x_{id}(t-1) + v_{id}(t)$ 
    Next  $d$ 
  Next  $i$ 
Until criterion

```

Şekil 4. 8 : Temel PSO algoritmasının sözde-kodu [37]

4.3.1.1 PSO algoritmasındaki parametrelerin incelenmesi ve algoritmanın performansını arttırmaya yönelik düzenlemeler

PSO algoritması ilk ortaya atıldığından beri, algoritma üzerinde bazı düzenlemelere gidilmiştir. Bilim insanları farklı problemler üzerinde algoritmayı deneyip, algoritmanın performansını arttıracak yeni görüşler ortaya atmışlardır. Yapılan yeni düzenlemelerle algoritmanın performansı önemli ölçüde artmıştır.


Bu bölümde PSO algoritmasındaki parametre değerlerinin seçimi, bu parametrelerdeki değişimin algoritmayı nasıl etkilediği gibi konulara değinilecektir. Ayrıca algoritmanın performansını önemli ölçüde değiştiren yeni düzenlemelerden bahsedilecektir.

Temel PSO algoritması incelendiğinde, algoritmanın davranışını etkileyecek parametrelerin, $\pm v_{\max}$ hız limit değeri ile, c_1 ve c_2 ivmelendirme katsayıları olduğu kolaylıkla görülebilir. Bunlar algoritma başlangıcında sabit birer değer alıp algoritma sonuna kadar bu değerlerini muhafaza eden parametrelerdir. Tek başına bu değerlerin değiştirilmesi bile algoritmanın davranışını şaşılacak derecede değiştirmektedir.


PSO algoritması stokastik arama yapan bir algoritmadır. Algoritmaya bu özelliğini veren, parçacık hızlarını güncellemede kullanılan 4.18 eşitliğindeki düzgün dağılımlı r_1 , r_2 rasgele sayılarıdır. Algoritma bu stokastik yapısından dolayı çözüm uzayından kolaylıkla uzaklaşıp uzayın farklı bölgelerinde gezinebilir. Bunu önlemek için, parçacıkların hızı güncellenirken belirli limit değerler göz önünde bulundurulur. Böylelikle parçacığın her bir iterasyonda gerçekleştirdiği maksimum yer değiştirmesi kontrol altına alınır. Kennedy ve Eberhart, küresel minimum değeri (0,0) noktası olan bir problem için farklı $v_{\max}$ değerlerinin algoritma üzerindeki davranışını incelemiştirler [37]. Şekil 4.9-10-11’de bu inceleme sonucunda kullanılan farklı $v_{\max}$ değerlerinin algoritmaya etkisi gözlemlenebilir.



Şekil 4. 9 : $v_{\max}$ değeri için bir limitin belirlenmediği durum. Bu durumda, küresel minimum noktasının (0,0) olduğu göz önünde bulundurulursa, 150 iterasyon sonunda parçacıkların bu noktadan bir hayli uzaklaşmış oldukları görülebilir [37].



Şekil 4. 10 : $v_{\max} = 2.0$ durumu. Bu durumda parçacıklar daha dar bir alanda gezinmelerine rağmen hala (0,0) küresel minimum değerinden uzaklar [37].



Şekil 4. 11 : $v_{\max} = 0.2$ durumu. Bu durumda parçacıklar daha da dar bir alanda gezinmekte ve küresel minimum değeri olan (0,0) noktasına oldukça yakınlar [37].

c_1 ve c_2 ivmelendirme katsayıları da algoritmanın davranışını önemli ölçüde değiştirmektedir. Yukarıda bahsi geçen araştırma esnasında, ivmelendirme katsayılarının da algoritmanın davranışı üzerine etkilerini incelenmiştir. Bu iki katsayı sıfır olarak alındığında Eşitlik 4.18 ifadesinden de görüleceği gibi parçacığın hızında bir değişiklik olmayacaktır. Dolayısıyla her bir parçacığın bir sonraki konumu $x_i(t+1)$, doğrusal olarak artma eğilimine girecektir. Katsayılar çok küçük seçildiğinde $x_i(t+1)$, zamanda yavaşça artan ve azalan bir yörünge çizecektir. Katsayı değerlerinin arttırılması $x_i(t+1)$ 'in zamanda değişimini hızlandıracaktır. Katsayıların çok büyük seçilmesi ise, parçacık hızları sınırlandırıldığı için, parçacıkların her seferinde bu hız limitine takılmasına sebep olacaktır.

Yapılan çalışmalar sonucunda bu parametreler için uygun değerler bulunmuştur. $v_{\max}$ değeri, şayet çözüm uzay aralığı öngörülebiliniyorsa, $v_{\max} = k \times x_{\max}$,

$0.1 \leq k \leq 1.0$ olarak alınabilir [38]. c_1 ve c_2 ivmendirme katsayıları ise $0 \leq c_1, c_2 \leq 2$ olarak alınmaktadır [39].

Atalet Katsayısı

Temel PSO algoritması ortaya atıldıktan sonra, algoritma üzerinde yapılan en büyük değişikliklerden biri atalet (inertia) katsayısının kullanılmasıdır. Atalet katsayısı ω , algoritmanın yakınsama hızını önemli ölçüde etkilemektedir ve ilk olarak Shi ve Eberhart tarafından ortaya atılmıştır [40]. Atalet katsayısı, parçacıkların bir sonraki iterasyondaki hızlarını belirlerken, mevcut hızlarını ölçeklemede kullanılır. Bu durumda eşitlik 4.18 ile verilen hız güncelleme ifadesi eşitlik 4.20'deki halini alır.

$$v_i(t+1) = \omega v_i(t) + c_1 r_1 (p_i(t) - x_i(t)) + c_2 r_2 (p_g(t) - x_i(t)) \quad (4.20)$$

Orijinal hız güncelleme ifadesi $\omega = 1$ alınarak elde edilebilir. Shi ve Eberhart atalet katsayısını $[0, 1.4]$ aralığında zamanda değiştirerek, katsayının algoritmaya etkisini incelemişlerdir [40]. İnceleme sonucunda atalet katsayısını $[0.8, 1.2]$ aralığında seçmenin algoritmanın yakınsama hızını arttırdığını görmüşlerdir. 1.2'den büyük değerler için algoritmanın yakınsamasında hatalar meydana gelmeye başlamıştır.

Atalet katsayısı bir anlamda, parçacığın bir önceki hızının ne kadarının bir sonraki hızına etki etmesi gerektiğini belirler. $c_1 = c_2 = 0$, olduğu durumda ω 'yı 1.0'den büyük seçmek parçacığın gittikçe ivmelenmesine sebep olacaktır. ω 'yı 1.0'den küçük seçmek ise parçacığın hızının zamanla sıfır olmasına sebep olacaktır. Şayet $c_1, c_2 \neq 0$ ise, parçacığın nasıl hareket edeceğini öngörmek oldukça zordur. Ama Shi ve Eberhart ω 'nın 1.0'a yakın değerleri için algoritmanın uygun bir davranış sergilediğini belirlemişlerdir [40].

Bir başka çalışmada $v_{\max}$ ve ω 'nın etkisi incelenmiştir [41]. Bu çalışmada $\omega = 0.8$ seçmenin, $v_{\max} = x_{\max}$ olduğu durumda bile iyi sonuçlar verdiği gözlemlenmiştir. Fakat en iyi performans, 1500 iterasyon boyunca ω 'yı 0.9'dan 0.4'e düşürerek elde edilmiştir.

ω 'yı yüksek seçmek algoritmanın küresel arama yeteneğini arttırmaktadır. Algoritmanın rasgele değerlerle ilk kez başlatıldığı anda, küresel arama yeteneğinin iyi olması algoritmanın yakınsama hızına büyük katkıda bulunacaktır. Bununla

birlikte, algoritma küresel minimum etrafında dolaşmaya başladığı anda ω 'nın büyük bir değere sahip olması bir dezavantaj olarak görülebilir. Bu nedenle, literatürde atalet katsayısını zamanla adaptif olarak değiştirmeyi öneren çeşitli çalışmalar mevcuttur [42].

5. RADYAL TABANLI FONKSİYON YAPAY SİNİR AĞININ PARÇACIK SÜRÜ OPTİMİZASYONU İLE EĞİTİLMESİ

5.1 Yöntem

Yapay sinir ağlarının ilk kullanılmaya başlandığı günden bugüne, bu ağların eğitimi bir mühendislik problemi olarak bilim insanlarının karşısına çıkmıştır. Yapay sinir ağlarının eğitimi için birçok yöntem öne sürülmüştür. Bu yöntemler ağların yapısına göre farklılık arzedeabilmektedir ve her bir yöntem ağın sınıflama performansını etkileyebilmektedir. Yapay sinir ağlarını eğitmede kullanılan yöntemlerden biri de, optimizasyon algoritmaları yardımıyla ağ parametrelerinin belirlenmesidir.

Bu tez kapsamında radyal tabanlı fonksiyon yapay sinir ağının nöron merkezleri ve her bir nöronun σ yayılım parametreleri, parçacık sürü optimizasyonu algoritması yardımıyla bulunmuştur.

Bu yöntemde çözüm uzayındaki her bir parçacık, $n_{\max}$ nörondan oluşan aday bir RTFA'yı temsil etmektedir. Yani n parçacıktan oluşan bir sürü için, problemin çözümüne yönelik n tane aday ağıımız vardır. Her bir ağ Eşitlik 5.1'deki gibi ifade edilebilir.

$$Net = [(\mu_1, \sigma_1), (\mu_2, \sigma_2), \dots, (\mu_{n_{\max}}, \sigma_{n_{\max}})] \quad (5.1)$$

Burada, μ nöron merkezini, σ yayılım parametresini, $n_{\max}$ ise ağıdaki maksimum nöron sayısını temsil etmektedir.

Algoritma süresince her bir parçacığın (ağın) uygunluk değeri Eşitlik 5.2 ile verilen uygunluk fonksiyonu ile bulunmaktadır. Belirlenen bir iterasyon sonunda algoritma optimum çözümü veren parçacığı (ağı) tespit etmektedir.

$$E = N_t \times \log\left(\frac{1}{N_t} \sum_{i=1}^{N_t} \|y_i - o_i\|^2\right) \quad (5.2)$$

Burada, N_t eğitim kümesindeki öznitelik vektör sayısını, y_i, o_i ise sırasıyla i . öznitelik vektörü için arzulanan çıkış ile ağ çıkışını temsil etmektedir.

Tez kapsamında RTFA'yı PSO ile eğitmek için aşağıdaki algoritma kullanılmıştır:

Adım 1) n adet parçacıktan oluşan parçacık sürüsünü oluştur. Her bir parçacık uzayda aday bir ağı temsil etmektedir. Maksimum iterasyon sayısını belirle ve sayaca sıfır değerini ver.

Adım 2) Her bir parçacığı ağı nörönlerini temsil edecek şekilde çöz ve ağı oluştur. Ağı gizli katmanı ve çıkış katmanı arasındaki ağırlıkları sözde-ters yöntemi yardımıyla bul. Ağ çıkışını elde et ve eşitlik 5.2 yardımıyla her bir parçacığın (ağın) uygunluk değerini hesapla.

Adım 3) Her parçacık için bireysel en iyi p_i 'yi ve bütün sürü için küresel en iyi p_g 'yi güncelle.

Adım 4) Her bir parçacığın hızını eşitlik 4.20 yardımıyla güncelle. Parçacıkların hızlarını $[-v_{\max}, v_{\max}]$ aralığına sınırla.

Adım 5) Eşitlik 4.19 yardımıyla her bir parçacığın konumunu güncelle.

Adım 6) Sayacı bir arttır. Eğer maksimum iterasyon sayısına ulaşıldıysa dur, aksi taktirde adım 2'ye git.

Zheng Qin ve arkadaşları benzer bir yöntemle RTFA'yı eğitip farklı örüntü tanıma problemleri için ağı performansını incelemişlerdir [43]. Bu çalışma sonucunda, ileri sürülen yöntemin sınıflama performansından ödün vermeden daha küçük bir ağ boyutuyla sınıflama işlemini gerçekleştirdiği görülmüştür.

5.2 PSO-RTFA'nın Fantom Öznitelik Uzayını Bölütlemesi

Önerilen yöntemin performansını denemek için, EKG vurularını sınıflamadan önce Şekil 5.1 ile gösterilen fantom öznitelik uzayı, farklı sayıda nörönlar kullanılarak bölütlenmiştir.



Şekil 5. 1 : Fantom öznelik uzayı

Şekil 5.1 ile gösterilen fantom öznelik uzayında 3 farklı sınıfa ait öznelik vektörlerinin olduğu kabul edilmektedir. Siyah bölgeler farklı bir sınıf olarak kabul edilmemekte, sınıflama esnasında bu bölgelerin diğer üç sınıftan birine sınıflandırılması sağlanmaktadır. Öznelik elemanı olarak her bir noktanın koordinat değeri kullanılmaktadır.

Eğitim kümesinde her sınıf için 600 vektör bulunmaktadır. Parçacık konumları [0.255] aralığında başlatılmıştır. PSO algoritmasının parametreleri Çizelge 5.1'deki gibi alınmıştır.

Çizelge 5. 1 : Fantom uzayı bölütlemek için PSO algoritmasında kullanılan parametreler

ω (Atalet Katsayısı)	0.7298
c_1, c_2	1.496
$[-v_{\max}, v_{\max}]$	[-20,20]
Sürü popülasyonu	20
İterasyon Sayısı	500

Bölütleme işlemi sırasıyla 3, 5, 10, 12, 15 ve 20 nöron sayısı için tekrarlanmıştır. EK-A'da bölütleme işlemi sonucunda elde edilen fantom öznelik uzayı görüntüleri gösterilmektedir.

EK-A'dan görüldüğü gibi önerilen yöntem sadece 3 nöronla bile kabul edilebilir bir çıkış değeri üretmektedir. Bununla birlikte, ağdaki nöron sayısı arttıkça ağın bölütleme kabiliyeti gittikçe kötüleşmektedir. 12 nöron için ağ, fantom öznelilik uzayı görüntüsüne oldukça yakın bir çıkış vermektedir.

σ yayılım parametresinin ağın bölütleme başarısına etkisini inceleyebilmek için, σ bütün nöronlar için aynı değer kullanılarak denemeler yapılmıştır. EK-B'de aynı σ değeri için ağ çıkışları gösterilmektedir. EK-A ile EK-B kıyaslandığında kullanılan nöron sayısı az iken σ değerini her bir nöron için değişken (farklı) almanın ağın bölütleme başarısını arttırdığı görülmektedir. Bunun aksine aynı σ değeri için nöron sayısı arttıkça ağın bölütleme başarısı artmaktadır. σ değerinin nöron sayısının az olduğu durumda daha büyük bir bölgeyi kapsadığı için ağın sınıflama başarısını arttırdığı düşünülebilir. Ağdaki nöron sayısı arttıkça her bir nöronun küçük bir bölgeyi çevrelemesi yeterli olmaktadır. Bu da aynı σ değeri için bölütleme başarısının artışı açıklamaktadır.

Üzerinde durulması gereken bir diğer nokta da, PSO-RTFA kombinasyonun nöron merkezlerini çözüm uzayı aralığı dışında bir yerde bulabiliyor olmasıdır. Yukarıda yapılan denemelerin bazılarında, ağın nöron merkezlerinden bir iki tanesi [0, 255] aralığının dışında bir yerde konuşlanmıştı. Bu algoritmanın yapısından kaynaklanan bir durumdur ve böyle olmasında bir sakınca yoktur.


RTFA, k-ortalamar algoritması ile eğitilip, her bir nöronun σ yayılım parametresi değeri bütün nöronlar için aynı değer alındığında, 3, 5, 12 ve 20 öbek merkezi için ağın çıkışı EK-C'deki gibi olmaktadır.

EK-A ve EK-C karşılaştırıldığında, k-ortalamar algoritmasının öbek merkez sayısı 3 ve 5 olarak seçildiğinde PSO-RTFA'ya nazaran oldukça kötü bir çıkış görüntüsü verdiği görülmektedir. Bununla birlikte, öbek sayısı arttıkça bölütleme başarısı artmaktadır. Bu durumda, RTFA'yı PSO algoritması ile eğitmenin en büyük avantajının, daha az nöron kullanarak aynı performansı elde etmek olduğu söylenebilir. Bu Zheng Qin ve arkadaşları'nın yaptıkları çalışmada elde ettikleri sonuçla uyumlu bir sonuçtur [43].

5.3 PSO-RTFA ile EKG Vurularının Sınıflandırılması

EKG vurularını sınıflamak için kullanılan sistemin blok diyagramı Şekil 5.2’de gösterilmektedir. Eğitim kümesi her sınıftan 50 adet olmak üzere toplam 300 öznitelik vektöründen oluşmaktadır. Test kümesindeki öznitelik vektörlerinin sayısı her bir sınıf için farklılık arz etmektedir. Öznitelik elemanı olarak bölüm 3’te bahsedildiği gibi 4 adet şekilsel öznitelik kullanılmıştır.

PSO algoritması, radyal tabanlı fonksiyon yapay sinir ağının nöron merkezlerini ve her bir nöronun σ yayılım parametresini optimize etmektedir. Algoritmaya ait parametreler Çizelge 5.2’de verilmektedir. Her bir parçacık uzayda bir RTFA’yı temsil etmektedir. Her parçacık çözülerek RTFA’ya ait nöron merkezleri ve her bir nöronun σ yayılım parametreleri elde edilir. Her bir parçacığın (ağın) uygunluk değeri Eşitlik 5.2 yardımıyla hesaplanır. Bulunan uygunluk değerlerine göre parçacıkların hızları ve konumları güncellenir. 500 iterasyon sonunda algoritma durdurulur.



Şekil 5. 2 : Sınıflamada kullanılan sistemin blok diyagramı


Çizelge 5. 2 : EKG vurularını sınıflamak için PSO algoritmasında kullanılan parametreler

ω (Atalet Katsayısı)	0.7298
c_1, c_2	1.496
$[-v_{\max}, v_{\max}]$	[-0.1, 0.1]
Sürü popülasyonu	20
İterasyon Sayısı	500

Algoritma sonlandırıldığında küresel en iyiye veren parçacığın konumu bize aranan RTFA'yı verir. Bu konum çözülerek ağı a ait nöron merkezleri ve her bir nöronun σ yayılım parametreleri elde edilir ve saklanır. Her bir iterasyonda ağı nöronlarının gizli katmanları ile çıkış katmanları arasındaki w ağırlıkları sözde-ters yöntemi yardımıyla elde edilir. 500 iterasyon sonunda elde edilen w ağırlık deęerleri test aşamasında kullanılacaktır. Bu yüzden bu deęerler saklanmalıdır.

Test aşamasında, eğitim sırasında elde edilen ağı nöron merkezleri, her bir nöronun σ yayılım parametreleri ve w ağırlıkları kullanılır. Oluşturulan ağı girişine verilen bir test vektörü için sınıf kararı üretilir.

Ağı EKG vurularını sınıflamadaki başarısını belirlemek için farklı nöron sayıları kullanılarak denemeler yapılmış ve geleneksel RTFA eğitim yöntemleri ve k-en yakın komşuya sınıflayıcı ile önerilen yöntem karşılaştırılmıştır.



Şekil 5.3: PSO-RTFA ile K-ortalamalar algoritmasının karşılaştırılması


Şekil 5.3'te önerilen yöntemle ve K-ortalamalar algoritmasıyla farklı sayılarda nöronlar kullanılarak gerçekleştirilen on denemenin ortalama sonuçları gösterilmektedir. Şekilden görüldüğü gibi önerilen yöntem EKG vurularını iyi bir performansla sınıflayabilmek için yalnızca 10 nörona ihtiyaç duymaktadır. K-ortalamalar algoritması ise önerilen yöntemin sınıflama başarımına ulaşabilmek için 25 öbek merkezine ihtiyaç duymaktadır. Çizelge 5.3'te önerilen yöntemle yapılan bir

denemenin sonucu gösterilmektedir. Duyarlılık ve belirlilik sırasıyla Eşitlik 5.3 ve 5.4 ile hesaplanabilir.

$$Duyarlilik = \frac{Toplam\ Dogru\ Pozitifler}{Toplam\ Dogru\ Pozitifler + Toplam\ Yanlis\ Negatifler} \times 100 \quad (5.3)$$

$$Belirlilik = \frac{Toplam\ Dogru\ Negatifler}{Toplam\ Dogru\ Negatifler + Toplam\ Yanlis\ Pozitifler} \times 100 \quad (5.4)$$

Çizelge 5.4'te ise önerilen yöntem ile 10 nöron için yapılan on farklı denemenin ortalama sonuçları verilmektedir.




Şekil 5. 4 : Bütün noronlar için aynı yayılım parametresi kullanıldığı durumda PSO-RTFA'nın sınıflama başarımı

Çizelge 5. 3 : Önerilen yöntemin yapılan bir deneme için vuru bazında sınıflama sonucu

Vuru Tipi	N	PVC	F	A	R	f	Duyarlılık	Belirlilik
N	796	0	27	2	11	0	95.215 %	98.690 %
PVC	0	577	17	10	1	0	95.371 %	99.738 %
F	11	2	232	0	2	1	93.548 %	97.613 %
A	3	0	0	161	0	1	97.575 %	99.390 %
R	3	1	0	0	146	0	97.333 %	99.294 %
f	0	1	1	0	0	128	98.461 %	99.900 %
Ortalama							96.251 %	99.104 %

Dikkat edilmesi gereken bir diğer nokta ise önerilen yöntemin yalnızca 6 nöronla bile kabul edilebilir bir performansla EKG vurularını sınıflayabiliyor olmasıdır. Önerilen yöntem σ yayılım parametresini her bir nöron için ayrı ayrı optimize ettiği için nöron sayısı az olsa bile kabul edilebilir bir performans sergileyebilmektedir. Geleneksel RTFA eğitim yöntemlerinde her bir nöronun σ yayılım parametresi bütün nöronlar için aynı kabul edilip Eşitlik 4.10 ile hesaplanmaktadır.

Bunu doğrulamak için σ yayılım parametresi her iterasyonda Eşitlik 4.10 ile hesaplanmak kaydıyla farklı nöron sayıları için yine 10'ar deneme yapılmıştır. Yalnız burada dikkat edilmesi gereken nokta σ 'nın her bir nöron için aynı kabul edilmesine karşın zamanla her bir iterasyonda değişiyor olmasıdır. Şekil 5.4'te yapılan denemenin sonuçları gösterilmektedir. Görüldüğü gibi nöron sayısının az olduğu durumda σ yayılım parametresini her bir nöron için aynı kabul etmek önerilen yöntemin sınıflama başarısını düşürmektedir. Bununla birlikte sınıflama başarısı hala K-ortalama algoritmalarından daha iyidir. Şekil 5.5'te σ yayılım parametresinin bütün nöronlar için aynı olduğu durum ile olmadığı durum detaylı bir şekilde karşılaştırılmıştır. Görülen sonuçlar 6,10,15,20,25 ve 30 nöronla yapılan 10'ar denemenin ortalama sonuçlarıdır.



Şekil 5. 5 : Bütün nöronlar için aynı yayılım parametresinin kullanıldığı durum ile değişken parametrelili durumun karşılaştırılması

Çizelge 5. 4: PSO-RTFA ile 10 nöron için yapılan on denemenin ortalama sonucu

N				PVC				F				A				R				f									
TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	TP	FN	FP	TN	Duyarlılık	Belirlilik				
1.	809	27	18	1280	571	34	2	1527	233	15	33	1853	160	5	25	1944	145	5	12	1972	126	4	1	2003	95.94	99.15			
2.	784	52	17	1281	569	36	5	1524	232	16	68	1818	160	5	11	1958	145	5	14	1970	128	2	1	2003	95.58	98.91			
3.	770	66	27	1271	572	33	5	1524	232	16	76	1810	150	15	14	1955	145	5	14	1970	128	2	1	2003	94.34	98.71			
4.	789	47	18	1280	569	36	6	1523	231	17	50	1836	159	6	25	1944	147	3	14	1970	124	6	2	2002	95.22	98.92			
5.	794	42	18	1280	569	36	2	1527	233	15	63	1823	160	5	12	1957	146	4	12	1972	124	6	1	2003	95.44	98.98			
6.	797	39	19	1279	568	37	2	1527	233	15	32	1854	160	5	25	1944	146	4	14	1970	125	5	3	2001	95.60	99.10			
7.	802	34	20	1278	553	52	1	1528	234	14	80	1806	155	10	10	1959	146	4	17	1967	116	14	0	2004	93.70	99.41			
8.	796	40	17	1281	577	28	4	1525	232	16	45	1841	161	4	12	1957	146	4	14	1970	128	2	2	2002	96.25	99.11			
9.	779	57	15	1283	576	29	5	1525	234	14	58	1828	159	6	20	1949	147	3	14	1970	127	3	1	2003	95.80	98.94			
10.	762	74	15	1283	567	38	2	1527	234	14	97	1789	159	6	13	1956	148	2	14	1970	121	9	2	2002	94.55	98.66			
Ortalama																							95.24	98.99					


Şekil 5.5'ten görüldüğü gibi yayılım parametresini bütün nöronlar için aynı kabul etmek nöron sayısının az olduğu durumda sınıflama performansını düşürmektedir, ancak nöron sayısı arttıkça daha kararlı sonuçlar elde edilmektedir.

Çizelge 5. 5 : Farklı sınıflayıcıların karşılaştırılması

Sınıflayıcı	Nöron sayısı	Duyarlılık %	Eğitim süresi	Test süresi
Kohonen – RTFA	64	93.565	7.940 sn.	2.6208 sn.
K-Means – RTFA	25	95.232	0.346 sn.	0.4987 sn.
Matlab newrb ($\sigma = 0.4$)	25	95.377	3.806 sn.	0.5213 sn.
PSO-RTFA	10	95.246	79.768 sn.	0.2250 sn.
PSO-RTFA (sabit σ)	30	95.469	251.070 sn.	0.5847 sn.
k-NN	k = 5	94.390	-	11.6271 sn.
k-NN	k = 3	94.989	-	9.9267 sn.

Çizelge 5.5'te diğer sınıflayıcılar ile önerilen yöntem karşılaştırılmıştır. Önerilen yöntem sınıflama başarımı açısından oldukça yüksek bir başarımla birlikte test kümesini sınıflama süresi de diğer sınıflayıcıların çok çok altındadır. Denemeler Intel (R) Pentium (R) M 1.86 GHz işlemciye, 2 GB RAM'e sahip bir bilgisayarda yapılmıştır. Algoritmaların geliştirilmesi için MATLAB (R) 7.1 kullanılmıştır.

Verilen bir EKG kaydına ait aritmilerin tespiti için MATLAB ortamında bir grafik arayüz (GUI) tasarlanmıştır. Şekil 5.6'da tasarlanan grafik arayüz gösterilmektedir.



Şekil 5.6 : Girilen bir EKG kaydını sınıflamak için tasarlanan grafik arayüz programı

Eğitim kümesi ve algoritma parametreleri kullanıcı tarafından verilmektedir. Belirlenen bir nöron sayısına sahip optimum ağ algoritma yardımıyla bulunmaktadır. Sonrasında kullanıcı tarafından verilen bir EKG kaydı bulunan optimum ağ vasıtasıyla sınıflandırılmaktadır.

5.4 Sonuçlar ve Tartışma

Önerilen yöntemin ağın sınıflama başarısından ödün vermeden diğer yöntemlere nazaran çok daha hızlı sınıflama sonuçları verdiği görülmektedir. Bunun sebebi şüphesiz bulunan optimum ağın diğer yöntemlere nazaran daha küçük boyutlarda olmasıdır. Bununla birlikte bir EKG vuru sınıflama uygulaması için sınıflama başarımı tatmin edici olmayabilir. EKG vurularının frekans domeni öznitelikleri kullanılarak sınıflama başarısını arttırmaya yönelik düzenlemeler yapılabilir. Öznitelik vektör boyutu arttıkça önerilen yöntemin eğitim süresi de buna paralel olarak artacaktır. Bu artış, yöntemin daha az nöronla optimum çözümü yakalama

eğiliminde olduğu göz önünde bulundurulursa, önemsenecek bir problem teşkil etmemektedir.

KAYNAKLAR

- [1] **Ubeyli, E.D.**, 2009, "Combining recurrent neural networks with eigenvector methods for classification of ECG beats," *Digital Signal Processing*, **19**, no **2**, pp. **320-329**,
- [2] **Ubeyli, E.D.**, 2007, "ECG beats classification using multiclass support vector machines with error correcting output codes," *Digital Signal Processing*, **17**, Issue **3**, Pages **675-684**
- [3] **Ceylan, R., Ozbay, Y., Karlik, B.**, 2009, "A novel approach for classification of ECG arrhythmias: Type-2 fuzzy clustering neural network," *Expert Systems with Applications*, **36**, no. **3**, pp. **6721-6726**
- [4] **Dokur, Z., Olmez, T.**, 2001, "ECG beat classification by o novel hybrid neural network", *Computer Methods & Programs in Biomedicine*, **66**, pp. **167-181**
- [5] **Osowski, S., Tran H. L.**, 2001, "ECG beat recognition using fuzzy hybrid neural network," *Biomedical Engineering, IEEE Transactions on*, **48**, no.**11**, pp.**1265-1271**
- [6] **Yu, S., Chou, K.**, 2008, "Integration of independent component analysis and neural networks for ECG beat classification", *Expert Syst. Appl.* **34**, 4 **2841-2846**.
- [7] **Wei, J., Seong Kong, G.**, 2007, "Block-Based Neural Networks for Personalized ECG Signal Classification," *Neural Networks, IEEE Transactions on*, **18**, no.6, pp.**1750-1761**
- [8] **Guler, İ., Ubeyli, E.D.**, 2005, "ECG beat classifier designed by combined neural network model," *Pattern Recognition*, **38**, Issue **2**, pages **199-208**
- [9] **Engin, M.**, 2004, "ECG beat classification using neuro-fuzzy network," *Pattern Recognition Letters*, **25**, Issue **15**, pages **1715-1722**
- [10] **Korurek, M., Nizam, A.**, 2008, "A new arrhythmia clustering technique based on Ant Colony Optimization," *Journal of Biomedical Informatics*, **41**, Issue **6**, Pages **874-881**
- [11] **Ghongade, R., Ghatol, A.**, 2008, "A Robust and Reliable ECG Pattern Classification using QRS Morphological Features and ANN", *TENCON 2008 - 2008 IEEE Region 10 Conference Nov. 18 – 21 India*
- [12] **Azemi, A., Sabzevari, V.R., Khademi, M., Gholizade, H., Kiani, A., Dastgheib, Z.S.**, 2006, "Intelligent Arrhythmia Detection and Classification

- Using ICA," *Engineering in Medicine and Biology Society, EMBS '06. 28th Annual International Conference of the IEEE* , **pp.2163-2166**
- [13] **Haijian, Z., Hai, W., Jiarui, L.**, 1998, "QRS classification using adaptive Hermite decomposition and radial basis function network," *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE* , **1**, **pp.147-150**
- [14] **Al-Fahoum, A.S, Howitt, I.**, 1999, "Combined wavelet transformation and radial basis neural networks for classifying life-threatening cardiac arrhythmias," *Medical and Biological Engineering and Computing*, **37**, **Number 1, Pages 566-573**
- [15] **Chudacek, V., Petrik M., Georgoulas, G., Cepek, M., Lhotska, L., Stylios, C.**, 2007, "Comparison of seven approaches for holter ECG clustering and classification," *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE* , **pp.3844-3847**
- [16] **Melgani, F., Bazi, Y.**, 2008, "Classification of Electrocardiogram Signals With Support Vector Machines and Particle Swarm Optimization," *Information Technology in Biomedicine, IEEE Transactions on* , **12**, **no.5**, **pp.667-677**
- [17] **Yazgan, E., Korürek, M.**, "*Tıp Elektroniği*", *İTÜ yayınları*
- [18] **Guyton, A.C., Hall, J.E.**, "*Textbook of Medical Physiology 11th. Edition*," *ISBN 0-7216-0240-1, Elsevier Inc.*
- [19] **Dinçer, U.**, 1989, "Elektrokardiyografi," *Aycan Akademik Yayıncılık*
- [20] **Korürek, M.**, 1996, "Tıp elektroniğinde tasarım ilkeleri, ", *ISBN 975-561-081-2*
- [21] **Pan, J., Tompkins, W. J.**, 1985, "A Real-Time QRS Detection Algorithm," *Biomedical Engineering, IEEE Transactions on* , **vol.BME-32**, **no.3**, **pp.230-236**
- [22] **Dokur, Z.**, 2006, "Pattern Recognition by Neural Networks", *Ders Notları, İTÜ*
- [23] **Tompkins, W. J., Webster, J. G.**, 1981, "Design of Microcomputer Based Medical Instrumentation", *Englewood Clifs, pp.398-9 Prentice-Hall.*
- [24] **Hecht-Nielsen, R.**, 1990, *Neurocomputing*, HNC, Inc. and University of California, San Diego, Addison-Wesley.
- [25] **Kurnaz, M.N**, 2006, "Artımsal yapay sinir ağları kullanılarak ultrasonik görüntülerin bölütlenmesi", *Doktora Tezi, İTÜ*
- [26] **Zurada, J.M.**, 1992, "Introduction to Artificial Neural Networks," *West Pupliching Company, St. Paul*

- [27] **Widrow, B., Hoff, M.**, 1960, "Adaptive Switching Circuits, Ire Wescon Convention Record," **4, 96-104.**
- [28] **Rumelhart, D.E., Mc Clelland, J.L.**, 1986, PDP Research Group, "Paralel Distributed Processing: Explorations in the Microstructure of Cognition", *MIT Pres, Cambridge.*
- [29] **Kohonen, T.**, 1972, "Correlation Matrix Memories, " *IEEE Transactions on Computers*, **21, 353-359.**
- [30] **Kohonen, T.**, 1984, "Self-Organization and Associative Memory, " Springer Verlag- Berlin.
- [31] **Broomhead, D. S., Lowe, D.**, 1988, "Multi-variable functional interpolation and adaptive networks, " *Complex Systems*, **2, pp. 321-355.**
- [32] **McQueen, J. B.**, 1967, "Some Methods for classi_cation and Analysis of Multivariate Observations," *Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability, Berkeley, University of California Press*, **1 281-297**
- [33] **Nizam, Ali**, 2008, "Karıncı koloni optimizasyonuna dayalı yeni bir aritmi sınıflama tekniđi", *Doktora Tezi, İTÜ*
- [34] **Kennedy, J., Eberhart, R.C.**, 1995, "Particle Swarm Optimization, " *Proceedings of IEEE International Conference on Neural Networks*, Piscataway, NJ 1942-1948
- [35] **Bengh, F.V.D**, 2001, "An Analysis of Particle Swarm Optimizers", *PhD Thesis*, University of Pretoria
- [36] **Settles, M.**, 2005, "An Introduction to Particle Swarm Optimization, " Department of Computer Science, University of Idaho, Moscow, Idaho U.S.A 83844
- [37] **Kennedy, J., Eberhart, R.**, 2001, "*Swarm Intelligence*"
- [38] **Corne, D., Dorigo, M., Glover, F**, 1999, "New Ideas in Optimization", **chapter 25, pages 379-387**, McGraw Hill
- [39] **Gaıng, Z.**, 1994, "A particle swarm optimization approach for optimum design of PID controller in AVR system, " *IEEE Transactions on Energy Conversion*, **19, no. 2, pp. 384-391.**
- [40] **Shi, Y., Eberhart, R.C.**, 1998, "A modified particle swarm optimizer," *In IEEE International Conference of Evolutionary Computation*, Anchorage, Alaska
- [41] **Shi, Y., Eberhart, R.C.**, 1998, "Parameter selection in particle swarm optimization," *In Evolutionary Programming VII, Proceedings of EP 98*, **pages 591-600**

- [42] **Shi, Y., Eberhart, R. C.**, 2001, "Particle Swarm Optimization with Fuzzy Adaptive Inertia Weight", *In Proceedings of the Workshop on Particle Swarm Optimization, Indianapolis, IN, USA*. Purdue School of Engineering and Technology, IUPUI.
- [43] **Qin, Z., Chen, J., Lui, Y., Lu, J.**, 2005, "Evolving RBF Neural Networks for Pattern Classification", *Lecture Notes in Computer Science*, **3801**
- url1: <http://lokman.cu.edu.tr/anestezi/tayfunguler/files/aritmiler.htm> Alındığı Tarih 29.04.2009
- url2: <http://www.physionet.org/physiobank/database/html/mitdbdir/mitdbdir.htm> Alındığı Tarih 29.04.2009
- url3: <http://www.rocksolidimages.com/pdf/kohonen.pdf> Alındığı Tarih 29.04.2009
- url4: <http://www.dtreg.com/rbf.htm> Alındığı Tarih 29.04.2009
- url5: <http://www.anc.ed.ac.uk/rbf/intro/node7.html> Alındığı Tarih 29.04.2009

EKLER

EK A : PSO-RTFA'nın fantom uzayı bölütlemesi

EK – A



(a) 3 nöron



(b) 5 nöron



(c) 10 nöron



(d) 12 nöron



(e) 15 nöron



(f) 20 nöron

Şekil A. 1 : PSO-RTFA'nın fantom uzayı bölütlemesi



(a) 3 nöron



(b) 5 nöron



(c) 10 nöron



(d) 12 nöron



(e) 15 nöron



(f) 20 nöron

Şekil A. 2 : PSO-RTFA'nın fantom uzayı bölütlemesi (yayılım parametresi bütün nöronlar için aynı seçildiğinde)



(a) 3 nöron



(b) 5 nöron



(c) 12 nöron



(d) 20 nöron

Şekil A. 3 : RTFA – K-Ortalamlar'ın fantom uzayı bölütlemesi

ÖZGEÇMİŞ

Ad Soyad: Berat Doğan

Doğum Yeri ve Tarihi: Malatya - 1985

Lisans Üniversitesi: Erciyes Üniversitesi - Elektronik Mühendisliği

Yayın Listesi:

▪ **Doğan B., Korürek M.,** 2009, EKG Vurularını Sınıflamada Radyal Tabanlı Fonksiyon Yapay Sinir Ağının Performans Değerlendirmesi, 14. Biyomedikal Mühendisliği Ulusal Toplantısı (BIYOMUT 2009), Dokuz Eylül Üniversitesi, İzmir