

İSTANBUL TEKNİK ÜNİVERSİTESİ H FEN BİLİMLERİ ENSTİTÜSÜ

**ELEKTROKARDİYOGRAM VURULARININ GAL AĞI YARDIMIYLA
SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Müh. Selin METİN

Anabilim Dalı: ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ

Programı: BİYOMEDİKAL MÜHENDİSLİĞİ

Tez Danışmanı: Doç. Dr. Mehmet KORÜREK

MAYIS 2002

İSTANBUL TEKNİK ÜNİVERSİTESİ H FEN BİLİMLERİ ENSTİTÜSÜ

**ELEKTROKARDİYOGRAM VURULARININ GAL AĞI YARDIMIYLA
SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ
Müh. Selin METİN
(504991125)**

**Tezin Enstitüye Verildiği Tarih : 13 Mayıs 2002
Tezin Savunulduğu Tarih : 27 Mayıs 2002**

**Tez Danışmanı : Doç.Dr. Mehmet Korürek
Diğer Jüri Üyeleri Prof.Dr. Atilla Bir
Doç.Dr. Tamer Ölmez**

MAYIS 2002

ÖNSÖZ

“Elektrokardiyogram Vurularının GAL Ağı Yardımıyla Sınıflandırılması” konulu tez çalışmamı gerçekleştirmemde bilimsel desteği ve değerli düşünceleriyle bana her aşamada yardımcı olan, danışmanım Sayın Doç. Dr. Mehmet KORÜREK’e teşekkür ederim.

Bugüne kadar çalışmalarım sırasında maddi ve manevi desteklerini benden esirgemeyen, sabır ve anlayış göstererek daima yanımda olan aileme de ayrıca teşekkür ediyorum.

Mayıs, 2002

Selin METİN

İÇİNDEKİLER

KISALTMALAR	v
TABLO LİSTESİ	vi
ŞEKİL LİSTESİ	vii
ÖZET	ix
SUMMARY	xii
1. GİRİŞ	1
1.1 Amaç	1
1.2 Kapsam	2
1.2.1 Kalıpların Elde Edilmesi	2
1.2.2 Filtreleme	3
1.2.3 QRS Komplekslerinin Algılanması ve Özniteliklerin Elde Edilmesi	3
1.2.4 Sınıflama İşlemi	4
1.2.4.1 Sınıflayıcı Olarak Yapay Sinir Ağları	4
1.2.4.2 GAL Ağı	4
1.3 EKG İşaretinin Analizi İçin Kullanılan Yöntemler	4
2. KALBİN ELEKTROFİZYOLOJİSİ	9
2.1 Kalbin Elektriksel İletim Sistemi	9
2.2 Elektrokardiyogram	12
2.2.1 EKG İşaretinde Gözlenen Dalga Şekilleri	13
2.2.1.1 P Dalgası	14
2.2.1.2 PR Aralığı	14
2.2.1.3 QRS Kompleksi	14
2.2.1.4 ST Segmenti	15
2.2.1.5 T Dalgası	16
2.2.1.6 U Dalgası	16
2.2.1.7 QR Aralığı	16
2.3 Derivasyonlar	16
2.3.1 Kalp Vektörü	20
2.4 EKG Vuruları	20
2.4.1 Normal Vuru	21
2.4.2 Erken Karıncık Kasılması	21
2.4.3 Sol Dal Blok Vurusu	22
2.4.4 Sağ Dal Blok Vurusu	23
2.4.5 Anormal Erken Kulakçık Kasılması	23
2.4.6 Yapay Vuru	24
2.4.7 Yapay ve Normal Vuru Birleşimi	25
2.4.8 Karıncık ve Normal Vuru Birleşimi	25
2.4.9 Karıncık Kaçak Vurusu	26

3. SINIFLAMA KURALLARI	27
3.1 Sınıflama Kriterleri	27
3.2 Karar Fonksiyonu	28
3.2.1 Karar Fonksiyonunun Performans Kriterleri	30
3.3 Özniteliklerin Seçilmesi	31
3.3.1 Öznitelik Uzayında Sınıfların Gösterilmesi	33
3.4 Sınıflama Sonucunun Değerlendirilmesi	34
3.5 Dalga Formu Deteksiyonu	35
3.5.1 Kalıp Uydurma Yöntemi	36
3.5.1.1 Basit Kalıp Uydurma Yöntemi	36
3.5.1.2 Düzey Sınırlaması Yöntemi	37
3.5.2 Yapısal Öznitelik Arama	38
3.6 Yapay Sinir Ağlarının Sınıflayıcı Olarak Kullanımı	39
4. YAPAY SİNİR AĞLARI	40
4.1 Yapay Sinir Ağının Tanımı	40
4.2 YSA Mimarileri	43
4.3 Yapay Sinir Ağlarında Öğrenme	44
4.3.1 Eğitici Öğrenme	44
4.3.1.1 Geri Yayılım Algoritması	45
4.3.2 Eğitici Öğrenme	45
4.4 Denetimli Yapay Sinir Ağları	46
4.4.1 Çok Katmanlı Algılayıcı	46
4.4.2 Radyal Taban Fonksiyonlu (RTF) Ağlar	47
4.4.3 GAL Ağı	48
4.4.3.1 GAL Ağının Öğrenme Fazı	50
4.4.3.2 GAL Ağının Unutma Fazı	51
4.4.3.3 GAL Ağının Olumlu ve Olumsuz Yanları	52
4.5 Denetimsiz Yapay Sinir Ağları	52
4.5.1 Kohonen Ağı	52
4.6 Yapay Sinir Ağlarında Bellek	53
4.6.1 Bilginin Gösterimi	54
4.7 Hata Toleransı	54
4.8 YSA Kullanımının Sebepleri	54
4.9 Yapay Sinir Ağlarının Klasik Yazılımlar ile Karşılaştırılması	55
4.10 Biyolojik İşaretlerin YSA'lar ile Algılanması ve Sınıflandırılması	56
5. ARİTMİ SINIFLAMA YÖNTEMİ	57
5.1 MIT-BIH Veri Tabanı	57
5.2 Yöntem	57
5.2.1 Kalıp Elde Etme	58
5.2.2 Filtreleme	58
5.2.3 QRS Deteksiyonu	60
5.2.4 Sınıflama İşlemi	61
5.3 GAL Ağının Sınıflama Sonuçları	62
5.3.1 Örnek Öznitelik Uzayı	62
5.3.1.1 Örnek Öznitelik Uzayının Sınıflama Sonuçları	63
5.3.2 EKG Vuruları	66

6. SONUÇLAR	69
KAYNAKLAR	72
EK A	75
EK B	78
EK C	84
ÖZGEÇMİŞ	86

KISALTMALAR

a	: Anormal kulakçık erken vurusu
AV	: Atriyo-ventriküler düğüm
BP	: Back propagation (geri yayılım)
ÇKA	: Çok katmanlı algılayıcı
E	: Karıncık kaçak vurusu
EEG	: Elektroensefalogram
EKG	: Elektrokardiyogram
f	: Yapay ve normal vuru birleşimi
F	: Karıncık ve normal vuru birleşimi
FN	: False negative (sahte negatif)
FP	: False positive (sahte pozitif)
GAL	: Grow and learn (büyü ve öğren ağı)
j	: Junctional escape beat (düğümsel kaçış vurusu)
J	: Junctional premature beat (düğümsel erken vuru)
L	: Sol dal blok vurusu
MIT-BIH	: Massachusetts Institute of Technology - Beth Israel Hospital
N	: Normal vuru
OR	: Lojik 'veya' işlemi
P	: Yapay vuru
PAC	: Premature atrial contraction (A, erken kulakçık kasılması)
PVC	: Premature ventricular contraction (V, erken karıncık kasılması)
Q	: Sınıflandırılmayan vuru; EKG'deki Q dalgası
R	: Sağ dal blok vurusu; EKG'deki R dalgası
RTF	: Radyal tabanlı fonksiyon
SA	: Sino-atriyal düğüm
SOM	: Self organizing map (öz-düzenleyen harita)
TN	: True negative (doğru negatif)
TP	: True positive (doğru pozitif)
V	: Erken karıncık kasılması
YSA	: Yapay sinir ağı

TABLO LİSTESİ

	<u>Sayfa No</u>
Tablo 2.1 : EKG işareti için bazı tipik değerler.....	13
Tablo 3.1 : Sınıflayıcı karar matrisi.....	35
Tablo 4.1 : Yapay sinir ağları ile Von Neumann makinasının karşılaştırılması	55
Tablo 5.1 : GAL ağının örnek giriş uzayını sınıflama sonuçları.....	65
Tablo 5.2 : GAL ağının EKG vurularını sınıflama sonuçları.....	66
Tablo 6.1 a) : Normal sınıflama sonucu (QRS deteksiyonu ile)	70
Tablo 6.1 b) : İndirgeme yönteminin sonucu (QRS deteksiyonu ile)	71
Tablo 6.1 c) : Normal sınıflama sonucu (orijinal QRS yerleri ile).....	71
Tablo 6.1 d) : İndirgeme yönteminin sonucu(orijinal QRS yerleri ile).....	71
Tablo B.1-25 : GAL ağının çeşitli EKG kayıtlarını sınıflama sonuçları	78

ŞEKİL LİSTESİ

	<u>Sayfa No</u>
Şekil 2.1	: Kalbin elektriksel iletim sistemi 9
Şekil 2.2	: Kalbin uyarı iletimi 10
Şekil 2.3	: Aksiyon potansiyelleri ve EKG 11
Şekil 2.4	: EKG işaretinde gözlenen dalga şekilleri 12
Şekil 2.5	: Çeşitli EKG parametreleri 13
Şekil 2.6	: PR aralığı 15
Şekil 2.7	: Derivasyonların vektörel gösterimi 17
Şekil 2.8	: Çevre derivasyonları 18
Şekil 2.9	: Goldberger'in unipolar çevre derivasyonları 18
Şekil 2.10	: Kalp vektörünün değişimi 20
Şekil 2.11	: Normal EKG vurusu içeren kayıt (N tipi EKG vurusu) 21
Şekil 2.12	: Erken karıncık kasılması içeren EKG kaydı (V tipi EKG vurusu) 22
Şekil 2.13	: Sol dal blok vurusu içeren EKG kaydı (L tipi EKG kaydı) 23
Şekil 2.14	: Sağ dal blok vurusu içeren EKG kaydı (R tipi EKG vurusu) 23
Şekil 2.15	: Anormal kulakçık erken vurusu içeren EKG kaydı (a tipi EKG vurusu) 24
Şekil 2.16	: Yapay vuru içeren EKG kaydı (P tipi EKG vurusu) 25
Şekil 2.17	: Yapay ve normal vuru birleşimi içeren EKG kaydı (f tipi EKG vurusu) .. 25
Şekil 2.18	: Karıncık ve normal vuru birleşimi içeren EKG kaydı (F tipi EKG vurusu) 26
Şekil 2.19	: Karıncık kaçak vurusu içeren EKG kaydı (E tipi EKG vurusu) 26
Şekil 3.1	: Sınıflamanın genel blok diyagramı 27
Şekil 3.2	: Sınıf sınır yüzeylerinin ayrılması 29
Şekil 3.3	: Sınıflayıcının genel yapısı 29
Şekil 3.4	: Sınıflama aşamaları 30
Şekil 3.5	: Parametrelerin eğitimle değişimi 31
Şekil 3.6	: Optimum sınıf dağılımı 32
Şekil 3.7	: Öznitelik uzayında sınıf kümeleri 34
Şekil 3.8	: İşaret ve dalga formu 36
Şekil 3.9	: QRS detektörü için basit kalıp uydurma şekli 37
Şekil 3.10	: QRS detektörü için düzey sınırlaması örneği 37
Şekil 4.1	: Bir nöronun nonlineer modeli 40
Şekil 4.2	: En sık kullanılan transfer fonksiyonları a) eşik fonksiyonu b) parçalı doğrusal fonksiyon c) sigmoid fonksiyon 42
Şekil 4.3	: Bir nöron modelinin işaret akış diyagramı 43
Şekil 4.4	: Eğitici öğrenme 45
Şekil 4.5	: Çok katmanlı algılayıcının yapısı 46
Şekil 4.6	: RTF ağı 48
Şekil 4.7	: Artma yöntemini kullanan öğrenme algoritmaları 49
Şekil 4.8	: GAL ağı yapısı 50

Şekil 4.9	: Daha önce saklanmış olan A düğümü, C'ye daha yakın olan B düğümünün ortaya çıkmasıyla gereksiz hale gelir	51
Şekil 4.10	: SOM algoritmasının nöronları uyarması.....	53
Şekil 5.1.a	: 60 Hz filtre frekans domenini	59
Şekil 5.1.b	: 60 Hz filtre z-domeni	59
Şekil 5.2	: Örnek giriş uzayı	63
Şekil 5.3.a	: İki sınıflı örnek uzay	64
Şekil 5.3.b	: Eğitim ve test kümeleri	64
Şekil 5.3.c	: Unutmadan önceki düğümler	64
Şekil 5.3.d	: Unutmadan sonraki düğümler	65
Şekil 5.3.e	: Sınıflama sonucu	65
Şekil A.1	: N tipi vuru kalıbı	75
Şekil A.2	: V tipi vuru kalıbı	75
Şekil A.3	: L tipi vuru kalıbı	75
Şekil A.4	: R tipi vuru kalıbı	76
Şekil A.5	: a tipi vuru kalıbı	76
Şekil A.6	: P tipi vuru kalıbı.....	76
Şekil A.7	: f tipi vuru kalıbı.....	77
Şekil A.8	: F tipi vuru kalıbı.....	77
Şekil A.9	: E tipi vuru kalıbı	77
Şekil C.1.a	: GAL ağının eğitim algoritması	84
Şekil C.1.b	: GAL ağının unutma algoritması	85

ELEKTROKARDİYOGRAM VURULARININ GAL AĞI YARDIMIYLA SINIFLANDIRILMASI

ÖZET

Kalp hastalıklarının tanı ve tedavisinde EKG (elektrokardiyogram) kayıtlarının hızlı ve doğru yorumlanması çok önemlidir. Ancak bu, uzun süreli EKG kayıtlarının incelenmesini gerektirir. Analiz için harcanan süreden ve insan emeğinden tasarruf etmek, saklanan bilgi miktarını azaltmak ve EKG vurularını çeşitli hastalıklar hakkında ön bilgi içeren sınıflara ayırmak için bilgisayar destekli otomatik analiz sistemleri kullanılır.

Otomatik analiz yöntemini iyileştirmek için incelenen sınıf sayısı artırılmalıdır. Ancak sınıf sayısının artması, sınıflayıcının sınıfları birbirinden ayırabilme performansını olumsuz etkilemektedir. Ayrıca veri boyutunu indirmek için yapılan öznitelik çıkartma ve dönüşüm işlemleri ek hesaplama maliyeti getirmektedir.

Tez çalışması içinde veriyi ön işleme sokmadan doğrudan sınıflayıcıya giriş olarak kabul eden bir algoritma geliştirilmiştir. Sınıflayıcı olarak GAL (grow and learn) ağı kullanılmıştır.

Çalışmada EKG vuruları 1'i normal, 8'i anormal olmak üzere 9 sınıfa ayrılmıştır: Normal vuru (N), erken karıncık kasılması (V), sol dal blok vurusu (L), sağ dal blok vurusu (R), anormal erken kulakçık kasılması (a), yapay vuru (P), yapay ve normal vuru birleşimi (f), karıncık ve normal vuru birleşimi (F), karıncık kaçak vurusu (E)'dur.

EKG vurularının incelenmesinde dalga formu deteksiyonu ve kalıp uydurma yöntemleri kullanılmıştır. Analiz aşamasında sırasıyla şu adımlar uygulanmıştır: 1) Kalıpların elde edilmesi, 2) Filtreleme, 3) QRS komplekslerinin algılanması ve özniteliklerin elde edilmesi, 4) Sınıflama işlemi.

Kalıpların Elde Edilmesi

EKG vurularının incelenmesinde her vuru tipi için ayrı kalıplar elde edilmiş ve bunlar incelenecek EKG kaydındaki QRS kompleksleriyle karşılaştırılmıştır. Kalıp alınacak EKG kaydında önce R tepesi belirlenmiş ve bunun etrafında 50 örneklik bir pencere seçilerek bu 50 örneğin genlik değerleri doğrudan öznitelik vektörlerini oluşturmada kullanılmıştır. İncelenen her vuru tipi için değişik EKG kayıtlarından 10'ar adet kalıp alınmıştır. Her kalıp R tepesinin genliğine göre normalize edilmiştir. Taban hattını ayarlamak için işaretin ortalaması alınarak işaretin kendisinden çıkarılmıştır. Bu yöntem, hesap yükünü hafifletmiştir. Bu şekilde elde edilen kalıpların hastanın yaşına, cinsiyetine, fizyolojisine ve ölçüm sistemine bağımlılığı

ortadan kaldırılmaya çalışılmıştır. Öznitelik vektörleri yalnızca EKG şekil bilgisinden etkilenir hale getirilmiştir.

Filtreleme

EKG işaretinde bulunabilecek 60 Hz'lik şebeke gürültüsünü ve DC bileşenleri filtrelemek için sayısal filtreleme işlemi uygulanmıştır. Taban hattına göre negatif yönde kalan işaret bileşenlerini de hesaplamalarda kullanabilmek için filtrelenmiş işaretin karesi alınmıştır. Taban hattını elde etmek amacıyla orijinal işaretin ortalaması alınarak kendisinden çıkarılmıştır.

QRS Komplekslerinin Algılanması ve Özniteliklerin Elde Edilmesi

QRS deteksiyonu için önce R tepeleri elde edilmiştir. Bu nedenle filtrelenmiş işarete bir eşik uygulanmış ve eşiği geçen örnekler üzerinde işlem yapılmıştır. Eşiği geçen ilk örneğin yeri bir listede saklanmış ve bundan sonraki 80 örnek boyunca göz kapama işlemi uygulanmıştır.

Sonraki aşamada eşiği geçen ilk örnekten önceki 50 ve sonraki 50 örnekten oluşan 100 örneklilik dizi incelenir. Eğer eşiği geçen ilk örnekten önceki 10 ve sonraki 10 örnekten oluşan dizinin ortalaması pozitif ise 100 örneklilik dizinin maksimum genliğe sahip elemanı R tepesini verir. Aksi halde 100 örneklilik dizinin minimum genliğe sahip elemanı R tepesidir. Bu işlem sayesinde çeşitli EKG aritmilerinde ortaya çıkan ters dönmüş R dalgaları da detekte edilebilmektedir.

Bu şekilde bulunan R tepesinin etrafında 50 örneklilik bir pencere alınarak bu örneklerin genlik değerleri doğrudan öznitelikler olarak elde edilmiştir. Öznitelik vektörlerinin ortalaması alınarak kendisinden çıkarılmış ve taban hattı düzeyinden kaynaklanabilecek genlik değişimi yok edilmiştir. Daha sonra her 50 örneklilik dizi R tepesine göre normalize edilmiştir. Öznitelik vektörlerinden oluşan QRS kompleksi dizileri sınıflama aşamasında kalıp vektörleriyle karşılaştırılmak üzere saklanmıştır.

Sınıflama İşlemi

Elde edilen QRS kompleksi dizileri GAL ağının eğitimi sonucu bulunan ağırlık matrisinin satırları ile karşılaştırılır. Ağırlık matrisinin satırları, kalıp vektörlerinden oluşmaktadır. Ağırlık matrisinin her satırının ilk 50 elemanı ağın bir düğümünü, 51. elemanı ise bu düğümün sınıfını göstermektedir. Karşılaştırma sonucu minimum mesafedeki ağ düğümünün sınıfı QRS kompleksinin sınıfı olarak atanır. Karşılaştırma ölçütü olarak öklid normu kullanılmıştır.

Sınıflayıcı Olarak Yapay Sinir Ağları

Yapay sinir ağları; öğrenebilme ve bilgiyi saklama yetenekleri, rasgele durumlara uyarlanabilmeleri ve hata toleransı gösterebilmeleri nedeniyle biyolojik işaretlerin sınıflandırılması için uygun yapılardır.

Çalışmada GAL ağı kullanılarak EKG vuruları analiz edilmeye çalışılmıştır. GAL ağının sınıf sınırlarını temsil edebilme yeteneğini ve genel çalışmasını test etmek amacıyla yapay olarak oluşturulmuş iki boyutlu bir örnek uzay kullanılmıştır. Böylece sözü edilen niteliklerin görsel olarak incelenebilmesi mümkün olmuştur.

GAL Ağı

GAL ağı, düğümleri sınıf sınırlarını temsil edecek şekilde dağıtmaktadır. Her bir düğüm, sınıf sınırlarıyla ilgili yalnızca bir ayrıntıyı saklar; yani bütüne ait bilgiyi değil, bütünün parçalarına ait bilgiyi saklar. Eğitim sırasında oluşan ve sınıfları temsil yeteneği diğer düğümlere göre daha zayıf olan düğümler, unutma sırasında ağdan çıkarılmaktadır. Böylece ağın boyutu indirgenmiş ve test işleminin süresi kısaltılmış olmaktadır.

Ağın performansını etkileyen önemli unsurlardan biri QRS komplekslerinin doğru algılanmasıdır. QRS deteksiyon algoritması, kaydın başında çok erken görülen QRS komplekslerini yakalayamamaktadır. Bunun nedeni, filtrelemeden ve yapılan işlemlerden kaynaklanan gecikme, göz kapama süresi ve kalıp uzunluğudur. Karşılaştırmada kullanılacak kalıpların vuru tiplerini iyi temsil edecek şekilde seçilmesi ve sayılarının çokluğu, ağın doğru sınıflama performansını artırmaktadır. Ancak kalıp sayısının fazla olması; yapılan karşılaştırma sayısını, dolayısıyla ağın eğitim ve sınıflama sürelerini artırmaktadır.

Çalışmada MIT-BIH veri tabanındaki EKG kayıtlarından yararlanılmıştır. 30 dakikalık kayıtlar 10'ar dakikalık bölümler halinde incelenmiştir. Kayıtların çoğu için %90'ın üzerinde başarımlar ve sınıflama duyarlılığı elde edilmiştir. Kullanılan algoritmalar MATLAB ile PIII 800 MHz işlemcili 128 MB RAM içeren bir PC üzerinde geliştirilmiştir.

CLASSIFICATION OF ELECTROCARDIOGRAM BEATS USING GAL NETWORK

SUMMARY

Fast and correct interpretation of ECG (electrocardiogram) data is very important for the diagnosis and cure of cardiac illnesses. However, this requires long term ECG records to be analyzed. To save time and human work, to reduce the amount of knowledge to be stored, and to classify the ECG data into classes that include pre-knowledge about illnesses, computer aided automatic analysis systems are used.

The number of classes to be analyzed must be increased to improve the automatic analysis method. However, as the number of classes increases, performance of the class separation decreases. Feature extraction and transform processes that are used to reduce the amount of data to be analyzed bring additional calculation cost.

In this thesis an algorithm is developed which, without any pre-processing, directly accepts the data as input for the classifier. GAL network is used as classifier.

In this study, ECG beats are classified into 9 categories: Normal beat (N), premature ventricular contraction (V), left bundle branch block (L), right bundle branch block (R), aberrated atrial premature beat (a), paced beat (P), fusion of paced and normal beat (f), fusion of ventricular and normal beat (F), ventricular escape beat (E).

Waveform detection and template matching methods are used in analysis of ECG beats. Analysis is performed according to the following steps respectively: 1) Obtaining the templates, 2) Filtering, 3) Detection of the QRS complexes from beats and feature extraction, 4) Classification process.

Obtaining the Templates

Different templates are obtained for each ECG beat class and these are compared with the QRS complexes in the ECG record to be analyzed. First R peak is defined in the ECG record from which the template is to be taken and a window of 50 samples is selected around the R peak. The amplitude values of these 50 samples are directly used to form the feature vectors. 10 templates are taken from different ECG records for each beat class. Each template is normalized according to the R peak amplitude. To adjust the isoelectric level mean value of the ECG signal is subtracted from the original signal. This method improves the cost of calculation. The dependance of the templates to patient's age, sexuality, physiology and to the measurement system is decreased by this method. Feature vectors are affected only from morphologic changes.

Filtering

To filter the 60 Hz noise and DC components in the ECG signal digital filtering is used. To be able to use the signal components which are in the negative direction according to the isoelectric level square of the filtered signal is taken. Mean value of the original signal is subtracted from itself to obtain the isoelectric level amplitude.

Detection of the QRS Complexes and Feature Extraction

R peaks are found first to detect QRS. Thus a threshold is applied to the filtered signal and only those samples that are above the threshold are taken into account. The position of the first sample which is above the threshold is stored in a list and during the following 80 samples no operation is done.

In the next stage a 100-sample array, which is formed by taking 50 samples before and after the first sample above the threshold, is analyzed. If the mean value of the array formed by taking 10 samples before and after the first sample above the threshold is positive, then the sample with the maximum amplitude in the 100 sample array is the R peak. Otherwise the sample with the minimum amplitude is the R peak. Using this method upside down R waves which occur in some of the ECG arrhythmias can be detected.

A 50-sample window around the R peak is taken and the amplitude values of these samples are taken as feature vectors. Mean values of the feature vectors are subtracted from the feature vectors and any probable amplitude change caused by isoelectric level is prevented. Then every 50 sample array is normalized according to the R peak amplitude. QRS complex arrays of feature vectors are stored to be compared with the template vectors.

Classification Process

QRS complex arrays are compared with the rows of the weight matrix obtained by the learning phase of the GAL network. Each row of the weight matrix is a template vector. The first 50 elements of each row of the weight matrix forms a node of the network, and the 51st element is the label of this node. The label of the network node, which has the minimum distance from the input vector, is appointed as the class of the QRS complex. Euclidean distance is used as comparison metric.

Neural Networks as Classifiers

Neural networks, with their learning and knowledge storing abilities, adaptation ability to random processes and error tolerances, are suitable structures for the classification of biological signals.

In this study ECG beats are analyzed using GAL network. To test the separation ability and general operation of the GAL network a two dimensional sample feature space is used. Thus a visual analysis of the mentioned qualities is made possible.

GAL Network

GAL network distributes the nodes so as to be able to represent the class borders. Each node stores only one detail about the class borders; that means the knowledge belonging to the pieces of the whole body is stored instead of storing the whole body. Nodes, whose ability to represent the classes is weaker than the others, are removed from the network during sleep stage. Thus the dimension of the network is reduced and time needed for test process is shortened.

One of the important factors affecting the network performance is the true detection of QRS complexes. QRS detection algorithm fails to detect the QRS complexes which occur very early at the beginning of the record. The reason for this is the latency occurring from the filtering, eye shutting period and the length of the templates. Choosing the templates, which correctly represent the beat types and having a large number of templates positively affects the network performance. However, the excess number of templates increases the number of the comparisons to be made, thus increasing the time needed for classification.

ECG records from the MIT-BIH database are used in this study. The 30 minute records are analyzed in 10 minute periods. The performance of the network for many of the records is above 90%. The algorithms are developed on a PC platform with PIII 800 MHz processor and 128 MB RAM using MATLAB.

1. GİRİŞ

1.1 Amaç

İnsan ölümlerinin önemli bir bölümünü kalp rahatsızlıkları oluşturmaktadır. Bu nedenle kalbin aktivitesine dair bilgilerin hastaya zarar vermeden, güvenilir bir biçimde elde edilmesi ve değerlendirilmesi büyük önem taşımaktadır. İnsan vücudu üzerinden kolaylıkla algılanabilen ve kalbin elektriksel aktivitesi hakkında bilgi veren işaretlere elektrokardiyogram (EKG) adı verilir. EKG işaretlerinin işlenmesi ve yorumlanması, kalp rahatsızlıklarının tanı ve tedavi aşamalarında büyük öneme sahiptir.

Doğru tanı konulabilmesi için hastanın kalp aktivitesinin uzun bir dönem boyunca izlenmesi gerekmektedir. Bu durum, uzun süreli ve büyük dosya boyutuna sahip EKG kayıtlarının saklanması gerektirmektedir. Bu kayıtların incelenmesi, özellikle zaman açısından yüksek maliyetli bir iştir. Bu nedenle hızlı ve otomatik EKG analizi yapabilen sistemlere ihtiyaç duyulmaktadır. Bu amaçla bilgisayar destekli analiz yöntemleri kullanılmaktadır.

EKG kayıtlarının bilgisayar destekli analizi iki şekilde gerçekleştirilebilir. 1) Gerçek zamanlı veriler incelenir ve önemli vurularda alarm verilerek kayıt işlemi başlatılır. Bu yöntemle yalnızca belirli dönemlere ilişkin kayıtlar saklandığından depolama alanı açısından tasarruf edilmiş olunur. 2) Tüm EKG işaretleri analiz uygulanmadan gerçek zamanlı olarak kaydedilir. Daha sonra bu kayıtlar bilgisayar yardımıyla incelenir ve vuru tipleri işaretlenir.

EKG işaretlerinin işlenmesindeki amaç, önemli verilerin gürültü veya gereksiz verilerden ayrılarak sınıflamaya uygun biçimde saklanmasıdır. Analiz sisteminin kullanılmasıyla yüksek başarımla mümkün olduğunca çok sınıf ayırt edilebilmelidir. Sınıf sayısını artırmak, öznelilik çıkarma işleminin performansına ve

sınıflayıcının genelleme yeteneğine bağlıdır. Bununla birlikte sınıf sayısının yüksek olması, genellikle yanlış sınıflama oranının artmasına yol açmaktadır.

Bu çalışmanın amacı, işaret işleme açısından düşük maliyetli ve yüksek sınıflama performansına sahip bir sınıflayıcı yapısı geliştirmektir. Sınıf sayısı ve saklanacak veri boyutu açısından en verimli yöntem araştırılmış ve başarıyı yüksek bir ağ yapısı tasarlanmaya çalışılmıştır.

1.2 Kapsam

Sınıflayıcı olarak yapay sinir ağı kullanılmış ve GAL ağı uygun ağ yapısı olarak seçilmiştir. GAL ağının gerçekleşmesinin basit olması ve dinamik yapısı sayesinde düğüm sayısının ihtiyaca göre belirlenmesi, tercih edilme nedenleridir.

EKG vurularının incelenmesinde dalga formu deteksiyonu ve kalıp uydurma yöntemleri kullanılmıştır. Sırasıyla şu adımlar uygulanmıştır: 1) Kalıpların elde edilmesi, 2) Filtreleme, 3) QRS komplekslerinin algılanması ve özniteliklerin elde edilmesi, 4) Sınıflama işlemi.

1.2.1 Kalıpların Elde Edilmesi

EKG vurularının incelenmesinde her vuru tipi için kalıplar elde edilmiş ve bunlar incelenecek EKG kaydındaki QRS kompleksleriyle karşılaştırılmıştır. Kalıp alınacak EKG kaydında önce R tepesi belirlenmiş ve bunun etrafında 50 örneklik bir pencere seçilerek bu 50 örneğin genlik değerleri doğrudan öznitelik vektörlerini oluşturmada kullanılmıştır. İncelenen her vuru tipi için değişik EKG kayıtlarından 10'ar adet kalıp alınmıştır.

Farklı hastalardan alınan aynı tip EKG kayıtlarında, hatta aynı hastanın değişik anlardaki EKG kayıtlarında bile önemli genlik değişimleri gözlenmektedir. Kalıpların standart olarak kullanılabilmesi için her kalıp R tepesinin genliğine göre normalize edilmiştir. Ayrıca taban hattını ayarlamak için işaretin ortalaması alınarak işaretin kendisinden çıkarılmıştır. Bu yöntem, hesap yükünü hafifletmiştir. Bu şekilde elde edilen kalıpların hastanın yaşına, cinsiyetine, fizyolojisine ve ölçüm

sistemine bağımlılığı ortadan kaldırılmaya çalışılmıştır. Öznitelik vektörleri yalnızca EKG şekil bilgisinden etkilenir hale getirilmiştir.

1.2.2 Filtreleme

EKG işaretinde bulunabilecek 60 Hz'lik şebeke gürültüsünü ve DC bileşenleri filtrelemek için sayısal filtreleme işlemi uygulanmıştır.

Taban hattına göre negatif yönde kalan işaret bileşenlerini de hesaplamalarda kullanabilmek için filtrelenmiş işaretin karesi alınmıştır. Taban hattını elde etmek amacıyla orijinal işaretin ortalaması alınarak kendisinden çıkarılmıştır.

1.2.3 QRS Komplekslerinin Algılanması ve Özniteliklerin Elde Edilmesi

QRS deteksiyonu için önce R tepeleri elde edilmiştir. Bu nedenle filtrelenmiş işarete bir eşik uygulanmış ve eşiği geçen örnekler üzerinde işlem yapılmıştır. Eşiği geçen ilk örneğin yeri bir listede saklanmış ve bundan sonraki 80 örnek boyunca göz kapama işlemi uygulanmıştır.

Sonraki aşamada eşiği geçen ilk örnekten önceki 50 ve sonraki 50 örnekten oluşan 100 örneklilik dizi incelenir. Eğer eşiği geçen ilk örnekten önceki 10 ve sonraki 10 örnekten oluşan dizinin ortalaması pozitif ise 100 örneklilik dizinin maksimum genliğe sahip elemanı R tepesini verir. Aksi halde 100 örneklilik dizinin minimum genliğe sahip elemanı R tepesidir. Bu işlem sayesinde çeşitli EKG aritmilerinde ortaya çıkan ters dönmüş R dalgaları da detekte edilebilmektedir.

Bu şekilde bulunan R tepesinin etrafında 50 örneklilik bir pencere alınarak bu örneklerin genlik değerleri doğrudan öznitelikler olarak elde edilmiştir. Öznitelik vektörlerinin ortalaması alınarak kendisinden çıkarılmış ve taban hattı düzeyinden kaynaklanabilecek genlik değişimi yok edilmiştir. Daha sonra her 50 örneklilik dizi R tepesine göre normalize edilmiştir. Öznitelik vektörlerinden oluşan QRS kompleksi dizileri sınıflama aşamasında kalıp vektörleriyle karşılaştırılmak üzere saklanmıştır.

1.2.4 Sınıflama İşlemi

Elde edilen QRS kompleksi dizileri GAL ağının eğitimi sonucu bulunan ağırlık matrisinin satırları ile karşılaştırılır. Ağırlık matrisinin satırları kalıp vektörlerinden

oluşmaktadır. Ağırlık matrisinin her satırının ilk 50 elemanı ağın bir düğümünü, 51. elemanı ise bu düğümün sınıfını göstermektedir. Karşılaştırma sonucu minimum mesafedeki ağ düğümünün sınıfı QRS kompleksinin sınıfı olarak atanır. Karşılaştırma ölçütü olarak öklid normu kullanılmıştır.

1.2.4.1 Sınıflayıcı Olarak Yapay Sinir Ağları

Biyolojik işaretler, rasgele süreçlere göre gerçekleşir. Ancak insan vücudundan algılanan işaretlerin sınıflandırılması mümkündür. Yapay sinir ağları; öğrenebilme ve bilgiyi saklama yetenekleri, rasgele durumlara uyarlanabilmeleri ve hata toleransı gösterebilmeleri nedeniyle biyolojik işaretlerin sınıflandırılması için uygun yapılardır.

Çalışmada GAL ağı kullanılarak EKG vuruları analiz edilmeye çalışılmıştır. GAL ağının sınıf sınırlarını temsil edebilme yeteneğini ve genel çalışmasını test etmek amacıyla yapay olarak oluşturulmuş iki boyutlu bir örnek uzay kullanılmıştır. Böylece sözü edilen niteliklerin görsel olarak incelenebilmesi mümkün olmuştur.

1.2.4.2 GAL Ağı

GAL ağı, düğümleri sınıf sınırlarını temsil edecek şekilde dağıtmaktadır. Her bir düğüm, sınıf sınırlarıyla ilgili yalnızca bir ayrıntıyı saklar; yani bütüne ait bilgiyi değil, bütünün parçalarına ait bilgiyi saklar. Eğitim sırasında oluşan ve sınıfları temsil yeteneği diğer düğümlere göre daha zayıf olan düğümler, unutma sırasında ağdan çıkarılmaktadır. Böylece ağın boyutu indirgenmiş ve test işleminin süresi kısaltılmış olmaktadır.

1.3 EKG İşaretinin Analizi İçin Kullanılan Yöntemler

Literatürde EKG işaretine ait özniteliklerin çıkartılması, EKG işaretinin analizi ve vuruların sınıflandırılmasına ilişkin yer alan yöntemlerden bazıları aşağıda verilmiştir.

Rosario Silipo ve arkadaşının gerçekleştirdiği çalışmada 7 tip EKG vurusu %65 başarımla sınıflanmıştır [1]: Normal vuru, sol, sağ ve bilateral karıncık hipertrofileri, anterior, inferior ve karışık miyokardiyal enfarktüsler. Sınıflayıcı olarak hibrit yapıda

ve normalize radyal tabanlı fonksiyonlar kullanan bir yapay sinir ağı kullanılmıştır. Ayrıca öz ilişkilendirici yapısında bir yapay sinir ağı aritmi deteksiyonunda ve yinelemeli bir ağ yapısı da iskemi analizinde kullanılmıştır. Çalışmada MIT-BIH ve Avrupa ST-T veri tabanları kullanılmıştır.

Douglas Coast ve arkadaşlarının gerçekleştirdiği çalışmada saklı markov modelleri kullanılarak EKG işaretinin istatistiksel ve yapısal bilgileri tek bir modelde birleştirilmiştir [2]. EKG dalga şekillerinin sınıflandırılmasında QRS kompleksi için %99, QRS+P dalgaları için ise %80.85 oranında duyarlılık değerleri elde edilmiştir.

Telemachos Stamkopoulos ve arkadaşlarının çalışmasında eğitici modda çalışan YSA tabanlı bir algoritma EKG işaretinden iskemik bölümleri ayırt etmek için kullanılmıştır [3]. Her vurudan sadece ST segmentini içeren bölümler bulunmuş ve buradan 20 örnek alınarak öznitelik vektörleri bulunmuştur. %84.4 oranında duyarlılık elde edilmiştir. Avrupa ST-T veri tabanından yararlanılmıştır.

John Frenster'in gerçekleştirdiği çalışmada 6 farklı YSA yapısı 6 organ sistemi üzerinde hastalık tanısı koymak üzere test edilmiş ve %95 oranında doğruluk değerleri elde edilmiştir [4]. İki tür giriş örüntüsü analiz edilmiştir.

Rosario Silipo ve arkadaşlarının gerçekleştirdiği çalışmada 3 katmanlı ileri beslemeli bir geri yayılım algoritmasıyla eğitilmiş bir yapay sinir ağı ile ST segmentleri analiz edilmiştir [5]. %80 oranında duyarlılık ve %90 oranında pozitif tahminsel kesinlik değerleri elde edilmiştir.

Giovanni Bortolan ve arkadaşlarının gerçekleştirdiği çalışmada öbekleşme analizi ve yapay sinir ağları EKG sınıflandırılması amacıyla birleştirilmiştir [6]. Farklı ağlardan elde edilen sonuçlar birleştirilerek 6 tür EKG vurusu (sol, sağ ve bilateral karıncık hipertrofileri, anterior, inferior ve karışık miyokardiyal enfarktüsler) sınıflanmıştır. Ortalama 67.8 oranında başarımlar elde edilmiş ve YSA sayısı arttığında başarımın arttığı gözlenmiştir.

Rosario Silipo ve arkadaşlarının gerçekleştirdiği çalışmada [7], 7 tip EKG vurusu (Normal vuru, sol, sağ ve bilateral karıncık hipertrofileri, anterior, inferior ve karışık miyokardiyal enfarktüsler) incelenmiştir. Öznitelik vektörleri 39 boyutludur.

Kohonen ağı ile %52, RTF içeren hibrit sistem ile %63 oranında duyarlılık elde edilmiştir.

Rosario Silipo ve arkadaşlarının gerçekleştirdiği çalışmada iskemik EKG vurularındaki ST segmenti düzey değişimleri incelenmiştir [8]. Öznitelik çıkarma işleminde Karhunen-Loeve dönüşümü uygulanmıştır. 3 katmanlı ileri beslemeli bir YSA yapısıyla %77 oranında duyarlılık ve %86 oranında pozitif tahminsel doğruluk değerleri elde edilmiştir. Avrupa ST-T veri tabanından yararlanılmıştır.

Douglas Coast'un gerçekleştirdiği çalışmada QRS kompleksi ve bunu çevreleyen izoelektrik bölgeler arasındaki ilişkileri saklı markov modelleri ile temsil eden bir algoritma geliştirilmiştir [9]. Bu algoritmayla QRS başlangıç ve bitiş noktalarının bulunmasında ortalama standart sapma değeri 11'den 2 ms'ye düşürülmüştür.

Maglaveras ve arkadaşlarının çalışmasında iki EKG işleme tekniği geliştirilmiştir [10]. YSA algoritması %100 doğru sınıflama yapmıştır. Çift yönlü ilişkilendirici hafıza algoritması diğer YSA yöntemlerine göre iyi sonuç vermemiştir.

Rosario Silipo ve arkadaşlarının gerçekleştirdiği çalışmada EKG sınıflaması yapmak üzere bulanık mantık kullanan hibrit yapılar geliştirilmiştir [11]. Kullanılan stratejilere göre %90'lar mertebesinde duyarlılık değerleri bulunmuştur.

Telemachos Stamkopoulos ve arkadaşlarının çalışmasında nonlinear ana bileşenlerin analizi tekniği kullanılarak ST segmenti normal ve anormal olmak üzere sınıflandırılmıştır [12]. Kullanılan öznitelik sayısı ikidir. Normal vuruların algılanma duyarlılığı %80, anormal vuruların algılanma duyarlılığı %90 civarında bulunmuştur.

Kei-ichiro Minami ve arkadaşlarının gerçekleştirdiği çalışmada kalp ritminin oluştuğu yere ve izlediği yola bağlı olarak QRS kompleksinde oluşan değişimler Fourier dönüşümü ile incelenmiş ve 3 farklı ritim türü bir YSA ile ayırt edilmiştir [13]. Ventriküler ve supraventriküler aritmilerin ayırt edilmesinde %98 oranında duyarlılık değerleri elde edilmiştir.

G. Vijaya ve arkadaşlarının çalışmasında YSA kullanılarak QRS kompleksi deteksiyonu gerçekleştirilmiştir [14]. Duyarlılık değeri %99.11 olarak bulunmuştur.

T.-F. Yang ve arkadaşlarının çalışmasında supraventriküler ve ventriküler ekstrasistol içeren sinüs ritmini kulakçık çırpıntısından ayırmak için YSA ve deterministik lojik yaklaşımları karşılaştırılmıştır [15]. %92 oranında duyarlılık değeri elde edilmiştir.

Philip de Chazal ve arkadaşının çalışmasında Bayes olasılıklarını saklı katmanı olmayan bir YSA ile modelleyen bir sınıflandırıcı geliştirilmiştir [16]. 7 tip EKG vurusu (normal vuru, sol, sağ ve bilateral karıncık hipertrofileri, anterior, inferior ve karışık miyokardiyal enfarktüsler) %70.9 başarımla sınıflanmıştır. Hastaların yaş-cinsiyet bilgileri, bazı özniteliklerin kendi aralarında oranları, genlik, süre ve alan gibi bazı şekil bilgileri kullanılarak 229 boyutlu öznitelik vektörleri oluşturulmuştur.

Branko G. Celler ve arkadaşının gerçekleştirdiği çalışmada 7 tip EKG vurusunu (normal vuru, sol, sağ ve bilateral karıncık hipertrofileri, anterior, inferior ve karışık miyokardiyal enfarktüsler) sınıflandırmak için birkaç sınıflayıcı yapısı karşılaştırılmıştır [17]. Saklı katman içermeyen bir YSA ile %68.8 başarımla elde edilmiştir. Yaş ve cinsiyet haricindeki tüm öznitelikler yalnızca QRS kompleksinden elde edilmiştir, P ve T dalgaları analize dahil edilmemiştir.

H. Gholam-Hosseini ve arkadaşının çalışmasında 4 farklı EKG vuru tipi sınıflandırılmıştır [18]. Normal ve erken karıncık kasılmasına (PVC) ait vurularda %99'a varan başarımla elde edilmiştir. Seçilen parametreler morfolojik ve istatistiksel öznitelikler olarak ikiye ayrılmıştır. Tüm öznitelikler QRS kompleksi, ST segmenti ve işaretin istatistiksel karakteristiklerinden elde edilmiştir. Morfolojik öznitelik çıkartmanın gürültüye ve hastaya bağımlı olduğu, istatistiksel yöntemlerin daha bağımsız veriler ürettiği bulunmuştur. Çalışmada ortalama ve kovaryans hesabını kullanan sınıflayıcılardan ve MIT-BIH veri tabanından yararlanılmıştır.

Kuo Yonghong ve arkadaşlarının gerçekleştirdiği çalışmada MIT-BIH veri tabanı kullanılarak normal, yapay, füzyon, ve erken karıncık kasılması vuruları açısından EKG vuruları sınıflandırılmıştır [19]. Öznitelik vektörleri doğrudan QRS kompleksinin genlik değerleri olarak alınmıştır. Gürültü etkisini ortadan kaldırmak için herhangi bir ön işlem uygulanmamıştır. ART2 ağı kullanılmıştır.

M. E. Tagluk ve arkadaşının çalışmasında EKG analizi için kernel tabanlı zaman-frekans teknikleri karşılaştırılmıştır [20]. Geliştirilen yöntem Wigner-Ville

dağılımında önemli bir değişime yol açmadan çapraz terimleri bastırmaktadır. Diğer yöntemlere göre tatmin edici sonuçlar bulunduğu söylenmekte ancak bunlara açıklık getirilmemektedir.

Zümray Dokur ve arkadaşlarının çalışmasında EKG'den öznitelik çıkarılması için ayrık wavelet dönüşümü kullanılmıştır [21]. EKG'nin öznitelikleri diverjans değerlerine göre dinamik programlamayla bulunmuştur. Normal, sol ve sağ demet bloğu, yapay vuru, ileilmeyen P dalgası, erken kulakçık vurusu, karıncık kaçak vurusu, erken karıncık vurusu, birleşmiş normal ve karıncık vurusu, birleşmiş normal ve yapay vuru olmak üzere 10 EKG vuru tipi %97 başarımla sınıflandırılmıştır.

Zümray Dokur ve arkadaşlarının gerçekleştirdiği çalışmada QRS kompleksinin R tepesi algılandıktan sonra ayrık Fourier dönüşümü spektrumunun önemli frekans bileşenlerinin genliklerinden öznitelik vektörleri elde edilmiştir [22]. GAL ve Kohonen ağırları 4 farklı EKG dalga şeklinin (normal, sol dal bloğu, PVC, yapay vuru) sınıflandırılması açısından karşılaştırılmıştır. GAL ağırlarının daha az sayıda düğümle daha hızlı öğrendiği ve daha iyi sınıflama yaptığı görülmüştür.

Sanjib Kalita ve arkadaşlarının gerçekleştirdiği çalışmada tek katmanlı ileri beslemeli bir YSA 3 farklı EKG vurusunu (normal sinüs ritmi, erken karıncık kasılması, bastırılmış ST segmenti) sınıflamakta kullanılmıştır [23]. Ana özniteliklerin çıkarılması ve ayrık kosinüs dönüşümü kullanılarak özniteliklerin boyutu indirgenmiştir. %50'nin üzerinde sınıflama duyarlılığı elde edilmiştir.


John Har ve arkadaşlarının çalışmasında EKG verisini sadece ana bileşenlerini içerecek şekilde indirgeyen bir algoritma geliştirilmiştir [24]. Ana özniteliklerin çıkarılması ve ayrık kosinüs dönüşümü yöntemleri karşılaştırılmıştır. EKG'den P, QRS, ST, T gibi sadece çok gerekli öznitelikler alınmıştır. Ana özniteliklerin çıkarılması yönteminin daha hızlı ve basit olduğu bulunmuş ve kullandığı iki karar eşiği değiştirilerek istenen duyarlılığın elde edilebileceği söylenmiştir.

Sandor M. Szilagyi'nin MIT-BIH veri tabanını kullanarak gerçekleştirdiği çalışmada normal ve PVC vuruları SOM algoritmasıyla sınıflandırılmıştır [25]. Öznitelikler EKG'den P, Q, R, S, T noktalarının çıkartılmasıyla elde edilmiştir. QRS kompleksi deteksiyonu %99.8 başarımla gerçekleştirilmiştir ancak sınıflama başarımı düşüktür. Gürültüyü ortadan kaldırmak için FFT ve IFFT dönüşümleri kullanılmıştır.

2. KALBİN ELEKTROFİZYOLOJİSİ

2.1 Kalbin Elektriksel İletim Sistemi

Kalp, birbirini izleyen dönemler boyunca hiç durmadan belirli bir elektrik potansiyel üreten ve bu etkinliğin ardından kasılma olarak da adlandırılan mekanik işi yapan bir organdır. Bu yüzden kalbi bir elektromotor kuvvet kaynağı olarak düşünülebiliriz.




Şekil 2.1 Kalbin elektriksel iletim sistemi

Miyokard (kalp kası), çok sayıda ince uzun hücreden oluşan bir dokudur. Yan uzantılarının yardımıyla kimi yerde birleşen miyokard hücreleri, bir takım diskler aracılığı ile uç uca bağlanarak dizilirler. Miyokardın kasılması için ön koşul, hücre zarının elektriksel anlamda uyarımıdır [26]. Dinlenme durumundaki miyokard hücresinde belirli uyarım tarafından başlatılan elektrokimyasal içerikli etkinliğe aksiyon potansiyeli ya da elektriksel sistol denir. Aksiyon potansiyeli, depolarizasyon ve repolarizasyon aşamalarından oluşur. Hücrenin repolarizasyonu izleyerek başlangıç durumundaki

özelliklerine dönmesi ile dinlenme potansiyeli öbür adı ile elektriksel diyastol gelişimi şekil 2.1’de gösterilmiştir.

Kalbin elektriksel iletim sistemi, sinoatrial düğüm (SA düğümü), his demeti, atriyoventriküler düğüm (AV düğümü), demet kolları ve purkinje liflerinin sol ve sağ dallarından oluşur [27]. Kalp, kulakçık ve karıncıklarıyla, SA düğümü kontrolünde kasılır. SA düğümü, ön, orta ve arka internodal yollar aracılığı ile atriyum - ventrikül (AV) düğümüne bağlanır.




Şekil 2.2 Kalbin uyarı iletimi

SA düğümü, kalbin vuru düzenleyicisi olarak çalışır. Burada oluşan ve frekansı merkezi sinir sistemi tarafından denetlenen aksiyon potansiyeli, depolarizasyon dalgası halinde kulakçıklardaki iletim yolları üzerinde yaklaşık 30 cm/s hızla ilerleyerek kulakçıkların kasılmasını ve kulakçıklarda bulunan kanın karıncıklara dolmasını sağlar. Yetişkinlerde aksiyon potansiyelinin frekansı yaklaşık 70 vuru/dk’dır. SA ve AV düğümleri arasındaki özel iletim yollarında aksiyon potansiyeli 45 cm/s hızla ilerleyerek 30-50 ms sonra AV düğümüne ulaşır. Bu süre, kulakçıklardaki tüm kanın karıncıklara boşalması için yeterli değildir. Bu nedenle

AV düğümü bir geciktirme elemanı gibi çalışarak aksiyon potansiyelini 110 ms kadar geciktirir.

Karıncıkların uyarılması purkinje lifleri aracılığıyla gerçekleşir. Purkinje lifleri üzerinde aksiyon potansiyeli 2-4 m/s hızla ilerleyerek karıncıkların kasılmasına ve içlerindeki kanın arterlere pompalanmasına neden olur.

Kulakçık depolarizasyonunu gerçekleştirerek internodal yollar aracılığı ile AV kavşağına ulaşan uyarı önce AV düğümüne girer. AV düğümünün üst kesiminde yavaşlayan uyarı iletimi, düğümün orta kesiminde en düşük hıza iner ve düğümün alt kesiminde yeniden hızlanmaya başlayarak purkinje ipliklerinde en yüksek değere ulaşır.




Şekil 2.3 Aksiyon potansiyelleri ve EKG

AV düğümü ile kalp kası ve iletim sisteminin diğer kısımları da karıncık kasılmasıyla sonuçlanacak uyarıyı başlatabilirler. SA düğümünden farklı olarak uyarı

başlatan bu merkezlere ektopik merkezler, bu uyarılara da ektopik uyarılar adı verilir. Bu patolojik durumlar, sinüs düğümünden gelen uyarıların iletilememesi veya engellenmesi nedeniyle oluşur. Bu kasılmalar genelde periyodik olmalarına rağmen, ritimleri SA düğümünün ritminden daha düşüktür.

2.2 Elektrokardiyogram

Kalp kaslarının kasılması sonucu oluşan elektriksel işarete elektrokardiyogram (EKG) adı verilir (şekil 2.4).




Şekil 2.4 EKG işaretinde gözlenen dalga şekilleri

EKG vücut üzerinden elektrotlar yardımıyla algılanabilir. EKG üzerinde kalbin izoelektrik seviyesi (taban hattı) üzerinde kalbin aktivitesini gösteren kısımlar harflerle simgelenir. SA düğümü tarafından üretilen doğal uyarı, ön, orta ve arka internodal yollar aracılığı ile önce sağ kulakçığa, ardından kulakçık septumuna ve son olarak sol kulakçığa yayılır. Buna göre sol kulakçığın depolarizasyonu, sağ kulakçığın depolarizasyonundan daha sonra oluşur. Kulakçık depolarizasyonunun (kasılmasının) elektrokardiyogramdaki karşılığı P dalgasıdır. PQ aralığı, his demeti iletim süresini gösterir. QRS kompleksi, karıncıkların depolarizasyonuna karşılıktır; uyarının karıncıklarda yayılma süresini yansıtır. His demeti ve kollarındaki iletim bozuklukları da QRS dalgasında değişime neden olur. Karıncıkların kasılmasıyla R dalgasının yukarı çıkışı aynı anda olur. ST aralığında kulakçık kas hücreleri yavaş, T dalgası süresinde hızlı repolarize olur. Kulakçık repolarizasyonunu yansıtan T dalgası, genellikle QRS içine giren ve açık seçik

görülemeyen bir oluşumdur. Normal EKG işareti için bazı tipik değerler tablo 2.1’de verilmiş ve şekil 2.5’te gösterilmiştir.

Tablo 2.1 EKG işareti için bazı tipik değerler

RR aralığı	0,6-1 s
QRS süresi	0,06-0,10 s
P dalga süresi	0,1 s
PQ segmenti	0,08 s
PR aralığı	0,10-0,20 s
ST segmenti	0,08 s
T dalga süresi	0,15 s
QT aralığı	0,35-0,425 s
TP segmenti	0,32 s



Şekil 2.5 Çeşitli EKG parametreleri

2.2.1 EKG İşaretinde Gözlenen Dalga Şekilleri

QRS kompleksi çevre derivasyonlarında ölçülür ve en büyük değeri alınır. Erişkinler için geçerli bir değer olan QRS kompleksinin süresi, 0.10 s’yi geçmez. QRS kompleksine ait en büyük dalganın genliği, çevre derivasyonlarında 8 mm den, göğüs derivasyonlarında ise 10 mm den küçük ise düşük QRS genliğinden söz edilebilir.

2.2.1.1 P Dalgası


Kulakçıkların depolarizasyonunu yansıtan P dalgasının tepesi yuvarlak, sivri, ya da çentikli olabilir. Tepecikler arası 0.03 s'yi aşmadıkça çentiklenme normal bir görünümdür. Erişkinlerde P dalgasının genişliği en çok 0.10 s olup, genliği 2.5 mm den küçüktür. En büyük P dalgasına genellikle derivasyon I ve II de rastlanır. Sinüs ritimli kişilerde P dalgası derivasyon I, II ve aVF de pozitif, aVR de negatif , aVL de pozitif yada negatif ya da iki fazlı, V'de ise genellikle iki fazlı ya da negatiftir. Derivasyon V'de, P dalgasının, pozitif kesimini izleyen negatif kesimine P'nin geç kuvveti denir. Negatif kesimin kapsadığı alana eşit olan P'nin geç kuvveti, negatif kesimin mm olarak derinliği ile saniye olarak genişliğinin cebirsel çarpımına eşittir ve normal olarak -0.04 (mm *s)'den küçüktür

2.2.1.2 PR Aralığı

SA düğümünden çıkan uyarının ventriküllere ulaşabilmesi için geçen sürenin karşılığı olan PR aralığı (şekil 2.6), P dalgasının başlangıç noktasından Q dalgasının başlangıcına; Q dalgasının görülmediği durumlarda ise R dalgasının başlangıç noktasına kadar olan uzaklık olarak ölçülür. PR aralığı bipolar ya da unipolar çevre derivasyonlarında saptanarak en büyük değer alınır. Kalp hızı 70-90 vuru/dakika olduğunda PR aralığının erişkinlerdeki değeri 0.12-0.20 saniye arasındadır.

2.2.1.3 QRS Kompleksi

Q dalgası; normal olarak derivasyon I ve II'de 0.04 s'den dar, 2 mm'den ve izleyen R dalgasının %25'inden daha az derindir. Buna karşılık derivasyon III'deki Q dalgası, sağlıklı kişilerde bile en az 0.04 s süreli ve 6 mm kadar derin olabilir. Derivasyon aVR'de, normal olarak, 0.04 s genişliğinde ve değişik derinliklerde Q dalgası ya da QS örneği görülebilir. Derivasyon aVL'deki Q dalgası 0.04 s'den dar, 2 mm'den ve izleyen R dalgasının % 50'sinden daha az derindir. Derivasyon aVF'deki Q dalgasının normal kişilerde, genişliği 0.04 s'den dar, derinliği 2mm'den ve izleyen R dalgasının % 25'inden küçüktür. Göğüs derivasyonlarının V4, V5, V6 gibi sol karıncığın karşısında yer alanlarında görülebilen Q dalgası, 0.04 s'den dar, 2mm'den ve izleyen R dalgasının % 15'inden küçüktür.



Şekil 2.6 PR aralığı

Normal R dalgası genliği derivasyon I'de 14 mm'den, aVL'de 12 mm'den, aVF'de 21 mm'den, V4'de 7 mm'den, V5'de 26 mm'den, V6'da 21 mm'den küçüktür. S dalgasının derinliği ise derivasyon V'de 21 mm'den, V2'de ise 30 mm'den küçüktür.

QRS kompleksinin sonlandığı nokta ile T dalgasının başlangıcını birleştiren aralık ST bölümü olarak adlandırılır. QRS kompleksi ile ST bölümü arasındaki kavşak J harfi ile gösterilir.

2.2.1.4 ST Segmenti

ST segmenti, genellikle taban hattı üzerinde uzanır. ST segmentinin yukarıya ya da aşağıya kayma derecesini değerlendirmek amacıyla önceki veya sonraki TP segmenti referans çizgisi olarak kullanılır. TP çizgisinin seçilemediği ya da taban hattı üzerinde yer almadığı durumlarda PR aralığı referans olarak alınır.

ST segmentinin çevre derivasyonlarında 1 mm'den yukarıya ya da 0.5 mm'den aşağıya kayması normal bir bulgudur. ST segmentinin daha çok göğüs derivasyonlarında, kimi olgularda ise çevre derivasyonlarında 2 ya da 3 mm yukarıya kayması normal olup erken repolarizasyon olarak adlandırılır. Bu durumda ST segmenti açıklığının yukarıya baktığı; izleyen T dalgasının pozitif, yüksek ve geniş tabanlı olduğu görülür.

2.2.1.5 T Dalgası

Karıncık repolarizasyonunu yansıtan T dalgasının erişkinlerdeki normal süresi 0.10-0.25 s'dir. Derivasyon I, II, V2-V6'da pozitif, aVR'de genellikle negatif, aVF ve aVL de pozitif, yassı, iki fazlı ya da negatiftir. Otuz yaşın üzerindeki erişkinlerde derivasyon V'de negatif olabilen T dalgası, otuz yaşın altındaki gençlerde V2 ve V4'de bile negatif görünebilir.

2.2.1.6 U Dalgası

T dalgasını izleyen ve nasıl oluştuğu kesin olarak bilinmeyen bir dalgadır. Normal kişilerde de görülebilir. Genliği, kendisinden önceki T dalgasının genliğinin % 25'ini geçmez. Derivasyon V2-V4'de 2 mm'yi aşmayan U dalgasına rastlanabilir. T dalgasının pozitif olduğu derivasyonlarda U dalgası da pozitifdir. U dalgasının negatif ya da önceki T dalgasından daha büyük genlikli olması normal bir bulgu değildir.


2.2.1.7 QT Aralığı

Karıncıkların depolarizasyon ve repolarizasyonu için geçen toplam süreyi yansıtan QT aralığı, QRS kompleksinin başlangıcından T dalgasının bitimine kadar olan uzaklığı kapsar. Erişkinlerde normal olarak 0.35-0.44 s arasında değişen QT aralığı, kalp hızına bağımlı olması nedeniyle düzeltilerek bildirilir. Bazett eşitliği uyarınca kalp hızına göre düzeltilmiş QT aralığı; saniye olarak ölçülen QT uzaklığı, saniye birimi ile RR aralığının kareköküne bölünerek bulunur. Düzeltilmiş QT aralığının üst sınırı 0.425 s'dir. Değerlendirme aşamasında, kural olarak, 12 derivasyondaki en uzun QT aralığı dikkate alınır. Bununla birlikte T dalgasının iyi seçildiği ve U dalgası ile karışmadığı bir derivasyonu seçmekte yarar vardır.

2.3 Derivasyonlar

EKG ölçümü vücut üzerindeki çeşitli noktalar arasındaki potansiyel farkları yardımıyla yapılır. Elektrodların hasta ile bağlantı şekilleri derivasyon olarak adlandırılır. Elektrokardiyogram örneklerinin açıklanıp kavranmalarında derivasyonlar önemli bir yer tutarlar. Günlük elektrokardiyografi uygulamaları

sırasında kullanılan 12 derivasyon, çevre derivasyonları ve göğüs derivasyonları olarak iki gruba ayrılırlar. Bu yapı şekil 2.7’de gösterilmiştir.



Şekil 2.7 Derivasyonların vektörel gösterimi

Çevre derivasyonları bipolar (standart) ve unipolar olarak iki gruba ayrılırlar.


Bipolar çevre derivasyonları, bedenin iki noktası arasındaki potansiyel farkını saptamaya yararlar. I, II, III olarak gösterilirler.

Elektrokardiyografi aygıtının negatif ucuna bağlı elektrodun sağ kola, pozitif ucuna bağlı elektrodun ise sol kola bağlanması ile elde edilen bipolar çevre derivasyonu, derivasyon I dir. Bu derivasyon sağ ve sol kol arasındaki potansiyel farkını yansıtır.


Elektrokardiyografin negatif ucuna bağlı elektrodun sağ kola, pozitif ucuna bağlı elektrodun ise sol bacağına bağlanması ile derivasyon II düzenlenmiştir olur. Böylece sağ kol ve sol bacak arasındaki potansiyel farkı ölçülmüş olur.

Elektrokardiyografin negatif ucuna bağlı elektrodun sol kola, pozitif ucuna bağlı elektrodun sol bacağına bağlanması ile derivasyon III düzenlenmiştir olur. Sol kol ile sol bacak arasındaki potansiyel fark derivasyon III de ölçülür.

Sağ kola, sol kola ve sol bacağına yerleştirilen elektrotlara bağlı teller birleştirilirse santral terminal olarak adlandırılan ve sağ kol, sol kol ve sol bacak arasındaki toplam potansiyel farkın sıfır olduğu ortak bir uç elde edilmiş olur. Santral terminal, elektrokardiyografin negatif ucuna iliştilir ve pozitif ucuna bağlı bir araştırıcı elektrot sırası ile sağ kola, sol kola ve sol bacağına yerleştirilirse şekil 2.8’de görüldüğü gibi sırası ile VR, VL, VF olarak gösterilen unipolar çevre derivasyonları elde edilir. Bunlar aracılığı ile çizilen potansiyel genlikleri küçük olduğu için bunların yerine Goldberger tarafından ölçülen ve potansiyel genliklerini 1.5 kat artıran bir düzenleme kullanılmaktadır. Goldberger’in unipolar çevre derivasyonlarını oluşturmak için elektrokardiyografin pozitif ucuna bağlı araştırıcı elektrot hangi tarafa yerleştirilmiş ise, o tarafın santral terminali ile ilişkisi kesilir. Bu yöntemle elde edilen derivasyonlar şekil 2.9’da görüldüğü gibi aVR, aVL, aVF olarak gösterilirler.



Şekil 2.8 Çevre derivasyonları



Şekil 2.9 Goldberger’in unipolar çevre derivasyonları

Merkezi terminal, Wilsonun öngördüğü biçimde elektrokardiyografin negatif ucu ile birleştirilir ve aygıtın pozitif ucuna bağlı bir araştırıcı elektrot, bu kez prekardiyumun

belirli noktalarında gezdirilirse unipolar göğüs derivasyonları elde edilir. Araştırmacı elektrodun, sternumun hemen sağ yanına ve dördüncü kosta aralığına konması ile V1 sternumun hemen sol yanına ve yine dördüncü kosta aralığına konması ile V2, sol orta klavikula çizgisi ile beşinci kosta aralığının kesiştiği noktaya yerleştirilmesi ile V4 derivasyonları oluşur. V3 derivasyonunun yeri, V2 ile V4'ün tam ortasıdır. V4 noktasından geçen yatay çizginin, koltuk çizgisi ile kesişme noktası V5'i, orta koltuk çizgisi ile kesişme noktası ise V6'yı verir. Az da olsa sol göğüs yarımındaki elektrot yerlerinin, sağ göğüs yarımındaki karşılıkları kullanılarak V3, V4, V5, V6 derivasyonları düzenlenir.

Bipolar çevre derivasyonlarına ilişkin elektrot çiftlerini birleştiren kavramsal düz çizgilere derivasyon eksenleri denir. Eksenin pozitif ucu, pozitif elektrodun yer aldığı ucudur. Derivasyon I, II, ve III'e ilişkin eksenler çizildiğinde, Einthoven adı ile bilinen üçgen elde edilir. Tam doğru olmayan bir takım varsayımlara dayanılarak frontal düzlemde yer alan bu üçgenin eşkenarlı olduğu, köşelere eş uzaklıkta olan merkezin sıfır noktasını gösterdiği, üçgenin merkezinde kalbin anatomik merkezinin yer aldığı, kalbin elektriksel merkezi ile anatomik merkezinin çakıştığı öngörülür. Üçgenin köşelerinde, unipolar çevre derivasyonlarına ilişkin pozitif uçlar yer alırlar. Unipolar derivasyon eksenleri üçgenin köşelerini üçgenin merkezine birleştiren doğrular çizilerek elde edilirler. Eksenlerin, üçgenin karşı kenarını kestikleri noktalar, söz konusu derivasyonların gerçekte olmayan kuramsal negatif uçları yerlerine geçerler. Unipolar derivasyon eksenlerinin, üçgenin pozitif ucu gösteren köşeleri ile sıfır noktasını yansıtan merkezi arasında kalan bölümleri, eksenlerin pozitif kesimlerini oluştururlar.

Unipolar göğüs derivasyon eksenleri içinde horizontal düzlemde yapılması gereken işlem, söz konusu derivasyonların prekardiyumdaki pozitif uçlarını üçgenin merkezi ile birleştirmektir. Eksenlerin pozitif uçları ile kalbin merkezi arasında kalan bölümleri pozitif eksen kesimlerini, merkezin öte yanında kalan kesimleri ise eksenin negatif kesimlerini oluştururlar. Derivasyon V1 ile derivasyon V6'nın eksenleri arasında yaklaşık 115 derecelik bir açı vardır.


Bipolar çevre derivasyonları Einthoven üçgenin merkezinden geçecek biçimde kaydırıldıklarında, tümü bir noktada kesişen ve birbirleri ile 30'ar derecelik açılar yapan altı eksenli bir referans sistemi elde edilmiş olur. Bu sistemde, derivasyon I'in

pozitif ucu 0 derece, negatif ucu 180 derece, derivasyon II'nin pozitif ucu +60 derece, derivasyon aVF'nin pozitif ucu +90 derece, derivasyon III'ün pozitif ucu ise +120 derece olarak gösterilir. Eksenlerin öbür uçları -30, -60, -90, -120, ve -150 dereceleri bildirirler. Çevre derivasyonu eksenlerinden oluşan ve frontal düzlemde yer alan bu sistemden, kalbin elektriksel eksenini belirlemek için yararlanılabilir.

Göğüs duvarı üzerinde yer alan pozitif uçlar, kalbin merkezi ile birleştirilerek elde edilen göğüs derivasyonları eksenleridir. Eksenlerin merkezin ötesinde kalan uçları negatiftir.

2.3.1 Kalp Vektörü

Herhangi bir derivasyonda elde edilen EKG işareti, skaler bilgi taşır. Aynı anda x, y, z doğrultularında elde edilecek EKG işaretleri yardımıyla kalp vektörü elde edilebilir (şekil 2.10).




Şekil 2.10 Kalp vektörünün değişimi

2.4 EKG Vuruları

EKG'deki ritim ve şekil bozukluklarına aritmi denir. EKG'deki şekil değişimleri kalbin aktivitesiyle ilgili bilgileri kapsar. EKG'deki ritim değişiklikleri ise uyarı işaretinin oluşum noktası, uyarının kalbin elektriksel iletim sistemi üzerindeki hızı ve uyarının frekansı ile ilgili bilgileri kapsar.

2.4.1 Normal Vuru

Normal vuru, şekil 2.11'deki dalga şekline sahiptir. Normal P dalgasının süresi 0,10 s'dir. PR süresi ortalama 0,16 s olarak gözlenir. PR süresi kalp hızının artması ile kısalır, yaş ile birlikte artar. QRS kompleksi süresi yetişkinlerde 0,06-0,10 s arasındadır. QRS süresinin uzaması, karıncıklarda iletimin gecikmiş olduğu anlamına gelir. QT süresi, QRS kompleksinin başlangıcından T dalgasının sonuna kadar olan aralıktır. QT süresi, kalp hızına bağlı olarak değişiklik gösterir. Normal yetişkinlerde bu süre 0,35-0,44 s arasındadır. T dalgasının normal süresi, 0,10-0,25 s arasındadır. Ancak QT süresinin içine girmiş olduğundan klinik elektrokardiyografide T dalgasının süresi ayrıca ölçülmez.




Şekil 2.11 Normal EKG vurusu içeren kayıt (N tipi EKG vurusu)

2.4.2 Erken Karıncık Kasılması

Erken karıncık kasılması (premature ventricular contraction – PVC), AV düğümünde oluşan elektriksel işaretin beklenenden daha önce meydana gelmesiyle görülür. Karıncıklar bir PVC oluşturduğunda kulakçıklar depolarize olamayabilirler. Depolarizasyonun gerçekleşmemesi durumunda P dalgası oluşmaz. Kulakçık depolarizasyonu meydana gelirse karıncık depolarizasyonunun etkisiyle P dalgası QRS kompleksi içinde kaybolur. PVC vurularında QRS kompleksi geniş ve anormal bir görünümündedir. Süresi 0,12 s'den daha uzundur ve QRS dalgası genellikle ters yönde bir sapma gösterir. Takip eden T dalgası genellikle QRS kompleksine zıt yöndedir. Bu nedenle ST segmentinde anormallikler görülebilir. PVC kesintisinin

olmadığı bölümde EKG ritmi ve şekli düzenlidir. PVC'nin hesaba katılmadığı vuru hızı normaldir. Dakikada 10'dan fazla PVC oluşması hayati tehlikeye yol açar.




Şekil 2.12 Erken karıncık kasılması içeren EKG kaydı (V tipi EKG vurusu)

2.4.3 Sol Dal Blok Vurusu

Sol dal blokları (left bundle branch block); sol karıncığa olan iletimin, sol His dalının tıkalı olması nedeniyle arka dallardan gecikerek gerçekleşmesinden kaynaklanır. Vuru düzenleyicisi SA düğümüdür. Sol karıncık aktivasyonu gecikir; sol karıncık aktive olmaya başladığında ise sağ karıncığın bu potansiyellere karşılık gelen potansiyelleri artık kalmamıştır. Bu nedenle dengelenemeyen sol karıncık potansiyelleri, büyük sol karıncık vektörleri oluşturur. Bu yüzden QRS vektörlerinin genliği yüksek olabilir. Karıncık aktivasyonunun gecikmesi, QRS'in orta ve son kısımlarında olur. P dalgası normaldir. Her P dalgasını bir QRS kompleksi takip eder. Q dalgası genellikle yoktur. QRS süresi, 0.12 s veya daha uzundur. R dalgasında çentik (RsR') olabilir. PR aralığı sabit olup 0.12 s'den daha uzundur. Derin S dalgası gözlenir. T dalgası ters dönmüştür. Ritim düzenlidir. Vuru hızı normaldir.


Klinikte sol dal bloğunun önemi, hasta hikayesi ve fiziksel muayene konulan tanı ile belirlenir. Ancak sol dal bloğu vakalarının büyük kısmında önemli bir kalp rahatsızlığı vardır.



Şekil 2.13 Sol dal blok vurusu içeren EKG kaydı (L tipi EKG kaydı)

2.4.4 Sağ Dal Blok Vurusu

Sağ dal bloklarında (right bundle branch block) vuru düzenleyicisi SA düğümüdür. Sağ karıncığa olan iletim, sağ His dalının tıkalı olması nedeniyle arka dallardan gecikerek mümkün olur. Sağ karıncık aktivasyonu gecikir. P dalgası normaldir. Her P dalgasını bir QRS kompleksi takip eder. PR aralığı sabit olup 0.12 s'den uzundur. QRS süresi, 0.12 s veya daha uzundur. Komplikasyonsuz sağ dal bloklarında QRS'in başlangıç ve orta kısımları normaldir; sadece son kısımları anormallik gösterir. QRS'in son kısmında karıncık aktivasyonu yavaşlamış ve gecikmiştir. Bu anormal aktivasyon, V5-V6 derivasyonlarında geniş S dalgasının ortaya çıkmasına neden olur.



Şekil 2.14 Sağ dal blok vurusu içeren EKG kaydı (R tipi EKG vurusu)


2.4.5 Anormal Erken Kulakçık Kasılması

İki kulakçıktan herhangi birinde oluşan ikincil uyarılar sonunda kulakçık erken kasılması (aberrated atrial premature beat) meydana gelir. Vuru düzenleyicisi

kulakçık içinde bir ektopik merkez de olabilir. Her vuru normal olarak karıncıklara ulaşır

Erken ektopik vuru, RR aralıklarının düzenini bozar. Kalp vuru hızı, ortalama olarak normal değerleri içindedir. Kulakçık ve karıncık hızları eşittir. Normal bir PP aralığından daha kısa süre içerisinde P dalgası gözlenir. Ektopik vuruya ait P dalgası morfolojisi farklıdır. Ektopik vuruya ait P dalgası önceki vuruya ait T dalgasının altında kaybolabilir. PR aralığı, sinüsten iletilen vuruların PR aralığından daha kısa, uzun veya eşit uzunlukta olabilir ve süresinin 0.12 s ile 0.20 s arasında olması beklenir. QRS aralığı, 0.12 s'den daha kısadır.

Bu vuruya normal insanlarda da sık rastlanır. Yaş ile birlikte oluşma sıklığı da artar. Tek başına bir kalp sorununu göstermez ancak kulakçık taşikardisi ve kulakçık fibrilasyonunun habercisi olabilir.



Şekil 2.15 Anormal kulakçık erken vurusu içeren EKG kaydı (a tipi EKG vuru)

2.4.6 Yapay Vuru

Kalbin doğal iletim sisteminde aksaklıklar olması durumunda kalp kasının kasılması için gereken elektriği sağlayan ‘pacemaker’ adı verilen aygıtlar kullanılmaktadır. Pacemaker; sağ karıncık, sağ kulakçık ve her ikisinden ardışıl olmak üzere yapay vuruyu kalbe iletir.


Yapay vuruda P dalgası nadiren görülür. PR aralığı ölçülemez. QRS kompleksi, yapay vurudan sonra görülür. Süresi genellikle 0.12 s'den daha uzundur. Eğer varsa PP aralığı değişik değerler alır. Kalp vuru hızı, RR aralığı, pacemaker ayarına göre değişik değerlerdedir.



Şekil 2.16 Yapay vuru içeren EKG kaydı (P tipi EKG vurusu)

2.4.7 Yapay ve Normal Vuru Birleşimi


Kalbin normal iletim sisteminde gecikme olması durumunda pacemaker sistemi devreye girer ve yapay olarak ürettiği vuruları kalbe iletir. Bu sırada kalp de doğal yollardan vuru oluşturursa her iki vuru da aynı anda gözlenir. Ortaya çıkan birleşik vuruda genişlemiş QRS kompleksi söz konusudur. P dalgası belirgin değildir.



Şekil 2.17 Yapay ve normal vuru birleşimi içeren EKG kaydı (f tipi EKG vurusu)

2.4.8 Karıncık ve Normal Vuru Birleşimi

Füzyon, ayrı odaklardan kaynaklanan uyarıların kulakçık ve karıncıkta karşılaşmaları sonucu oluşan melez bir vurudur. Karşılaşma karıncıkta gerçekleştiği takdirde karıncık ve normal vuru birleşimi olarak adlandırılır. QRS kompleksi geniştir ve süresi 0.12 s'den uzundur.




Şekil 2.18 Karıncık ve normal vuru birleşimi içeren EKG kaydı (F tipi EKG vurusu)

2.4.9 Karıncık Kaçak Vurusu

Kalpdeki SA ve AV düğümlerinin darbe üretim hızı, karıncıklardaki kaçak darbe üreten merkezlerin hızından düşük olduğunda veya SA ve AV düğümlerinde üretilen darbeler bloke olup karıncıklara ulaşamadığında karıncık kaçak vurusu oluşur. Bunun nedeni, kalbin elektriksel iletim sistemindeki (çoğunlukla His demetindeki) bozukluklardır. Vurular, ektopik merkez kaynaklıdır. Ektopik merkez genellikle AV düğümüdür, karıncıklardır, nadiren de kulakçıklardır. Sürekli vurular gözlemlendiğinde ciddi bir kalp rahatsızlığından söz edilebilir. Bir seri kaçış vurusu idioventriküler ritim adını alır.

Kalp vuru hızı 30-40 vuru/dk civarındadır. Kulakçıklarda herhangi bir aktivasyon meydana gelmediği için P dalgası gözlenmez. EKG kaydı, var olmayan P dalgası ve dakikada yaklaşık 40 kez düzenli olarak görülen geniş (0.12 s'den uzun süreli) QRS kompleksleri ile karakterize edilir.



Şekil 2.19 Karıncık kaçak vurusu içeren EKG kaydı (E tipi EKG vurusu)


3. SINIFLAMA KURALLARI

3.1 Sınıflama Kriterleri

Sınıflama, bir çeşit örüntü tanıma (pattern recognition) işlemidir. Örüntü tanımada yaklaşım, kalıp uydurmadır (template matching). Her sınıf için seçilen ya da hesaplanan kalıp, sistemin belleğinde saklanır; giriş işareti örneği veya örnekten elde edilen parametreler bu kalıplarla karşılaştırılır.

Olaylar uzayı, tanıma işleminde seçilen konuyu; olaylar uzayındaki örnekler ise, bu uzayda varlığı sorgulanan bilgileri temsil etmektedir. Olaylar uzayındaki örnekleri temsil eden vektörler sınıflanarak gruplara ayrılır ve sınıfları etiketlenir. Sınıf sayısının artması, bilgisayarın incelenen olaydaki algılama gücünün artmasına yol açar. Ancak sınıf sayısı ile doğru algılama performansı arasında genellikle ters bir ilişki vardır. Sınıf sayısını artırma doğru algılama performansını düşürür

Sınıflama işlemi için, önce işaret modellenir ve öz nitelikleri (parametreleri) elde edilir. Sınıflayıcı; bu öz nitelikleri ve önceden sınıfı belirlenmiş işaret öz niteliklerini, önceden seçilmiş karar kuralını kullanarak sınıflar. Sınıflama, karar kuralı sonuçlarının karşılaştırılması işlemidir. İşaret, gerçek zamanda (real-time, on-line) veya gerçek olmayan zamanda (off-line) işlenebilir.



Şekil 3.1 Sınıflamanın genel blok diyagramı

Sınıflama işleminin genel blok diyagramı şekil 3.1’de gösterilmiştir. Ölçme ve işleme bloğunda, işaret algılanır ve gürültülerden temizlenir, giriş örnek dizisinden $\underline{x}$ ölçme vektörü elde edilir. Burada, elde edilen veri sayısı çok fazladır. Öznitelik bulucuda, uzun veri kayıtlarıyla uğraşmamak için, çeşitli modeller ve dönüşümler kullanılarak işaret sıkıştırılır ve bazı öznitelikler, işareti temsil eden parametreler olarak elde edilir. Bu işleme öznitelik bulma (feature extraction) işlemi adı verilir. Gerekli sınıflama algoritması, öznitelik seçiciden alınır. Sınıflayıcıda, sınıflanacak $\underline{\beta}$ öznitelik vektörü, her sınıfa ait önceden hesaplanarak saklanmış öznitelik kalıplarıyla karşılaştırılır. Karşılaştırmada belli bir kritere, kurala veya indekse göre $\underline{\beta}$ vektörü, i . kalıp vektörüne diğerlerine olduğundan daha iyi uyuyorsa, $\underline{\beta}$ vektörü i . sınıfa dahil edilir.

3.2 Karar Fonksiyonu


Öznitelik uzayında sınıfları birbirinden ayırmak için sınıf sınırlarını temsil edebilecek fonksiyonlar tanımlanmaktadır. Sınıflayıcı, $\underline{\beta}$ öznitelik vektörünü, M adet kalıp öznitelik vektörleriyle karşılaştırır. Karşılaştırma belli bir kurala (karar kuralı) göre yapılır. Karar kuralı, bazı durumlarda bir performans indeksi, bazı durumlarda da bir ayırım (karar) fonksiyonu, $d_j(\underline{\beta})$ kullanır. Karar fonksiyonları literatürde bazen mesafe ölçütleri olarak da tanıtılmaktadır. En bilinen karar fonksiyonlarından biri eşitlik 3.1’de gösterilmektedir.

$$d(X) = w_0 + w_1 \cdot x_1 + w_2 \cdot x_2 + + w_n \cdot x_n \quad (3.1)$$

X , n boyutlu öznitelik uzayında giriş vektörünü temsil eder. $d(X)$ fonksiyonu, $d(X)=0$ noktasında n boyutlu uzayda bir hiper düzlem tanımlamaktadır. Şekil 3.2 a)’da sınıflar lineer olarak ayrıştırılabilir ve hiper düzlem, öznitelik uzayını iki parçaya bölmektedir. X vektörünün düzleme olan uzaklığına bağlı olarak $d(X)$ fonksiyonunun değeri işareti ile birlikte değişmektedir. $d(X)$ fonksiyonu eşitlik 3.2’deki gibi bir fonksiyondan geçirilirse öznitelik uzayı iki parçaya etiketlenerek ayrılacaktır.


$$f(d(X)) = \begin{cases} +1 & d(X) > 0 \\ -1 & \text{aksi halde} \end{cases} \quad (3.2)$$

Bu karar fonksiyonu ile birbirlerinden uzakta öbekleşmiş iki sınıfa ait örnekler kolaylıkla ayrılabilir. Ancak şekil 3.2 b)'deki gibi bir dağılımda karar yüzeyleri ancak eğrilerle tanımlanabilmektedir; sadece bir doğru kullanmak sınır yüzeyini oluşturmak için yeterli olmaz. Şekilde sınıf sınır eğrisi kırık doğruların birleşimi ile elde edilmiştir. Sınıf sınır yüzey eğrisine birden fazla düzlem kullanılarak yaklaşılr. Bu yaklaşım, sınıflayıcı yapılarında katmanlaşmaya doğru gidilmesine sebep olmaktadır.



Şekil 3.2 Sınıf sınır yüzeylerinin ayrılması


Her sınıfın kendi özelliğini taşıyan ayırım fonksiyonu, çoğu durumda bir skalerdir. Karar kuralı, bu fonksiyon değerini seçilen bir karar eşiği ile karşılaştırır. Karşılaştırma sonucuna göre, giriş vektörü, hangi ayırım fonksiyonunu maksimum yapmışsa veya hangi ayırım fonksiyonunu seçilen karar eşiğinin üzerine çıkartmışsa, o ayırım fonksiyonunun ait olduğu sınıfa sınıflanır (şekil 3.3). Sonucun seçilen sınıflara uymadığı durumda “ret” sınıfı kullanılabilir.



Şekil 3.3 Sınıflayıcının genel yapısı

Sınıflama işlemi iki aşamada gerçekleştirilir (şekil 3.4):

1. Öğrenme (eğitim) modu: Uzun sürer, zahmetlidir. Eğitim kümesi, tüm sınıfları temsil edebilecek yeterli sayıda örnek (öznitelik vektörü) içermelidir.
2. Çalışma (deneme, test) modu: Gerçek zamanda çalışmaya uygundur.



Şekil 3.4 Sınıflama aşamaları


Genelde, eğitim modunda, eğitim için kullanılan her sınıfa ait N_i adet giriş vektörünün her birinden elde edilen β_i öznitelik vektörlerinin ortalaması alınarak, sınıfların μ_i kalıp vektörleri bulunur. Bu, N_i adet bilinen sınıfa ait örneğin işleme sokulması demektir. Çalışma modunda, sınıflanacak giriş vektörünün β_x öznitelik vektörü hesaplanarak eğitim modunda hesaplanmış ve saklanmış olan sınıflara ilişkin kalıp öznitelik vektörleriyle işleme sokulmak üzere sınıflayıcıya verilir.

3.2.1 Karar Fonksiyonunun Performans Kriterleri

Karar kuralının performansı birkaç parametre ile tanımlanabilir.

1. İteratif olarak sınıflayıcı ağırlıklarının bulunması
2. Sınıflayıcı yapısının eğitim sırasında ihtiyaca göre büyümesi
3. Eğitimin kısa sürede gerçekleştirilebilmesi
4. Eğitim sonrası sınıflayıcının az sayıda ağırlık ile gerçekleştirilmesi
5. Sınıflayıcının yüksek genelleme özelliği (doğru algılama performansı)
6. Sınıflayıcının fiziksel olarak kolaylıkla gerçekleştirilebilmesi

Eğitim sırasında karar fonksiyonunun parametreleri iteratif olarak değiştirilerek sınıf sınır yüzeylerine yaklaşılmaya çalışılır (şekil 3.5). Eğitim ile w_0 , w_1 ve w_2 parametrelerinin amaç fonksiyonu için en uygun değerleri (kalın çizgi) bulunur. Yüzeyi belirleyen hiper düzlemler, sınıflayıcı ağırlıklarını oluşturmaktadır. Sınıflayıcının az sayıda ağırlık ile gerçekleşmesi, sınıf sınır yüzeylerinin mümkün olan en az sayıda parametre ile tanımlanması sayesinde olur.



Şekil 3.5 Parametrelerin eğitimle değişimi

Karar fonksiyonunun genelleme yeteneği, tasarım sırasında kullanılan örnek işaretler dışındaki verilere fonksiyonun doğru cevap verme sayısı olarak tanımlanmaktadır. Tasarım sırasında kullanılan örnek sayısının büyüklüğü, genelleme yeteneğinin artmasına yol açmaktadır.

3.3 Özniteliklerin Seçilmesi

Özniteliklerin çıkartılması, sadece bir sınıfa ait olan ve diğer sınıflarda bulunmayan karakteristik bilgilerin tespit edilmesi işlemidir. Olaylar uzayındaki sınıfları birbirlerinden ayıran doğru özniteliklerin tespit edilmesi, sınıflama performansını olumlu etkiler. Özniteliklerin bulunmasına yönelik matematiksel bir yöntem yoktur ve çoğu durumda öznitelikler tasarımcının sezgisine bağlı olarak tespit edilir. Öznitelikler dikkatli seçilmelidir; öyle ki, işarete ait bilginin çoğunu içermelidir, yani sınıflayıcıya yüksek ayırım gücü vermelidir. Sınıflamada etkili olmayan öznitelikler seçilmemelidir. Bazı durumlarda işaret bu özniteliklerden tekrar elde edilebilmelidir.


İşaretin herhangi bir lineer veya nonlinear dönüşümü, ayırım gücü sağlaması şartı ile öznitelik seçiminde kullanılabilir.

Çoğu durumlarda, elde edilen öznitelikler birbirine bağımlıdır; bununla beraber bazı yöntemler, birbirinden bağımsız öznitelikler sağlarlar.

Hesaplama boyutunun büyüklüğü ve öznitelik bulmak için geçen zamanın uzunluğu, özniteliklerin sayısının azaltılmasını gerektirir. Öte yandan, özniteliklerin sayısının az olması, sınıflamada ya da işareti yeniden oluşturmada doğruluğu azaltır.

Sınıf özniteliklerinin ağırlık merkezi durumunda olan kalıplardan ne kadar çok bilgi elde edilebilirse, doğru sınıflama yapma olasılığı o kadar artar, ancak bununla orantılı olarak işlemin zorluğu ve maliyeti de artar.

Özniteliklerin sayısı, öznitelik uzay boyutunu direkt olarak tanımlamaktadır. Özniteliklerin belirlenmesi incelenen konuya veya incelenen konuya ait örneklerin olaylar uzayında dağılımına bağlıdır. Genellikle literatürde her farklı konu için farklı bir yöntem tanımlanmaktadır. Ayrıca olaylar uzayında sınıf dağılımını gösterecek yeterli sayıda örnek de mevcut değildir. Bu durumda incelenen olaya ait sınıf dağılımı tam olarak ifade edilemez.



Şekil 3.6 Optimum sınıf dağılımı

İki boyutlu 3 sınıftan oluşan bir örnek öznitelik uzayını ele alalım. Özniteliklerin doğru belirlenmesinden sonra, öznitelik uzayında örneklerin dağılımı şekil 3.6'ya benzemektedir. Sınıflar birbirlerinden mümkün olduğunca uzaktadır ve her sınıfa ait öznitelik vektörlerinin bir arada bulunduğu gözlenir. Öznitelik çıkartma işleminin

başarımını, d_1 , d_2 , d_3 'ün küçük değerlerde d_{12} , d_{13} ve d_{23} 'ün büyük değerlerde oluşu belirler.

Özniteliklerin belirlenmesi işlemi, tasarımcının tecrübesine ve kabullerine bağlı kalmaktadır. Olaylar uzayı tam olarak tanımlanamadığı için özniteliklerin belirlenmesinde tasarımcıyı yönlendiren bir matematiksel yöntem de mevcut değildir. Öznitelikler seçilirken olaylar uzayındaki tüm örnekler kullanılamaz. Genellikle olaylar uzayının tanımlanması için az sayıda örnek ile bir alt küme oluşturulmaktadır. Alt küme içindeki örnek işaretler ne kadar fazla ise eğitim kümesinin uzayı temsil yeteneği o kadar iyi olacaktır. Mevcut çalışmalar, sadece seçilen özniteliklerin birbirlerine göre anlamca sıralanmasına yöneliktir ve boyut azaltılmasında kullanılmaktadır. Boyut azaltmada amaçlanan, öznitelik uzayını daha düşük boyutlu uzaya dönüştürerek gerekli performans kriterini basitleştirmek veya kriter için gerekli şartların veya hesaplamaların sayısını azaltmaktır.


Çoğu durumda doğadaki ham işaretlerden yeterli bilgi elde edilemez. İşaret, matematiksel bir dönüşüm uygulanarak farklı bir domene taşınır ve bu domende işareti temsil eden bileşenlerden bilgi sağlanır. Böylece, bir domende saklı bilgi, diğer domende açığa çıkartılmış olur. Zaman domeninde işaret üzerinde yayılmış şekilde bulunan bilgi, dönüşüm sonucu kolaylıkla ayrıştırılabilir.

Eğitim kümesinin küçük seçilmesi, yapılan çalışmanın istatistiksel olarak anlamını azaltır. Bu durumda genelleme yeteneği, dönüşüm işleminin seçimine doğrudan bağlı olacaktır.

3.3.1 Öznitelik Uzayında Sınıfların Gösterilmesi

Şekil 3.7'de $\underline{\beta}=[\beta_1 \ \beta_2 \ \beta_3]^T$ öznitelik vektörünün boyutu üç olup, iki sınıf verilmiştir. Giriş, bu iki sınıf kümesinden biri olarak seçilir. Örüntü kümeleri, özniteliklerin olasılık dağılımı olarak kestirilebilmektedir.

Şekil 3.7'den açıkça görülmektedir ki, sınıflama sadece β_2 üzerinden yapılabilir. Çünkü, β_2 eksenindeki kümelere ilişkin sınıf aralıkları üst üste düşmez (örtüşmez). Diğer eksenlerde ise bu iki sınıf kümesi kesişmektedir.



Şekil 3.7 Öznitelik uzayında sınıf kümeleri

İki boyutlu uzayda, ancak, (β_1, β_2) veya (β_2, β_3) düzlemlerinde bu iki sınıfı ayırabilecek bir ayırım fonksiyonu bulunabilir. Böyle bir sınıf dağılımına sahip öznitelik uzayı için lineer olmayan bir yapıya sahip sınıflayıcılar kullanmak gereksizdir.

3.4 Sınıflama Sonucunun Değerlendirilmesi

Sınıflama sonucunun değerlendirilmesinde kullanılan parametrelerden biri karar matrisidir. Karar matrisi, sınıflayıcının giriş uzayına verdiği cevap ile gerçekte giriş uzayındaki sınıfların durumunu gösterir.

Doğru pozitif (TP - true positive), gerçekte ait olduğu sınıfa sokulan girişlerin yüzdesini (sayısını) verir.

Sahte pozitif (FP - false positive), gerçekte o sınıfa ait olmadığı halde sınıfa sokulanların yüzdesini verir.

Doğru negatif (TN - true negative), pek kullanılmamakla birlikte, gerçekte sınıf dışı olan örneklerin sınıf dışında tutulmaları yüzdesini verir.

Sahte negatif (FN - false negative), gerçekten sınıfa ait olup da sınıf dışı tutulanlarının yüzdesini göstermektedir.(Tablo)

Karar matrisinin gösterdiği yüzdelere için şu eşitlikler geçerlidir:

$$TP + FN = 1 \quad (3.3a)$$

$$TN + FP = 1 \quad (3.3b)$$

Tablo 3.1 Sınıflayıcı karar matrisi

Sınıflayıcı cevabı		Doğruluk Durumu	
		Örnek sınıfa ait	Örnek sınıf dışı
	Örnek sınıfa ait	Doğru Pozitif (TP)	Sahte Pozitif (FP)
	Örnek sınıf dışı	Sahte Negatif (FN)	Doğru Negatif (TN)

Sınıflama sonucunun değerlendirilmesinde kullanılan diğer parametreler, duyarlık ve pozitif kestirimdir.


$$\text{Sınıflama duyarlığı} = \frac{\text{Sınıfa sokulan gerçek sınıf örnekleri sayısı (TP)}}{\text{Gerçek sınıf örnekleri sayısı (TP + FN)}} \quad (3.4)$$

$$\text{Doğru sınıflama kestirimi} = \frac{\text{Sınıfa sokulan gerçek sınıf örnekleri sayısı (TP)}}{\text{Sınıfa sokulanların tümü (TP + FP)}} \quad (3.5)$$

3.5 Dalga Formu Deteksiyonu

Dalga formu; işarete veya işaretin belli bir bölgesine ait, genelde zaman domeninde incelenen, belli bir yapıya sahip reel değerli bir fonksiyondur. Biyomedikal mühendisliğinde; fonokardiyografide özel kalp seslerinin incelenmesi, solunum işaret analizi, EKG’de QRS ve P dalga deteksiyonları, fetal kalp vurularının deteksiyonu, EEG’de spike ve/veya spindle deteksiyonu gibi alanlarda uygulamaları vardır. Bunun dışında dalga formu deteksiyonunun diğer uygulama alanları; alarm, görüntüleme ve otomatik sınıflandırmadır.

İşaret içinde aranan dalga-formunun ortaya çıkartılabilmesi için, ya dalga formunun yapısal özelliğinden, ya da formun bir kalıba uyması özelliğinden faydalanılır. Amaç, gürültülü işaret içinde belirlenen dalga formunun 1) bulunup bulunmadığının, 2) eğer bulunuyorsa, bulunduğu anların ve 3) gerçeğe en yakın biçiminin belirlenmesidir (şekil 3.8).



Şekil 3.8 İşaret ve dalga formu

Bu amaçla kullanılan algoritmalar; işarete ve dalga formuna özgüdür, sezgiye ve tecrübeye dayalıdır ve işareti sürekli denemeye tutar.

Dalga-formu analizinde işaretin bir zaman dilimindeki şekli belli olan parçasına, yani dalga-formuna, kalıp (template) adı verilir. Kalıp seçimi için işarete veya işaret parçasına ait ön bilgi (*a priori* bilgi - tecrübe) gereklidir. Kalıp seçimi; aranan işaret için şekle uygun olanlar içinde, ortalama almayı gerektirir.

Kalıba uydurma işleminde örüntü (pattern) tanıma teknikleri uygulanır. Analiz aşamasında korelasyon, uyumlaştırılmış filtreleme ve diğer örüntü tanıma işlemleri kullanılarak işaretin kalıba uyan parçaları (segmentleri, dilimleri) araştırılır.

Bu yöntemin dezavantajı; kalıba uydurmanın külfetli ve zaman alıcı bir işlem olmasıdır. Diğer yöntemlere üstünlüğü ise genel olması nedeniyle, sadece kalıbı değiştirerek (algoritmayı bozmadan) diğer şekillerin varlığının da araştırılabilmesidir.

3.5.1 Kalıp Uydurma Yöntemi

Burada aranan dalga-formunun biçimi kalıp olarak bellidir. Amaç; işaretin bu kalıba uyduğu an t_i , dalga-formunun gerçek şekli ve/veya dalga-formu kazancı G_i 'nin bulunmasıdır.

3.5.1.1 Basit Kalıp Uydurma Yöntemi

Seçilmiş olan kalıbın şekli basit olarak bellidir ve esnektir. Örnek olarak EKG işaretinde QRS kompleksinin bulunduğu anları yakalamak için çeşitli benzerlik algoritmaları (korelasyon, ortalama fark kareleri) kullanılabilir (şekil 3.9).



Şekil 3.9 QRS detektörü için basit kalıp uydurma şekli

3.5.1.2 Düzey Sınırlaması Yöntemi

Bu yöntemde kalıp bellidir. Yöntem çeşitli dalga formlarına uyarlanabilir, esnektir.

$\hat{G}\hat{s}(k)$ → Kalıp

$\hat{G}$ → Kalıp kazancı

$L^+(k), L^-(k)$ → Toleranslar

$s^+(k) = \hat{G}\hat{s}(k) + L^+(k)$ → Üst sınır

$s^-(k) = \hat{G}\hat{s}(k) - L^-(k)$ → Alt sınır

M: Kalıptaki örnek sayısı

$\underline{x}(k) = [x(k), x(k-1), \dots, x(k-M+1)]^T$ → Gözlem vektörü

$\underline{s}^+ = [s^+(M), s^+(M-1), \dots, s^+(1)]^T$ → Üst sınır vektörü

$\underline{s}^- = [s^-(M), s^-(M-1), \dots, s^-(1)]^T$ → Alt sınır vektörü

Her k anında, gözlem vektörü sınır vektörleriyle karşılaştırılır. Dalga formu

$$\underline{s}^- \leq x(k) \leq \underline{s}^+ \quad (3.6)$$

için mevcuttur. $x(k)$ bu eşitliği sağlamıyorsa; $x(k+1)$ vs. için işlemler tekrar edilir (şekil 3.10).



Şekil 3.10 QRS detektörü için düzey sınırlaması örneği

$L^+(k)$ ve $L^-(k)$ sınırları büyük seçilirse gürültü artar, FP sayısı artar; sınırlar küçük seçilirse doğru sınıflama sayısı azalır, FN artar. Dalga-formunun varlığı; sınırlar arasında kalan örnek sayısının, M değerinin % 90'ının altında kalması şartına bağlanabilir. Bu, gürültüye olan duyarlılığı azaltır. Burada eşik tekniği uygulanabilir:

$$\text{Eşik} = 0.90 M \text{ seçilirse} \quad (3.7)$$

Gözlem penceresinde sınır değerler arasında kalan işaret sayısı $>$ Eşik

için dalga-formu mevcuttur.

3.5.2 Yapısal Öznitelik Arama

Amaç; dalga-formunun kalıbı tam olarak belli olmadığından, kalıp yerine dalga-formuna ait bir takım yapısal özelliklerden yararlanmak; basit yapısal analiz yardımıyla gürültülü işaret içindeki dalga formlarını detekte etmektir.

İşaret içinde, bazı ortak yapıya sahip dalga formları:

$$s_i(t) ; i = 1, 2 \quad (3.8)$$

Dalga formuna örnek olarak EKG işaretindeki QRS kompleksi verilebilir. QRS kompleksi, her kişide aynı değildir; ancak yapısal olarak benzer karaktere ve Q, R ve S dalgaları belli bir yapısal değişime sahiptir.

$n(t)$: Toplamsal gürültü,

$m(t)$: Çarpımsal gürültü,

$s(t)$: Esas işaret

$x(t)$: Gözlenen işaret (gözlem işareti) iken gözlem işaret modeli

$$x(t) = m(t) \cdot [s(t) + n(t)] \quad (3.9)$$

Örneğin $m(t)$, EKG işaretinde solunum gürültüsü modülasyonu olabilir. Bazı durumlarda $m(t)$ çarpımsal gürültüsü yok kabul edilebilir, $m(t) = 1$. Bu durumda gözlenen işaret, aşağıdaki şeklini alır:

$$x(t) = s(t) + n(t) \quad (3.10)$$

Dalga-formu analizi açısından, i. gözlem penceresi içinde; $s_i(t)$, dalga-formu olmak üzere gözlem işareti:

$$x_i(t) = [s_i(t) + n_i(t)] \quad (3.11)$$

Ayrık zaman ifadeleriyle gözlem işareti:

$$x_i(k) = [s_i(k) + n_i(k)] \quad (3.12)$$

Dalga-formunun kalıbı tam olarak bilinmemektedir. Bunun yerine dalga-formuna/formlarına ait genlik ve birbiri peşisıra gelen belli dalga şekilli yapılanmalar gibi bir takım yapısal özelliklerden yararlanılır.

3.6 Yapay Sinir Ağlarının Sınıflayıcı Olarak Kullanımı

Yapay sinir ağlarının literatürde sınıflama amacıyla sıkça kullanıldığı gözlenmektedir. Ancak genel olarak ağların bir uzaydan diğer bir uzaya geçiş amacıyla kullanıldığı söylenebilir [28]. Eğitim kümesindeki vektörler kullanılarak iki uzay arasındaki lineer olmayan transfer fonksiyonuna adım adım yaklaşılr.

Yapay sinir ağlarının sınıflayıcı olarak kullanılmasının nedenlerini başlıca 5 kısma ayırabiliriz: 1) Eğitim kümesindeki vektörler kullanılarak sonuca adım adım yaklaşılr; 2)Eğitim kümesinde bulunmayan giriş vektörlerine uygun cevap üretilir (genelleme yeteneği); 3)Literatürde geliştirilmiş çoğu ağ fiziksel olarak kolaylıkla gerçekleştirilebilir; 4)Ağlar paralel bir yapıya sahip olduğu için sınıflama işleminde hızlı cevap üretir; 5) Ağlar, kompleks sınıf dağılımlarını temsil edebilme yeteneğindedir.


4. YAPAY SİNİR AĞLARI

4.1 Yapay Sinir Ağının Tanımı

Yapay sinir ağları (YSA) insan vücudundaki sinir hücrelerinin çalışmasını taklit etmek üzere tasarlanmıştır [29]. YSA'lar, deneyime dayalı bilgiyi saklamak ve kullanmak üzere biraraya getirilmiş, çok yoğun, paralel ve dağıtılmış işlemcilerden oluşur. İki açıdan beyne benzerler:

1. Bilgi ağ tarafından bir öğrenme süreci sonunda edinilir.
2. YSA düğümleri arasındaki bağlantılar (sinaptik ağırlıklar), bilgiyi saklamakta kullanılır.

Bir YSA'da işlem yapan hücelere nöron adı verilir. Nöronlar, birbirlerine insan sinir sistemi hücrelerinin birbirleriyle yaptığı sinaptik bağlantılara benzer şekilde bağlıdırlar (şekil 4.1- [30, s.11]).



Şekil 4.1 Bir nöronun nonlineer modeli

Bir nöronun modelinin üç temel belirleyici elemanı vardır [30]:

1. Her biri kendine ait ağırlık veya kuvvetle karakterize edilmiş bağlantılar kümesi. k nöronuna bağlı j sinapsinin girişindeki x_j işareti w_{kj} ağırlığıyla çarpılır. Beyindeki sinapslerin aksine bir yapay nöronun sinaptik ağırlığı negatif ile pozitif değerler arasında değişebilir.
2. Nörona ait sinapslerin ağırlıklarıyla çarpılmış giriş işaretlerinin toplanması için bir toplayıcı.
3. Nöronun çıkışındaki işaretin genliğini sınırlandırmak için bir transfer (aktivasyon) fonksiyonu.

Şekil 4.1'deki nöron modelinde b_k ile gösterilen kutuplama işareti de bulunmaktadır. b_k işareti, değerinin pozitif ya da negatif olmasına göre transfer fonksiyonunun net girişini artırıcı veya azaltıcı yönde etki eder.

Nöronların çalışması genel olarak şöyle formüle edilebilir[31]:

$$\alpha = \sum_{i=0}^{n-1} W_i X_i \quad Y = f(\alpha - \theta) \quad (4.1)$$

X_i ve W_i , sırasıyla girişleri ve bunlarla ilişkili ağırlıkları, n giriş sayısını göstermektedir. Y çıkışı, α ile θ eşik değerinin fonksiyonu olarak ifade edilir. f , genellikle nonlinear olan transfer fonksiyonudur.

Transfer fonksiyonu; bir nöronun çıkışını, etkilediği yerel v bölgesine bağlı olarak tanımlar (şekil 4.2-[30, s.13]). En çok kullanılan transfer fonksiyonları şunlardır:

1. Eşik fonksiyonu:
$$f(v) = \begin{cases} 1 & v \geq 0 \\ 0 & v < 0 \end{cases}$$

Bu transfer fonksiyonuyla işlem gören bir nöronun çıkışı ise şöyle olur:

$$y_k = \begin{cases} 1 & v_k \geq 0 \\ 0 & v_k < 0 \end{cases} \quad v_k = \sum_{j=1}^m w_k x_j + b_k \quad (4.2)$$


Burada v_k , nöronun etkilediği yerel bölgeyi göstermektedir.

2. Parçalı doğrusal fonksiyon: $f(v) = \begin{cases} 1, & v \geq +\frac{1}{2} \\ v, & +\frac{1}{2} > v > -\frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases}$

3. Sigmoid fonksiyon: YSA'ların yapısında en çok kullanılan transfer fonksiyonu türüdür. Bu fonksiyon, doğrusal ve doğrusal olmayan davranışlar arasında bir denge kurar. Bu tür fonksiyonlara bir örnek, lojistik fonksiyonudur:


$$f(v) = \frac{1}{1 + \exp(-av)} \quad (4.3)$$

a, fonksiyonun eğimini gösteren katsayıdır. Bunu değiştirerek değişik eğimlere sahip fonksiyonlar elde edilebilir. Diğerlerinin aksine sigmoid fonksiyonu, 0 ile 1 arasında değerler alır ve türevi vardır.



Şekil 4.2 En sık kullanılan transfer fonksiyonları a) eşik fonksiyonu b) parçalı doğrusal fonksiyon c) sigmoid fonksiyon

Nöron ve transfer fonksiyonu bu şekilde tanımlandıktan sonra yapay sinir ağının diğer bir tanımı şöyle verilebilir:Yapay sinir ağı, birbirleri ile sinaptik bağlantılar yapmış ve transfer fonksiyonlarıyla ilişkilenmiş düğümlerden oluşan yönlü bir graftır (şekil 4.3 - [30, s.17]).



Şekil 4.3 Bir nöron modelinin işaret akış diyagramı

1. Her nöron bir lineer sinaptik bağlantılar kümesi, bir kutuplama işareti ve (çoğunlukla nonlinear) bir transfer fonksiyonu ile temsil edilir. Kutuplama işareti, +1 olarak sabitlenmiş bir girişe yapılan sinaptik bağlantıyla temsil edilir.
2. Bir nöronun sinaptik bağlantıları, o nörona ait giriş işaretlerini ağırlıklandırır.
3. Giriş işaretlerinin ağırlıklandırılmış toplamı, nöronun harekete geçirdiği yerel bölgeyi belirler.
4. Transfer fonksiyonu, nöronun harekete geçirdiği yerel bölgeyi bir çıkış işareti oluşturmak üzere etkiler.

Bir nöronun durumu harekete geçirdiği yerel bölge veya nörona ait çıkış işaretiyle belirlenebilir.

4.2 YSA Mimarileri

Genel olarak üç temel ağ mimarisi tanımlanabilir:

1. Tek katmanlı ileri beslemeli ağlar: En basit katmanlı ağ yapısında, bir giriş katmanı ve bunun bağlı olduğu nöronlardan oluşan bir çıkış katmanı bulunur. İşaret akışı, girişten çıkışa doğru tek yönlüdür. Tek katmandan kastedilen, çıkış katmanı nöronlarıdır çünkü giriş katmanında hesaplama yapılmaz.

2. Çok katmanlı ileri beslemeli ağlar: Giriş ve çıkış katmanları arasında saklı katmanlar bulunur. Saklı katman eklenmesiyle ağın yüksek dereceden hesaplamalar yapması sağlanır.

3. Tekrarlı (recurrent) ağlar: Bir tekrarlı ağın ileri beslemeli ağlardan farkı, en az bir geri besleme döngüsüne sahip olmasıdır. Tekrarlı ağlarda da saklı katmanlar bulunabilir. Geri besleme döngülerinin varlığı, ağın öğrenme yeteneğini geliştirir.

4.3 Yapay Sinir Ağlarında Öğrenme


Öğrenme; bir yapay sinir ağının bağımsız parametrelerinin, ağın içinde bulunduğu çevrenin etkilerinden oluşan bir sürecin sonucunda ortamın yeni durumuna uyarlanmasıdır.

Eğitim aşaması bir YSA uygulamasının niteliğini belirleyen etkenlerin başında gelir. Eğer eğitim kümesi yeterince geniş değilse; ağ, kendini tüm sınıflara ait örnekleri tanıyacak şekilde ayarlamak yerine mevcut eğitim kümesini ezberlemekle yetinebilir. Ağın eğitimi için kullanılan veriler, tüm öznitelik uzayını temsil edebilir nitelikte olmalıdır. Eğitim için kullanılan örneklerin ağa rasgele sunulması da önemlidir. Bir YSA, eğitim kümesinin tamamı üzerinden genelleme yapabilmeli, her seferinde tek bir sınıf ile ilgilenmemelidir.

Öğrenmenin türü, parametre değişikliğinin ne şekilde gerçekleşeceğiyle belirlenir. Öğrenme, eğitici ve eğitici olmayan olmak üzere iki türdür:

4.3.1 Eğitici Öğrenme

Eğitici öğrenmede, eğitici ortam hakkında bilgiye sahiptir. Eğitilen sistem ise ortam hakkında bilgiye sahip değildir. Eğitilen sisteme ilişkin ağırlıklar eğitim kümesi aracılığıyla değiştirilir. Sonuçta eğitimin ortam hakkında sahip olduğu bilgi eğitilen sisteme aktarılmış olur (şekil 4.4-[30, s.63]).



Şekil 4.4 Eğitici öğrenme

4.3.1.1 Geri Yayılım Algoritması

Eğitici öğrenmenin en yaygın uygulanan türü geri yayılım (back propagation–BP) algoritmasıdır. Biyomedikal işaretlerin işlenmesi amacıyla geliştirilmiş pek çok uygulama bu yöntemi kullanır. BP algoritması iki aşamadan oluşur:

İleri fazı: Ağın serbest parametreleri ayarlanır ve giriş işareti ağ boyunca katman katman ilerletilir. İleri fazı hata işaretinin hesaplanmasıyla sona erer:

$$e_i = d_i - y_i \quad (4.4)$$

Burada d_i arzu edilen çıkışı ve y_i de x_i girişine karşılık elde edilen çıkışı gösterir.

Geri fazı: Bu faz sırasında bulunmuş olan hata işareti e_i ağ boyunca geri yönde ilerletilir. Bu aşamada e_i işaretini minimize etmek üzere ağın serbest parametrelerine ilişkin ayarlamalar yapılır.


4.3.2 Eğitici­siz Öğrenme

Eğitici­siz öğrenmede, öğrenme işleminin her adımında istenilen yanıt sağlayan eğitici yoktur. Eğitilen sistem, sonuçta elde edilecek yanıtı açacak her etkiyi oluşturmak, eleştiriye göre yorumlamak zorundadır. Girişlerin istatistiksel düzenini belirledikten sonra sınıflamayı başaracak beceriyi sistem kendisi oluşturur. Ağın sinaptik ağırlıklarının ayarlanması Hebb öğrenmesi veya yarışmalı öğrenme gibi nörobiyolojik ilkelerle gerçekleştirilir.

4.4 Denetimli Yapay Sinir Ağları

4.4.1 Çok Katmanlı Algılayıcı

BP algoritması, özellikle çok katmanlı algılayıcı (ÇKA) olarak bilinen ileri beslemeli ağların tasarımında kullanılmıştır. Çok katmanlı algılayıcıda giriş ve çıkış katmanları, ağı dış dünyaya bağlar. Bu iki katmana ek olarak bir veya daha fazla sayıda gizli nöron katmanları bulunmaktadır (şekil 4.5 [32, s.38]). Gizli nöronlara giriş veya çıkış katmanlarından doğrudan ulaşamadığı için bu adı almışlardır. Saklı katmanın görevi, giriş verisinin içerdiği önemli öznitelikleri çıkarmaktır.



Şekil 4.5 Çok katmanlı algılayıcının yapısı

I^0 ve O^0 , sıfırıncı seviyedeki giriş ve çıkış vektörünü tanımlar. Bu iki vektör, giriş katmanında birbirlerine eşittir.

$$\begin{aligned} \bar{I}^0 &= (I_1^0, I_2^0, \dots, I_{n0+1}^0) & I_{n0+1}^0 &= 1 \\ \bar{O}^0 &= (O_1^0, O_2^0, \dots, O_{n0+1}^0) & \bar{I}^0 &= \bar{O}^0 \end{aligned} \quad (4.5)$$

$n0$ değeri ağı girişindeki düğüm sayısını gösterir. Birinci katmandaki giriş ve çıkış arasındaki ilişki şöyledir:

$$\bar{I}^1 = (I_1^1, I_2^1, \dots, I_{n1}^1) \quad I_j^1 = \sum_{i=1}^{n0-1} w_{ji}^1 \cdot O_i^0 \quad (4.6)$$

w_{ji}^1 , sıfırıncı katmandaki i. düğüm ile 1. katmandaki j. düğüm arasındaki bağlantıyı; $n1$ ise 1.saklı katmandaki düğüm sayısını göstermektedir. Saklı katmanın çıkışı aşağıdaki gibidir:

$$\bar{O}^1 = [F(I_1^1), F(I_2^1), \dots, F(I_{n1}^1)] \quad O_{n1+1}^1 = 1 \quad F(x) = \frac{1}{1 + e^{-x}} \quad (4.7)$$

Çıkış katmanındaki giriş-çıkış ilişkisi ise

$$\bar{I}^\zeta = (I_1^\zeta, I_2^\zeta, \dots, I_{n\zeta}^\zeta) \quad I_j^\zeta = \sum_{i=1}^{n\zeta+1} w_{ji}^\zeta \cdot O_i^{\zeta-1} \quad \bar{O}^\zeta = [F(I_1^\zeta), F(I_2^\zeta), \dots, F(I_{n\zeta}^\zeta)] \quad (4.8)$$


şeklindedir. $n\zeta$, çıkış katmanındaki düğüm sayısını; ζ ise çıkış katmanını göstermektedir.

Ağın eğitiminde BP algoritması iki şekilde kullanılmaktadır: Ardışıl modda ağın bağımsız parametreleri her örnek için yeniden ayarlanır. Bu mod örüntü sınıflanmasında en iyi sonuç veren yöntemdir. Dönemsel (batch) modda ise ağın bağımsız parametreleri dönemler halinde ayarlanmakta ve her dönem eğitim kümesinin tamamını içermektedir. Bu mod, nonlinear kestirimlerde en iyi sonuçları verir.

4.4.2 Radyal Taban Fonksiyonlu (RTF) Ağlar

RTF ağları, hafızaya dayalı bir öğrenme yöntemiyle eğitilir (şekil 4.6-[29, s.57]). Öğrenme, çok boyutlu uzayda bir eğri uydurma problemi olarak görülebilir:

1. Öğrenme, çok boyutlu uzayda eğitim kümesine en iyi uyan yüzeyi bulmaya eşdeğerdir.
2. Genelleme (ağın önceden karşılaşmadığı giriş verisine cevabı), bu çok boyutlu yüzeyin test verisini işlemek için kullanımına eşdeğerdir.



Şekil 4.6 RTF ağı

RTF ağları ile ÇKA ağları arasındaki temel farklar şöyledir:

1. RTF ağları yerel, ÇKA ağları ise global yaklaşım yapar.
2. RTF ağlarında tek bir gizli katman varken ÇKA ağlarında gizli katman sayısında bir sınırlama yoktur.
3. Bir RTF ağının çıkışı daima lineerdir. ÇKA ağında çıkış lineer veya nonlinear olabilir.
4. Bir RTF ağında saklı katmanın aktivasyon fonksiyonu, giriş işaretinin vektörü ile ağa ait bir parametre vektörü arasındaki Öklid mesafesini hesaplar. Bir ÇKA ağında ise aktivasyon fonksiyonu, giriş işaret vektörü ile sinaptik ağırlık vektörünün iç çarpımını hesaplar.

RTF ağının örüntülerin ayrılması açısından yaptığı iş Cover teoremi ile açıklanabilir. Buna göre; giriş uzayından öznitelik uzayına (gizli katmana) yapılan dönüşümler nonlinear olduğunda ve öznitelik uzayının boyutu giriş uzayının boyutundan büyük olduğunda, giriş uzayında ayrıştırılabilirliği düşük olan bir örüntü sınıflama işleminin öznitelik uzayında lineer olarak ayrıştırılabilir bir işleme dönüşmesi kuvvetle muhtemeldir.

4.4.3 GAL Ağı

Artma yöntemini kullanan öğrenme (incremental learning) algoritmaları (şekil 4.7- [33, s.6]), ağ yapısını yeni düğümler ve bağlantılar ekleyerek veya çıkararak değiştirirler. GAL algoritması [33], bu yöntemi kullanır. Eğitim sırasında tek seferde


bir giriş uzayı öğrenilir; unutmada ise ağı karmaşıklığını azaltmak için en son değişiklikler sonucunda artık gereksiz olan düğümler kaldırılır. YSA uygulamalarında yaygın olarak öğrenme sırasında ağı düğümlerinin ve mimarisinin ne olacağına tasarımcı tarafından deneme-yanılma yöntemiyle karar verilmektedir. GAL ağında ise ağı mimarisini ve düğümlerin neler olacağını öğrenme algoritması kendisi belirler.



Şekil 4.7 Artma yöntemini kullanan öğrenme algoritmaları

Ağı eğitimi için harcanan süre bir yapay sinir ağı uygulamasının maliyetini belirleyen en önemli faktörlerden biridir. İteratif algoritmalar sonuca ulaşmak için çok sayıda iterasyona gereksinim duyarlar ve bu nedenle gerçek zamanlı çalışamazlar. GAL algoritması, ağı geçmişte edinmiş olduğu bilgiye zarar vermeden gerekli değişiklikleri tek seferde yapan ve elemanları tam olarak bağlantılı bir yapay sinir ağıdır ve bu nedenle gerçek zamanlı çalışmaya uygundur.

GAL ağı, iki katmandan meydana gelir (şekil 4.8 [33, s.9]). Giriş katmanının ardından gelen katmanda öğrenilecek kalıplar (prototipler); çıkış katmanında ise sınıfları gösteren elemanlar bulunur. W_e e birimine ait ağırlık vektörünü, T_{ec} e kalıbından c sınıfına olan bağlantıyı gösterir. P giriş vektörü için e kalıbına ait aktivasyon fonksiyonu, A_e , P ile W_e arasındaki uygun bir $D(\cdot)$ metriğine göre hesaplanan mesafedir. Kazanan hepsini alır kuralına göre kalıba en yakın mesafede bulunan giriş seçilir. T_{ec} değerleri, e'nin c sınıfına ait bir kalıp olup olmamasına göre 0 veya 1 olur. Ağı düğümlerinin yapısı aşağıdaki denklemle ifade edilir.



Şekil 4.8 GAL ağının yapısı

$$\forall e, A_e = D(P, W_e)$$

$$E_e = \begin{cases} 1, & A_e = \min_i (A_i) \\ 0, & \text{aksi takdirde} \end{cases} \quad \text{Çıkış katmanı} = C_c = \sum_e E_e * T_{ec} \quad (4.9)$$

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

Bu yapı, giriş uzayını en yakın komşuluk kuralına göre bölümlere ayırır. Kalıp birimlerinin etki alanı, iki en yakın kalıp biriminin ortalamasından geçen hiperdüzlemlerle sınırlanır. Bir sınıfın etki alanı ise o sınıfa ait kalıpların etki alanlarının birleşimidir.

4.4.3.1 GAL Ağının Öğrenme Fazı


Başlangıçta sınıf ya da kalıp birimi yoktur; bunlar eğitim sırasında eklenir ve W ile T değerleri ayarlanır. c sınıfına ait bir P girişi ağa verildiğinde ağın cevabı denklem 4.10'daki gibi hesaplanır. Eğer cevap doğruysa bir değişiklik yapılmaz. Aksi takdirde yeni bir kalıp düğümü yaratılır ve gelecek sefer aynı giriş ile karşılaşıldığında en yakın komşuluğu verebilmesi için yeni yaratılan düğümün ağırlığı giriş vektörüne eşit alınır. Daha sonra kalıp birimi ile doğru sınıf birimi arasındaki bağlantı 1 yapılır. Eğer bu sınıfla ilk kez karşılaşıyorsa yeni bir sınıf olarak ağa eklenir.

$$W_e = P \quad \forall o, T_{eo} = \begin{cases} 1, & 0 = c \text{ ise} \\ 0, & \text{aksi takdirde} \end{cases} \quad (4.10)$$

İterasyon sayısına bağlı olarak kalıpların sayısı artmakta, ancak hata yüzdesi azalmaktadır. Başlangıçta hatalı sınıflamaları düzeltmek amacıyla çok sayıda kalıp eklenmekte fakat iterasyon sayısı arttıkça ağ daha sık olarak doğru cevap vermekte ve eklemelerin sayısı azalmaktadır.

4.4.3.2 GAL Ağının Unutma Fazı

GAL algoritması, eğitim kümesindeki giriş örüntülerinden sınıf sınırlarına en yakın olanlarını saklar. Ancak hangi giriş örüntülerinin kalıp olarak saklanacağı ve bunların sayısı, öğrenme esnasında ağın bu girişlerle karşılaştığı sıraya bağlıdır. Daha önce saklanmış bir kalıp, sınıra daha yakın bir kalıp ağa eklendiğinde gereksiz hale gelir (şekil 4.9-[33, şekil 11]). Böyle düğümler artık aynı sınıfa ait başka bir düğümün etki alanında bulunduklarından ağın karmaşıklığını azaltmak için elenebilirler.



Şekil 4.9 Daha önce saklanmış olan A düğümü, C'ye daha yakın olan B düğümünün ortaya çıkmasıyla gereksiz hale gelir.

Eleme işlemini gerçekleştirmek amacıyla unutma fazı uygulanır. Kalıplardan biri geçici olarak ağdan çıkarılır ve ağa giriş olarak verilir. Eğer ağın cevabı giriş vektörünün sınıfı ile aynı ise giriş olarak alınan düğüm gereksizdir ve ağdan kaldırılabilir.

Bu strateji ile düğümlerin etki alanına giren tüm noktalar yerine yalnızca kalıp düğümleri kontrol edildiğinden hatanın artması mümkündür. Artan hatayı kompanse etmek için birbiri ardına öğrenme ve unutma fazları kullanılır. Öğrenme sırasında hata azaltılırken, unutma sırasında ağın boyutu indirgenir. Birkaç tekrardan sonra GAL ağı, yeni eklemeler gerektirmeyecek şekilde eğitim kümesini temsil eder hale

gelir. Tüm kalıp düğümleri sınıf sınırlarına en yakın noktalara yerleştiklerin artık düğüm çıkarmak da mümkün değildir, yani ağ kararlı hale gelmiştir.

4.4.3.3 GAL Ağının Olumlu ve Olumsuz Yanları

Mevcut GAL ağının yapısını değiştirmenin tek yolu yeni bir kalıp eklemektir. Yeni bir kalıp eklendiğinde değişiklik yapmanın tek yolu ise unutma fazında bu kalıbı ağdan çıkarmaktır. Bunun dışında ağdaki bağlantı ağırlıkları değiştirilmez. Bunun avantajları şöyledir:

1. Ağda değişiklik yapmak çok basit olduğundan öğrenme çok hızlıdır.
2. Bağlantı ağırlıklarının değerlerini saklamak için gereken presizyon giriş örüntüsünü saklamak için gerekli olandan daha fazla değildir.


Dezavantajları ise şunlardır:

1. Yöntem, gürültüye karşı dayanıklı değildir. Giriş örüntülerinden veya eğiticiden kaynaklanan belli bir miktar gürültü varsa ağın cevabı önemli ölçüde bozulur.
2. Hiç gürültü olmadığında bile GAL tarafından bulunan sınırlar Bayes anlamındaki sınırlardan oldukça farklı olabilir.

4.5 Denetimsiz Yapay Sinir Ağları

4.5.1 Kohonen Ağı

Kohonen'in geliştirdiği öz-düzenleyen haritada (self organizing maps – SOM) nöronlar ızgara gibi dizilmiş bir çerçevedeki (lattice) düğümlerde bulunurlar. Nöronlar çeşitli giriş örüntülerine maruz kaldıklarında, yarışmalı öğrenme süreci sonunda yalnızca uyararla ilgili olanlar uyarılırlar (şekil 4.10). Nöronların çerçeve içindeki dizilişleri giriş örüntülerinin fiziksel özelliklerine bağlıdır ve beyindeki sinir hücrelerinin dizilişlerine benzer. Duyu organlarından beyne gelen uyarılar serebral korteksin farklı bölgelerine topolojik olarak düzenlenmiş bir şekilde iletilir.



Şekil 4.10 SOM algoritmasının nöronları uyarması

SOM algoritmasında bir komşuluk fonksiyonu, tüm ağı kapsamakla işe başlar ve yarışmalı süreci kazanan nöronu merkezine alacak şekilde, kazanan nörona ulaşılan dek kapsamını daraltır. Ağın içindeki düğümlerin yapısı aşağıdaki denklemle ifade edilir.

$$D_j = \sum_{i=1}^n (x_i - w_{ji}(k))^2 \quad E_e = \begin{cases} 1 & D_e = \min_j \{D_j\} \\ 0 & \text{aksi takdirde} \end{cases} \quad (4.11)$$

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

4.6 Yapay Sinir Ağlarında Bellek

YSA'nın önemli bir özelliği bilgiyi saklama şeklidir. YSA'da bellek dağıtılmıştır. Bilgi bağlantı ağırlıklarında saklanır. Ağırlıkların değerleri ağın o anki bilgi durumunu temsil eder. Örneğin; bir giriş/istenen çıkış çiftinin belirtilen bilgi parçası ağın içinde birçok bellek biçimine dağıtılmıştır. Bellek üniteleri ile diğer saklı bilgiler, bu bilgiyi paylaşırlar. Bazı YSA bellekleri ilişkilidir. Öyle ki, eğitilen ağa bir kısmı uygulanırsa, ağ bu girişe belleğindeki en yakın çıkışı bu giriş için seçer ve tam girişe bağlı çıkış ortaya çıkar. Eğer YSA öz-ilişkili ise kısmi giriş vektörlerinin ağa verilmesi bu girişlerin tamamlanması ile sonuçlanır.

YSA belleğinin yapısı; eksik, gürültülü ve tam seçilemeyen bir giriş uygulandığı zaman bile mantıklı çıkışlar üretmeye uygundur. Bu kurala genelleme adı verilir. Bir

genellenmenin kalitesi ve anlamı, uygulama çeşidine, ağın tipine ve karmaşıklığına dayanır. Lineer olmayan çok katmanlı ağlar (özellikle geriye yayılım ağları), gizli katmandaki özelliklerden öğrenirler ve bunları çıkışlar üretmek için birleştirirler. Gizli katmandaki bilgi, yeni giriş örüntülerine akılcı çözümler oluşturmak için kullanılabilir.

4.6.1 Bilginin Gösterimi

1. Benzer sınıflardan benzer girişler ağda benzer gösterimler oluşturmalı ve böylece aynı kategoriye ait olarak sınıflanmalıdır.
2. Farklı sınıflara ayrılacak nesnelere ağda çok farklı gösterimler atanmalıdır.
3. Belirli bir özellik önemli ise ağda onun gösterimi ile görevlendirilen hücre sayısı fazla olmalıdır.
4. Önceden belirli bilgi ve değişmez özellikler ağın tasarımı sırasında ağa yerleştirilmelidir. Böylece ağın tasarımı, bunları öğrenmek zorunda kalmayacağından basitleşir.

4.7 Hata Toleransı

Klasik hesaplama sistemleri küçük bir zarardan bile etkilenir. YSA'nın hata toleransı olduğundan durum farklıdır. YSA, paralel dağıtılmış parametrelili bir sistem olduğundan her bir işlem elemanı izole edilmiş bir ada olarak düşünülebilir. İşlem elemanlarının az da olsa zarar görmesi sistemin bütününe etkiler. Daha çok işlem elemanının zarar görmesiyle sistemin davranışı biraz daha değişir. Performans düşer ancak sistem hiçbir zaman durma noktasına gelmez.

YSA sistemlerinin hata toleranslı olmalarının nedeni, bilginin tek bir yerde saklanmayıp sisteme dağıtılmasıdır. Bu özellik sistemin durmasının önemli bir zarara neden olacağı uygulamalarda önem kazanır.

4.8 YSA Kullanımının Sebepleri

1. YSA'lar verilerden hareketle, bilinmeyen ilişkileri akıllıca hemen ortaya çıkarabilmektedir. Bu özellikleri, uygulama açısından son derece önemlidir. Ayrıca veri toplama için bir ön sorgulama ya da açıklama gerekmemektedir.

2. YSA'lar çözüm olarak genelleştirilebilir. Bir örnekten hareketle, diğer örneklerdeki benzerlikleri doğru olarak anlayabilirler. Genelleştirme yapılabilmesi bu bakımdan çok iyi bir özelliktir çünkü gerçek dünya verilerinde sürekli olarak gürültü ve bozucu etkiler mevcuttur.
3. YSA'lar lineer olmayan yapıdadır. Bu özellikleri nedeniyle daha karmaşık problemleri lineer tekniklerden daha doğru çözerler. Nonlineer davranışlar hissedilir, algılanır, bilinebilir, ancak bu davranışları ya da problemleri matematiksel olarak çözmek zordur.
4. YSA'lar son derece paralellığe sahiptir. Bağımsız işlemleri aynı anda çok hızlı yürütebilirler. Paralel donanımlar yapıları gereği YSA'lara uygun olduğundan kendisine alternatif çözüm metodlarından daha elverişlidir.

4.9 Yapay Sinir Ağlarının Klasik Yazılımlar ile Karşılaştırılması

YSA'lar tahmin, örnek değerlendirme ve gruplama işlemlerinde etkilidir. Aynı işlemleri klasik bir bilgisayar programı ile yapmak da mümkündür. YSA'lar kuralları açık ve belirli olmayan veya anında optimizasyon kısıtlamaları koyan uygulamalar için idealdir. Klasik programlarda ise belirli bir görev için yazılmış bir yazılım yıllarca aynı tip işi yapar.

Klasik bilgisayarların temel bir örneği olan Von Neumann makinası ile yapay sinir ağı arasındaki farklar Tablo 1'de görülmektedir.

Tablo 4.1 Yapay sinir ağları ile Von Neumann makinasının karşılaştırılması

Yapay Sinir Ağı	Von Neumann Makinası
Bağlantı ağırlıkları, eşik değerleri ve ağ yapısı değiştirilip, ayarlanarak eğitilir.	Programlanılır
Hafıza ve işlemci üniteleri ayrık değildir	Hafıza ve işlemci üniteleri farklıdır
Paralel (ayrık veya sürekli) ve asenkron çalışır	Seri, dijital ve senkron çalışır
Büyük boyutta fazla ünite içerdiği ve dağılmış olduğu için hataya toleranslıdır	Hataya toleranslı değildir
Öğrenme sürecinde özdenetimlidir	Yazılıma bağlıdır
Bilgi sinir hücrelerini birleştiren bağlantılarda saklanır ve adapte edilebilir	Bilgi adresle belirli hafızada saklanır
İşlem anarşiktir	İşlem otokratiktir
İşlem hızı milisaniyeler mertebesinde	İşlem hızı nano saniyeler mertebesinde

YSA'ların uygulamadaki dezavantajları ise şöyledir:

1. Bir problemin çözümünde çok uygun bir çözüm bulamayabilirler ve çözümde hata yapabilirler. Bunun nedeni, eğitim için uygun bir fonksiyon bulunmamasıdır. Fonksiyon bulunsa bile yeterli veri sağlanmayabilir.
2. Sonuç almak için çok fazla sayıda giriş örneğinin hesaplanması gerekebilir. Ayrıca hangi ağırlığın sonucu nasıl etkileyeceğini tahmin etmek zordur.
3. YSA'larla bir dizi işlem yapmak, bunları eğitmek yavaş ve pahalı olabilir. Maliyeti arttıran nedenlerden en önemlisi eğitim verilerinin elde edilmesi ve değerlendirilmesidir.
4. Bir YSA'nın niteliği ve kapasitesi uygulamadaki hızı ile orantılıdır; öyle ki düğüm sayısındaki az bir artış bile çalışma zamanında daha yüksek mertebeden bir artışa neden olur.

4.10 Biyolojik İşaretlerin YSA'lar ile Algılanması ve Sınıflandırılması

Biyomedikal işaretlerin işlenmesinde amaç, hastanın patolojik durumunu belirlemek ve durumundaki tedaviye bağlı değişiklikleri izlemektir. Biyopotansiyellerin, tıbbi görüntülerin, konuşma ve ses verilerinin, elektrokardiyografi, elektromiyografi, elektroensefalografi, elektrogastrografi gibi biyolojik işaretlerin işlenmesinde ve analizinde YSA'lar kullanılır. Algoritmik bir çözümün bulunamadığı veya çözümün zor elde edildiği durumlarda YSA kullanmak faydalıdır. Pek çok uygulamada YSA'lar diğer işaret ve görüntü işleme teknikleriyle birlikte kullanılır.

Biyomedikal alanda YSA uygulamaları üç ana kategoriye ayrılmıştır: işaret sıkıştırma, işareti kompanze etme ve yorumlama. Sıkıştırma, bir işaretin içerdiği tüm bilginin gizli katman nöronlarının transfer fonksiyonları cinsinden temsil edilebilmesidir. Eğer giriş sayısından daha az sayıda gizli katman nöronu varsa sıkıştırma gerçekleşmiştir. İşareti kompanze etmek için YSA gürültüsüz bir çıkış üretir veya işaretin taşıdığı bilginin arzu edilen kısmını güçlendirir. Yorumlama ise bir YSA'nın olayları ya da durumları normal veya patolojik rahatsızlık olarak sınıflandırmasıdır.

5. ARİTMİ SINIFLAMA YÖNTEMİ

Çalışmada yapay sinir ağı EKG vurularını sınıflamak amacıyla kullanılmıştır. Bu nedenle MIT-BIH EKG veri tabanından yararlanılmıştır.

5.1 MIT-BIH Veri Tabanı

MIT-BIH (Massachusetts Institute of Technology – Beth Israel Hospital Data Base) veri tabanında bulunan EKG kayıtları, Beth-Israel Hospital Aritmi Laboratuvarı tarafından 1975-1979 yılları arasında alınmış olan 4000’i aşkın uzun dönem Holter kayıtlarından oluşturulmuştur. Bu veri tabanında 48 adet EKG kaydı bulunmaktadır. Bu 48 kayıttan herbiri 30 dakika uzunluktadır.

EKG kayıtları yaşları 32-89 arasında değişen 25 erkek ve yaşları 23-89 arasında değişen 22 kadından alınmıştır. Hastaların tümüne iki farklı derivasyon uygulanmıştır. Kayıtların birçoğu II nolu standart bipolar derivasyonda alınmıştır. Diğer derivasyon ise çoğunlukla V1, bazen V2 veya V3, bir kayıta ise V4 derivasyonudur. Normal QRS kompleksleri genellikle II nolu standart bipolar derivasyonda alınan EKG işaretinde belirgin olarak gözlenir.

EKG işareti 360 Hz ile örneklenmiş olup ± 5 mV aralığında 11-bit çözünürlüğe sahiptir. Örnek değerleri 0-2047 aralığında değer alırlar ve 1024 değeri 0 V’a karşılık gelmektedir.

5.2 Yöntem

MIT-BIH veri tabanından ascii formatta elde edilen EKG işaretleri üzerinde çalışılmıştır. Her işaret için yalnızca bir derivasyon incelenmiştir. Sınıflama yöntemi olarak dalga formu deteksiyonu seçilmiştir. Vuruların belirlenmesinde kalıp uydurma tekniğinden yararlanılmıştır. Aritmileri sınıflara ayırmak için GAL ağı kullanılmıştır.

5.2.1 Kalıp Elde Etme

Çalışmada incelenen her EKG vuru tipi için o vuru tipine ait QRS kompleksi kalıp olarak kullanılmıştır. EKG kaydı içindeki ilgili QRS kompleksini seçme işlemi kullanıcı tarafından yapılmıştır.

R tepesine denk gelen örneğin yeri kalıp alma algoritmasına verilerek bu örnekten önceki 29 örnek ve sonraki 20 örnekten oluşan, toplam 50 örneklilik bir pencere kalıp olarak saklanmaktadır. Önce bu 50 örneğin ortalaması alınarak taban hattı düzeyi elde edilir. Daha sonra orijinal işaretten taban hattı düzeyi çıkarılır.

$$\begin{aligned} x_o &= \frac{1}{50} \sum_{i=1}^{50} x(n) \\ x_s(n) &= x(n) - x_o \end{aligned} \quad (5.1)$$

Elde edilen işaret R tepesine denk gelen örneğin (30. örnek) genliğine göre normalize edilir.


$$x_n(n) = \frac{x_s(n)}{x_s(30)} \quad (5.2)$$

Bu 50 örnek, ilgili vuruya ait kalıpların saklandığı bir matrisin bir satırını oluşturur. Her satırın 51. sütununda o vuru tipine verilen etiket bulunmaktadır.


Bu şekilde her vuru tipi için değişik EKG kayıtlarından toplam 10 adet kalıp alınmıştır. Böylece 10 satır $\times$ 51 sütundan oluşan kalıp matrisleri elde edilmiştir. Bu matrislerin saklandığı dosyalar GAL ağı için eğitim kümesini oluşturmak üzere kullanılmıştır. Kalıplara ait örnekler Ek A'da yer almaktadır.

5.2.2 Filtreleme

İncelenecek EKG kaydına ilk aşamada 360 Hz ile örneklenmiş işarettaki DC bileşenleri ve 60 Hz'lik şebeke gürültüsünü yok etmek üzere sayısal filtre uygulanmıştır (şekil 5.1-[27] şekil 11.54 a)-b)).



(a)



(b)

Şekil 5.1 60 Hz filtre a) frekans domeni b) z-domeni

$$\frac{Y(z)}{X(z)} = H(z) = 1 - z^{-6} \quad (5.3)$$

Sıfırlar $z = 1$ noktasından itibaren birim çember üzerinde 6 eşit aralıkla yerleşmiştir. Kutuplar, $z = 1$ ve $z = 0$ noktalarındadır. $z = 1$ noktası $w = 0$ frekansına, yani doğru gerilime karşı düşer.

$$Y(z) = X(z)(1 - z^{-6}) \quad (5.4)$$

z dönüşüm notasyonu kullanıldığında ayrık zaman ifadesi,

$$y(n) = x(n)(1 - z^{-6}) \quad (5.5)$$

$$y(n) = x(n) - x(n-6) \quad (5.6)$$

olarak elde edilir. Bu eşitlik, filtre çıkışının eski giriş ve çıkışlar cinsinden ardışıl olarak hesaplanabileceğini göstermektedir. Bu son eşitlikle elde edilen filtrenin uygulandığı işarete DC bileşenler ve 60 Hz gürültüsü bulunmamaktadır.

Filtrelenmiş işaretin karesi alınarak ortalamanın altında kalan bileşenlerin de hesaba katılması sağlanır.

$$v(n) = y^2(n) \quad (5.7)$$

Taban hattını elde etmek amacıyla orijinal işaretin ortalaması alınarak kendisinden çıkarılmıştır.

$$\begin{aligned} x_o(n) &= \frac{1}{N} \sum_{i=1}^N x(n) \\ x_s(n) &= x(n) - x_o(n) \end{aligned} \quad (5.8)$$

5.2.3 QRS Deteksiyonu

QRS deteksiyonu için önce R tepeleri elde edilmiştir. Bu nedenle filtrelenmiş işarete bir eşik uygulanmış ve eşiği geçen örnekler üzerinde işlem yapılmıştır. Eşik değeri çoğu kayıt için 14000'dir, bazı kayıtlarda ise 10000, 8000, ve hatta 2500 olmaktadır. Bunun nedeni, EKG işaretinin her hastada farklılık göstermesidir. Eşiği geçen ilk örneğin yeri bir listede saklanmış ve bundan sonraki 80 örnek boyunca göz kapama işlemi uygulanmıştır, yani bu 80 örnek için hiçbir işlem yapılmamıştır.

$$\begin{aligned} z(i) > THR &\Rightarrow k(j) = i \\ z(i) < THR &\Rightarrow z(i+80) \text{ ile devam et} \end{aligned} \quad (5.9)$$

Listenin uzunluğu, incelenen işaret içindeki toplam QRS sayısını verir. Sonraki aşamada eşiği geçen ilk örnekten ($k(i)$) önceki 50 ve sonraki 50 örnekten oluşan 100 örneklilik dizi incelenir. Eğer $k(i)$ 'den önceki 10 ve sonraki 10 örnekten oluşan dizinin

ortalaması pozitif ise 100 örneklilik dizinin maksimum genliğe sahip elemanı R tepesini verir. Aksi halde 100 örneklilik dizinin minimum genliğe sahip elemanı R tepesidir. Bu işlem sayesinde çeşitli EKG aritmilerinde ortaya çıkan ters dönmüş R dalgaları da detekte edilebilmektedir.

$$\begin{aligned} \frac{1}{20} \sum_{k(i)-10}^{k(i)+10} x_s(k(i)) > 0 &\Rightarrow k_{mak} = \max_i \{x|_{k(i)-50}^{k(i)+50}\} : R \text{ tepe sin in yeri} \\ \frac{1}{20} \sum_{k(i)-10}^{k(i)+10} x_s(k(i)) < 0 &\Rightarrow k_{mak} = \min_i \{x|_{k(i)-50}^{k(i)+50}\} : R \text{ tepe sin in yeri} \end{aligned} \quad (5.10)$$

Bu şekilde oluşturulan k_{mak} dizisinde R tepelerinin yerleri saklanmaktadır. Bu dizinin eleman sayısı, toplam QRS sayısını göstermektedir. R tepesinden önceki 29 ve sonraki 20 örnekten oluşan 50 örneklilik bir pencere (y_q) QRS kompleksi olarak elde edilir.

$$x_q = x|_{k_{mak}-29}^{k_{mak}+20} \quad (5.11)$$

5.2.4 Sınıflama İşlemi

Elde edilen QRS dizilerinin ortalaması alınarak orijinal QRS dizisinden çıkarılır. Böylece taban hattı düzeyinin etkisi ortadan kaldırılır.

$$\begin{aligned} x_{q-o} &= \frac{1}{50} \sum_{i=k_{mak}-29}^{k_{mak}+20} x_q(i) \\ x_{q-s}(n) &= x_q(n) - x_{q-o} \end{aligned} \quad (5.12)$$

y_q işareti R tepesinin genliğine göre normalize edilir.

$$x_{q-n}(n) = \frac{x_{q-s}(n)}{x_{q-s}(k_{mak})} \quad (5.13)$$

Bu şekilde elde edilen diziler GAL ağının eğitimi sonucu bulunan ağırlık matrisinin satırları ile karşılaştırılır. Ağırlık matrisinin her satırının ilk 50 elemanı ağın bir düğümünü, 51. elemanı ise bu düğümün sınıfını göstermektedir. Karşılaştırma

sonucu minimum mesafedeki ağ düğümünün sınıfı QRS kompleksinin sınıfı olarak atanır. Karşılaştırma ölçütü olarak öklid normu kullanılmıştır. w_i , ağın düğümlerini göstermek üzere,

$$D_i(x_{q_n}, w_i) = \|x_{q_n} - w_i\| = \sum_{k=1}^m (x_{q_n}(k) - w_i(k))^2$$

$$E_e = \begin{cases} 1 & D_e = \min_i \{D_i\} \\ 0 & \text{aksi halde} \end{cases} \quad (5.14)$$

$$C_c = \sum_e E_e \cdot T_{ec}$$

E_e , ağın birinci katmanındaki düğümlerin çıkışını; T_{ec} ise atanacak düğüme göre sadece 0 veya 1 değerini alan VEYA işlemini gösteren bağlantı katsayısını belirtmektedir.

5.3 GAL Ağının Sınıflama Sonuçları

Bu bölümde iki farklı sınıflama sonucu incelenmiştir.


1. Örnek öznitelik uzayı
2. EKG vuruları

Birinci araştırma GAL ağının genelleme yeteneğini, eğitim algoritmasının stratejisini ve öznitelik uzayında düğüm dağılımını görsel olarak incelemek için yapılmıştır. İkinci araştırma EKG işaretindeki aritmi vurularının analizi için gerçekleştirilmiştir. İki inceleme arasında bir bağlantı yoktur.

5.3.1 Örnek Öznitelik Uzayı

Örnek öznitelik uzayı, iki elemanlı 20×20 (400) vektörden oluşmaktadır. Eğitim kümesini oluşturmak üzere bu uzaydaki her bir sınıftan rasgele seçilmiş 100'er tane olmak üzere toplam 200 vektör alınmıştır. Test kümesi, 2 sınıfa ait rasgele seçilmiş toplam 200 vektörden oluşmaktadır (şekil 5.2).

Karşılaştırmada üç parametre dikkate alınmıştır: doğru sınıflama yüzdesi, eğitim ve sınıflama süresi ve ağın düğüm sayısı.




Şekil 5.2 Örnek giriş uzayı


Doğru sınıflama yüzdesi, ağın genelleme yapabilme özelliğini ifade etmektedir. Eğitim süresi, ağın eğitimi için geçen süreyi gösterir. Sınıflama süresi, test işleminin ne kadar zaman aldığını ve buna bağlı olarak yöntemin gerçek zamanlı olarak kullanılıp kullanılamayacağını ifade etmektedir. Ağın düğüm sayısı ise yapay sinir ağının karmaşıklığı hakkında bilgi vermektedir.

5.3.1.1 Örnek Öznitelik Uzayının Sınıflama Sonuçları


Örnek uzay, eğitim ve sınıflama sonuçları Şekil 5.3 a) – e) 'de görülmektedir. GAL ağı, sınıflamayı 16 düğüm ile gerçekleştirmektedir. Unutma fazından önceki düğüm sayısı ise 23'tür. Şekil 5.3 c)-d)'de görüldüğü gibi, unutma sonucu düğümler sınıf sınırlarına doğru kaymıştır. Ağın eğitim süresi 1.42 s'dir. Ağın sınıflama süresi 0.22 s'dir. Eğitim algoritmasının iterasyon sayısı 150'dir. Bu ağırlık matrisi ile ağ, giriş örnek uzayını %87,5 oranında doğru sınıflamıştır.




Şekil 5.3 a) İki sınıflı örnek uzay




Şekil 5.3 b) H Eğitim ve v test kümeleri



Şekil 5.3 c) Unutmadan önceki düğümler



Şekil 5.3 d) Unutmadan sonraki düğümler



Şekil 5.3 e) Sınıflama sonucu

Şekil 5.3 GAL ağının örnek uzayı sınıflama sonuçları

Tablo 5.1 GAL ağının örnek giriş uzayını sınıflama sonuçları

Ağın düğüm sayısı	16
Ağın unutmadan önceki düğüm sayısı	23
Ağın eğitim süresi	1.420000 s
Doğru	175
Yanlış	25
Doğru sınıflama yüzdesi	%8.750000e+001
GAL ağının sınıflama süresi	0.220000 s

5.3.2 EKG Vuruları

Her EKG kaydı için yapay sinir ağı çıkışında QRS vurularına atanan sınıflar bir dosyada saklanmış ve bu dosya MIT-BIH veri tabanından elde edilen orijinal sınıfları gösteren dosya ile karşılaştırılmıştır. Her kayıta yalnızca bir derivasyon incelenmiştir. Bu şekilde sınıflamaya ilişkin duyarlık, doğru sınıflama kestirimi, TP, FP, FN değerleri hesaplanmıştır. Sonuçlar tablo 5.2’de görülmektedir. Tablodaki dosya adının ilk 3 rakamı incelenen kaydı, son 4 rakam ise dosyanın kaydın hangi bölümüne ait olduğunu göstermektedir.

Tablo 5.2 GAL ağının EKG vurularını sınıflama sonuçları

Dosya Adı	Toplam TP	Toplam FN	Toplam FP	Toplam Doğru %	Toplam Yanlış %	Sınıflama Duyarlığı	Doğru Sınıflama Kestirimi
100_0010	739	15	21	97.237	2.7632	0.9801	0.9724
101_0010	610	32	39	93.991	6.0092	0.9502	0.9399
102_1020	702	23	23	96.828	3.1724	0.9683	0.9683
103_2030	648	33	34	95.015	4.9853	0.9515	0.9501
104_1020	418	321	320	56.563	43.437	0.5656	0.5664
105_0010	810	23	27	96.774	3.2258	0.9724	0.9677
106_1020	557	166	166	77.04	22.96	0.7704	0.7704
107_0010	700	6	6	99.15	0.84986	0.9915	0.9915
118_2030	690	34	66	91.27	8.7302	0.953	0.9127
119_1020	647	17	17	97.44	2.5602	0.9744	0.9744
200_2030	787	33	49	94.139	5.8612	0.9598	0.9414
201_1020	424	94	109	79.55	20.45	0.8185	0.7955
202_0010	530	4	5	99.065	0.93458	0.9925	0.9907
203_2030	800	143	150	84.211	15.789	0.8484	0.8421
207_1020	642	1	0	99.844	0.15552	0.9984	1
208_0010	866	146	148	85.404	14.596	0.8557	0.854
209_2030	887	0	75	92.204	7.7963	1	0.922
210_0010	846	35	35	96.027	3.9728	0.9603	0.9603
212_0010	891	42	42	95.498	4.5016	0.955	0.955
213_1020	897	174	184	82.979	17.021	0.8375	0.8298
214_0010	710	51	59	92.328	7.6723	0.933	0.9233
215_1020	1095	19	19	98.294	1.7056	0.9829	0.9829
217_2030	683	39	40	94.467	5.5325	0.946	0.9447
219_2030	700	23	57	92.47	7.5297	0.9682	0.9247

GAL ağının eğitim kümesi her kaydın ilk 2 dakikalık bölümünde denenmiş ve uygun ağırlık matrisi bulunduğundan sonra kaydın kalanı incelenmiştir. %90’ın üzerinde başarı oranı veren ağırlık dosyaları kaydın kalanını sınıflamakta kullanılmıştır.

Vuruların ayrıntılı sınıflama sonuçları Ek B’de yer almaktadır. Genel olarak ağın %90’lar mertebesinde doğru sınıflama yaptığı gözlenmiştir. 100 ve 101 no’lu kayıtlarda çalışma içersinde incelenmeyen erken kulakçık virusu (PAC - A tipi vuru) bulunduğundan bu kayıtlar için ağın başarımı biraz düşük çıkmıştır. 102 no’lu kayıta sınıflandırılmayan vurular (Q tipi vuru) bulunmaktadır. Tez çalışmasında sınıflandırılmayan vurulara ilişkin bir düzenleme yapılmadığından bu kayıta başarım biraz düşüktür. 104 no’lu kaydı yüksek başarım ile sınıflayacak uygun ağırlık matrisi bulunamamıştır. 201 no’lu kayıta tez içerisinde incelenmeyen jonksiyonal (düğümsel) erken vuru (nodal (junctional) premature beat – J tipi vuru), jonksiyonal kaçış virusu (nodal (junctional) escape beat – j tipi vuru) ve A tipi vuru bulunmaktadır. Bu nedenle bu kayıt için ortalama başarım %80 civarındadır. 203 no’lu kayıta çok çeşitli vuru tipleri bulunmaktadır ve kayıt oldukça gürültülüdür. Bu nedenle bu kayda ilişkin ortalama başarım %80’dir. 207 no’lu kaydın özellikle son 10 dakikasında tez çalışmasında incelenmeyen A tipi vurular ve ventriküler flatır vuruları vardır. Bu tip vuruların bulunmadığı kısımdaki başarım %99.8’dir. Ağ, 208 no’lu kayıttaki çok çeşitli vuruları sınıflamakta hata göstermiştir. 209 no’lu kayıta çok fazla miktarda A tipi vuru bulunmaktadır.

Ağın performansının QRS komplekslerinin doğru deteksiyonundan çok etkilendiği gözlenmiştir. QRS deteksiyon algoritmasının hatalı sonuç verdiği bazı vurular yüzünden gerçek vuruların bulunduğu dosyayla karşılaştırma sırasında hatalar olabilmektedir. QRS detektörünün gürültüye karşı çok fazla bağışık olmadığı ve pik yapan bazı gürültü vurularını R tepesi olarak algıladığı gözlenmiştir.

QRS komplekslerinin yerleri doğru belirlendiğinde GAL algoritması oldukça yüksek başarım göstermektedir. R tepelerinin yerleri MIT-BIH veri tabanından alınarak yapılan sınıflamalarda oldukça yüksek başarım gözlenmiştir.

QRS deteksiyonu, ağın sınıflama süresini önemli ölçüde uzatmaktadır. Bu nedenle QRS detektörü kullanıldığında kaydın tümünü incelemek mümkün olmamıştır. Kayıt, 10’ar dakikalık bölümler halinde incelenmiştir. Ancak bu işlem yaklaşık 34 dk. sürmektedir. Kaydın ilk 2 dakikalık bölümünün sınıflandırılması ise yaklaşık 59 sn’de gerçekleştirilmiştir. İncelenen kayıt süresi uzadıkça sınıflama süresinin de üstel olarak uzadığı gözlenmiştir. Bu haliyle sınıflama algoritması gerçek zamanlı

alıřmaya uygun deęildir. QRS deteksiyonu algoritmasının daha hızlı alıřacak biimde deęiřtirilmesi gerekmektedir.

R tepelerinin MIT-BIH veri tabanından alındıęı durumda sınıflama iřlemi 10 dk'lık kayıtlar iin 7 sn kadar srmektedir. Bu haliyle GAL aęı, ok hızlı sınıflama yapmaktadır.

Aęın performansını etkileyen bir dięer unsur da kalıpların vuru tiplerini iyi temsil edebilir nitelikte olmasıdır. Her kayıttaki vuru tiplerinden kalıp alınırsa doęru sınıflama yapma řansı artacaktır. Ancak bu durum ok fazla sayıda kalıp alınmasını gerektirir ki bu da aęın eęitim ve sınıflama srelerini uzatır.

6. SONUÇLAR

Tez çalışmasında 9 tip EKG vurusu incelenmiştir. GAL ağının sınıflama performansına ilişkin ayrıntılı sonuçlar Ek B’de yer almaktadır.

A tipi vuru (erken kulakçık vurusu) yaygın gözlenmekle birlikte kalıp alma aşamasında seçilen 50 örneklik pencerenin bu vuru tipinin karakteristik özelliklerini temsil etmek için kısa kaldığı gözlenmiştir. A tipi vuru için oluşturulan kalıp vektörleri daima normal sınıfıyla karışmaktadır bu nedenle bu vuru sınıflamaya dahil edilmemiştir.

Kayıtlar çoğu durumda 10’ar dakikalık parçalar halinde analiz edilmiştir. Bunun nedeni, MATLAB ile geliştirilen algoritmanın cevap süresinin kayıt uzunluğu arttıkça üstel olarak artmasıdır. C veya C++ gibi makine işlemcisine daha hızlı erişen yazılım dillerinde cevap süresinin daha hızlı olacağı tahmin edilmektedir.

Algoritma, kaydın başındaki QRS kompleksi çok erken görülmüşse yakalayamamaktadır. Bunun nedeni, hem filtrelemekten hem de yapılan işlemlerden kaynaklanan gecikmedir. Ayrıca göz kapama süresi ve kalıp uzunluğu da etkili olmaktadır.

Bazı vurularda gözlenen düşük başarımlarının önemli nedenlerinden biri, kas gürültüsü veya elektrot hareketinden kaynaklan gürültü yüzünden oluşan piklerdir. Algoritma, bu pikleri de QRS kompleksi olarak algılamakta ve sınıflama sürecinde fazla sayıda vuru saklanmış olduğundan hatalar oluşmaktadır.

QRS deteksiyon algoritmasının incelenen diziler kısaltılarak daha hızlı hale gelebileceği düşünülmektedir. R tepesini bulurken maksimum veya minimum değer 100 örnek yerine daha kısa bir aralıkta aranması, işleme giren veri miktarını önemli ölçüde azaltacaktır. Ancak bu durumda yanlış algılama sayısı artacaktır. İşaretin eğimini de hesaba katan bir yöntemle bu sorunun üstesinden gelinebileceği tahmin edilmektedir.

Bazı kayıtlar için uygun sınıflamayı yapacak ağırlık matrisi oluşturulamamıştır. GAL ağının eğitim algoritması olasılığa bağlı çalıştığından uygun ağırlıkları bulmak için birden fazla denemek yapmak gerekebilir. Ayrıca kullanılan eğitim kümelerinde her sınıf için 10 farklı örnek saklanmıştır. Bunların sayısı artırıldığında sınıflayıcının performansı da artacaktır. Ancak yapılacak karşılaştırma sayısı da artacağından sınıflama süresi de bir miktar uzar.

Yapılan işlem miktarını azaltmak amacıyla oluşturulan 50 örneklik diziler $\frac{1}{2}$ oranında örneklenmiştir; yani 1 örnek al, 1 örnek bırak prensibiyle QRS kompleksini temsil etmek üzere 25 örneklik diziler ele alınmıştır. Kalıp vektörleri de aynı şekilde kısaltılmıştır. İndirgenmiş vektörler GAL ağına giriş olarak verilmiş ve ağın cevabı incelenmiştir. Örnek olarak incelenen kayda ilişkin sonuçlar tablo 6.1 (a)-(d)'de görülmektedir. Sonuçta önemli bir kayıp gözlenmemiştir. İleride daha düşük boyutlu giriş verileriyle çalışılabileceğine karar verilmiştir. Boyut indirgemesi yöntemi kullanıldığı takdirde P ve T dalgalarını da içine alan daha uzun bir pencerenin incelenebileceği düşünülmektedir. Böylece A tipi vuru ve kulakçık fibrilasyonu da dahil daha fazla sayıda vuru tipinin sınıflandırılabilmesi düşünülmektedir. Bu işlemlere ilişkin sonuçlar tablo 6.1 (a)-(d)'de görülmektedir.

Ölçüm sistemindeki farklı derivasyonların paralel olarak incelenmesi ve belli bir karar eşiğine göre sonuçların karşılaştırılması sınıflama performansını artırabilecek bir diğer yöntemdir. Ancak bu durumda yapılan işlem sayısı doğrudan 2 katına çıkacaktır.

Tablo 6.1 a) Normal sınıflama sonucu, süre = 2.0369e+003 s (QRS deteksiyonu ile)

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
119_0010 Gerçek	659	519	140	519	140	0	0	0	0	0	0	0
119_0010 Sonuç	659	510	149	510	140	0	0	9	0	0	0	0
Doğru Pozitif				510	140	0	0	0	0	0	0	0
Sahte Negatif				9	0	0	0	0	0	0	0	0
Sahte Pozitif				0	0	0	0	9	0	0	0	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı			Doğru Sınıflama Kestirimi				
650	9	9	98.634	1.3657	0.9863			0.9863				

Tablo 6.1 b) İndirgeme yönteminin sonucu, süre = 2.1318e+003 s (QRS deteksiyonu)

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
119_0010 Gerçek	659	519	140	519	140	0	0	0	0	0	0	0
119_0010 Sonuç	659	498	161	498	140	0	0	21	0	0	0	0
Doğru Pozitif				498	140	0	0	0	0	0	0	0
Sahte Negatif				21	0	0	0	0	0	0	0	0
Sahte Pozitif				0	0	0	0	21	0	0	0	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı	Doğru Sınıflama Kestirimi						
638	21	21	96.813	3.1866	0.9681	0.9681						

Tablo 6.1 c) Normal sınıflama sonucu, süre = 1.0500 s (orijinal QRS yerleri ile)

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
119_0010 Gerçek	659	519	140	519	140	0	0	0	0	0	0	0
119_0010 Sonuç	659	511	148	511	131	0	8	0	0	0	0	9
Doğru Pozitif				511	131	0	0	0	0	0	0	0
Sahte Negatif				8	9	0	0	0	0	0	0	0
Sahte Pozitif				0	0	0	8	0	0	0	0	9
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı	Doğru Sınıflama Kestirimi						
642	17	17	97.42	2.5797	0.9742	0.9742						

Tablo 6.1 d) İndirgeme yönteminin sonucu, süre = 6.4900 s (orijinal QRS yerleri ile)

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
119_0010 Gerçek	659	519	140	519	140	0	0	0	0	0	0	0
119_0010 Sonuç	659	511	148	511	131	0	8	0	0	0	0	9
Doğru Pozitif				511	131	0	0	0	0	0	0	0
Sahte Negatif				8	9	0	0	0	0	0	0	0
Sahte Pozitif				0	0	0	8	0	0	0	0	9
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı	Doğru Sınıflama Kestirimi						
642	17	17	97.42	2.5797	0.9742	0.9742						

İncelenen EKG kayıtlarının önemli bölümünde %90'lar mertebesinde sınıflama başarımı elde edilmiştir. Sonuçlar literatürdeki çalışmalarla karşılaştırıldığında tatmin edici bulunmuştur.

KAYNAKLAR


- [1] **Silipo, R. and Marchesi, C.**, 1998. Artificial neural networks for automatic ECG analysis, *IEEE Transactions on Signal Processing*, May, vol. 46, no.5, 1417-1425.
- [2] **Coast, D.A., Stern, R.M., Cano, G.G. and Briller, S.A.**, 1990. An approach to cardiac arrhythmia analysis using hidden markov models, *IEEE Transactions on Biomedical Engineering*, September, vol. 37, no. 9, 826-835.
- [3] **Stamkopoulos, T., Strintzis, M., Pappas, C. and Maglaveras, N.**, 1992. One-lead ischemia detection using a new backpropagation algorithm and the European ST-T database, *IEEE Computers in Cardiology*, 663-666.
- [4] **Frenster, J. H.**, 1990. Neural networks for pattern recognition in medical diagnosis, *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. 12, no. 3, 1423-1424.
- [5] **Silipo, R., Taddei, A. and Marchesi, C.**, 1994. Continuous monitoring a detection of ST-T changes in ischemic patients, *IEEE Computers in Cardiology*, 225-228.
- [6] **Bortolan, G., Degani, R. and Willems, J.L.**, 1992. ECG classification with neural networks and cluster analysis, *IEEE Computers in Cardiology*, 177-180.
- [7] **Silipo, R., Bortolan, G. and Marchesi, C.**, 1996. Supervised and unsupervised learning for diagnostic ECG classification, *18th Annual International Conference of the IEEE-EMBS*, paper no.1054.
- [8] **Silipo, R., Laguna, P., Marchesi, C. and Mark, R.G.**, 1995. ST-T segment change recognition using artificial neural networks and principal component analysis, *IEEE Computers in Cardiology*, 213-216.
- [9] **Coast, D.A.**, 1993. Segmentation of high-resolution ECGs using hidden markov models, *IEEE Conference on Acoustics, Speech and Signal Processing*, Minneapolis, USA, April 27-30, 67-70.
- [10] **Maglaveras, N., Stamkopoulos, T., Pappas, C. and Strintzis, M.**, 1998. ECG processing techniques based on neural networks and bidirectional associative memories, *Journal of Medical Engineering and Technology*, May/June, vol. 22, no. 3, 106-111.

- [11] **Bortolan, G., Silipo, R. and Marchesi, C.**, 1996. Fuzzy pattern classification and the connectionist approach, *Pattern Recognition Letters*, vol. 17, 661-670.
- [12] **Stamkopoulos, T., Diamantaras, K., Maglaveras, N. and Strintzis, M.**, 1998. ECG analysis using nonlinear PCA neural networks for ischemia detection, *IEEE Transactions on Signal Processing*, November, vol. 46, no. 11, 3058-3067.
- [13] **Minami, K., Nakajima, H. and Toyoshima, T.**, 1999. Real-time discriminations of ventricular tachyarrhythmia with Fourier transform neural network, *IEEE Transactions on Biomedical Engineering*, February, vol. 46., no. 2, 179-185.
- [14] **Vijaya, G., Kumar, G. and Verma, H.K.** , 1998. ANN-based QRS-complex analysis of ECG, *Journal of Medical Engineering and Technology*, July/August, vol. 22, no. 4, 160-167.
- [15] **Yang, T.-F., Devine, B. and Macfarlane, P.W.**, 1994. Artificial neural networks for the diagnosis of atrial fibrillation, *Medical and Biological Engineering and Computing*, November, 32, 615-619.
- [16] **de Chazal, P. and Celler, B. G.**, 1998. Selecting a neural network structure for ECG diagnosis, *20th Annual International Conference of the IEEE-EMBS*, Hong Kong, 1422-1425.
- [17] **Celler, B. G. and de Chazal, P.**, 1998. Low computational cost classifiers for ECG diagnosis using neural networks, *20th Annual International Conference of the IEEE-EMBS*, Hong Kong, 1337-1340.
- [18] **Gholam-Hosseini, H. and Nazeran, H.**, 1998. Detection and extraction of the ECG signal parameters, *20th Annual International Conference of the IEEE EMBS*, Hong Kong, 127-130.
- [19] **Yonghong, K., Jie, J., Yecho, H. and Zhicheng, L.**, 1998. Paced ECG analysis based on neural networks, *20th Annual International Conference of the IEEE-EMBS*, Hong Kong, 206-209.
- [20] **Tagluk, M. E. and English, M. J.**, 1997. The analysis of ECG signals using time frequency techniques, *19th International Conference of the IEEE- EMBS*, 1320-1323.
- [21] **Dokur, Z., Ölmez, T. and Yazgan, E.**, 1999. Comparison of discrete wavelet and Fourier transforms for ECG beat classification, *Electronics Letters*, September, vol. 35, no. 18, 1502-1504.
- [22] **Dokur, Z., Ölmez, T., Yazgan, E. and Ersoy, O.K.**, 1996. Detection of ECG waveforms by using artificial neural networks, *18th Annual International Conference of the IEEE-EMBS*, Amsterdam, paper no.1308.


- [23] Kalita, S., Belina, J., Tolani, M., Tankha, D., Everett, P. and Hahn, T., 1993. Effective ECG classification using single layer neural network with data pre-processing, *IEEE*, 734-735.
- [24] Har, J., Belina, J., Casas, R., Hashmi, A. and Mills, C., 1993. Neural network electrocardiogram classification through key feature extraction, *IEEE*, 727-728.
- [25] Szilagyi, M. S., 1998. Event recognition, seperation and classification from ECG recordings, *20th Annual International Conference of the IEEE-EMBS*, Hong Kong, 236-239.
- [26] Nizam, M., 2000. Mikrodnetleyici kontrollu çok kanallı elektrokardiyografi cihazı tasarımı, *Yüksek Lisans Tezi*, İ.T.Ü Fen Bilimleri Enstitüsü, İstanbul.
- [27] Yazgan, E. ve Korürek, M., 1996. Tıp elektroniği, İ.T.Ü., Elektrik-Elektronik Fakültesi, Ofset Baskı Atölyesi.
- [28] Ölmez, T., 2001. Makine Öğrenmesi ve Genetik Algoritmalar, ders notu.
- [29] Haykin, S., 2000. Neural networks: a guided tour, in *Nonlinear Biomedical Signal Processing*, vol. I , IEEE Press.
- [30] Haykin, S., 1999. Neural networks, a comprehensive foundations, Prentice Hall, Upper Saddle River, N.J.
- [31] Nazeran, H. and Behbehani, K., 2000. Neural networks in processing and analysis of biomedical signals, in *Nonlinear Biomedical Signal Processing*, vol. I, IEEE Press.
- [32] Dokur, Z., 1999. Yapay sinir ağları ve genetik algoritmalar kullanılarak ekg vurularının sınıflandırılması, *Doktora Tezi*, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.
- [33] Alpaydm, E., 1991. GAL: Networks that grow when they learn and shrink when they forget, *Technical Report, TR-91-032*, International Computer Science Institute, Berkeley, CA, USA.
- [34] Korürek, M., 2000. Biyomedikal Mühendisliğinde Özel Konular, ders notu.
- [35] MIT-BIH Arrhythmia Database, 1992. Available from Massachusetts Institute of Technology, 77 Massachusetts Avenue, Room 20A-113, Cambridge, MA 02139, USA.
- [36] Korürek, M., 2000. Biyolojik İşaretlerin İşlenmesi, ders notu.

EK A


Sınıflamada kullanılan EKG vurularına ait kalıp örnekleri:




Şekil A.1 N tipi vuru kalıbı




Şekil A.2 V tipi vuru kalıbı




Şekil A.3 L tipi vuru kalıbı




Şekil A.4 R tipi vuru kalıbı




Şekil A.5 a tipi vuru kalıbı




Şekil A.6 P tipi vuru kalıbı



 ekil A.7 f tipi vuru kalıbı



 ekil A.8 F tipi vuru kalıbı



 ekil A.9 E tipi vuru kalıbı

EK B

Aşağıdaki tablolarda GAL ağının çeşitli EKG kayıtlarındaki sınıflama sonuçları gösterilmiştir. Gerçek satırı, ilgili dosyanın MIT-BIH veri tabanındaki orijinal değerleri, sonuç satırı ise GAL ağının sınıflaması sonucunda bulunan değerleri gösterir. Her kayıt için, sınıflamada kullanılan yapay sinir ağına ait düğüm sayıları ayrıca tabloların üzerinde gösterilmiştir. Tablolar 10’ar dakikalık bölümlerin sonuçlarının toplanmasıyla oluşturulmuştur.

Tablo B.1 Düğüm sayısı: 24

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
100 Gerçek	2265	2231	34	2231	1	0	0	0	0	0	0	0
100 Sonuç	2265	2195	70	2195	0	1	5	64	0	0	0	0
Doğru Pozitif				2163	0	0	0	0	0	0	0	0
Sahte Negatif				68	1	0	0	0	0	0	0	0
Sahte Pozitif				32	0	1	5	64	0	0	0	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi					
2163	69	102	95.497	4.5033	0.9691		0.955					

Tablo B.2 Düğüm sayısı: 28

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
101 Gerçek	1864	1854	10	1854	0	0	0	0	0	0	0	0
101 Sonuç	1863	1711	152	1711	1	0	0	1	146	3	0	1
Doğru Pozitif				1708	0	0	0	0	0	0	0	0
Sahte Negatif				146	0	0	0	0	0	0	0	0
Sahte Pozitif				3	1	0	0	1	146	3	0	1
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi					
1708	146	155	91.68	8.3199	0.9213		0.9168					

Tablo B.3 Düğüm sayısı: 26

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
102 Gerçek	2180	99	2081	99	4	0	0	0	2023	54	0	0
102 Sonuç	2180	99	2081	99	7	10	1	0	2006	10	37	10
Doğru Pozitif				99	1	0	0	0	1963	7	0	0
Sahte Negatif				0	3	0	0	0	60	47	0	0
Sahte Pozitif				0	6	10	1	0	43	3	37	10
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi					
2070	110	110	94.954	5.0459	0.9495		0.9495					

Tablo B.4 Düğüm sayısı: 19

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
103 Gerçek	2078	2074	4	2074	0	0	0	0	0	0	0	0
103 Sonuç	2076	1980	96	1980	0	1	2	35	1	4	52	1
Doğru Pozitif				1979	0	0	0	0	0	0	0	0
Sahte Negatif				95	0	0	0	0	0	0	0	0
Sahte Pozitif				1	0	1	2	35	1	4	52	1
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi					
1979	95	97	95.328	4.6724	0.9542		0.9533					

Tablo B.5 Düğüm sayısı: 19

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
104 Gerçek	2222	163	2059	163	2	0	0	0	1374	664	0	0
104 Sonuç	2221	163	2058	163	51	2	23	124	1564	89	6	198
Doğru Pozitif				60	0	0	0	0	1151	25	0	0
Sahte Negatif				103	2	0	0	0	223	639	0	0
Sahte Pozitif				103	51	2	23	124	413	64	6	198
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi					
1236	967	984	55.651	44.349	0.5611		0.5568					

Tablo B.6 Düğüm sayısı: 23

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
105 Gerçek	2595	2519	76	2519	41	0	0	0	0	0	0	0
105 Sonuç	2595	2417	178	2417	72	13	11	5	29	15	9	24
Doğru Pozitif				2376	0	0	0	0	0	0	0	0
Sahte Negatif				143	41	0	0	0	0	0	0	0
Sahte Pozitif				41	72	13	11	5	29	15	9	24
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi					
2376	184	219	91.561	8.4393	0.9281		0.9156					

Tablo B.7 Düğüm sayısı: 21

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
106 Gerçek	2021	1503	518	1503	518	0	0	0	0	0	0	0
106 Sonuç	2021	1574	447	1574	221	26	61	0	11	4	16	108
Doğru Pozitif				1478	221	0	0	0	0	0	0	0
Sahte Negatif				25	297	0	0	0	0	0	0	0
Sahte Pozitif				96	0	26	61	0	11	4	16	108
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi					
1699	322	322	84.067	15.933	0.8407		0.8407					

Tablo B.8 Düğüm sayısı: 21

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
107 Gerçek	2131	0	2131	0	59	0	0	0	2072	0	0	0
107 Sonuç	2131	0	2131	0	16	25	0	0	2088	0	2	0
Doğru Pozitif				0	9	0	0	0	2064	0	0	0
Sahte Negatif				0	50	0	0	0	8	0	0	0
Sahte Pozitif				0	7	25	0	0	24	0	2	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi					
2073	58	58	97.278	2.7217	0.9728		0.9728					

Tablo B.9 Düşüm sayısı: 21

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
118 Gerçek	2281	0	2281	0	16	0	2161	0	0	0	0	0
118 Sonuç	2281	39	2242	39	11	3	2176	5	1	1	5	40
Doğru Pozitif				0	3	0	2083	0	0	0	0	0
Sahte Negatif				0	13	0	78	0	0	0	0	0
Sahte Pozitif				39	8	3	93	5	1	1	5	40
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı	Doğru Sınıflama Kestirimi						
2086	91	195	91.451	8.5489	0.9582	0.9145						

Tablo B.10 Düşüm sayısı: 21

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
119 Gerçek	1981	1537	444	1537	444	0	0	0	0	0	0	0
119 Sonuç	1981	1495	486	1495	444	0	0	41	0	0	1	0
Doğru Pozitif				1495	443	0	0	0	0	0	0	0
Sahte Negatif				42	1	0	0	0	0	0	0	0
Sahte Pozitif				0	1	0	0	41	0	0	1	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı	Doğru Sınıflama Kestirimi						
1938	43	43	97.829	2.1706	0.9783	0.9783						

Tablo B.11 Düşüm sayısı: 26

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
200 Gerçek	2593	1735	858	1735	826	0	0	0	0	0	2	0
200 Sonuç	2593	1786	807	1786	719	2	52	0	1	4	20	9
Doğru Pozitif				1718	719	0	0	0	0	0	0	0
Sahte Negatif				17	107	0	0	0	0	0	2	0
Sahte Pozitif				68	0	2	52	0	1	4	20	9
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı	Doğru Sınıflama Kestirimi						
2437	126	156	93.984	6.0162	0.9508	0.9398						

Tablo B.12 Düşüm sayısı: 25

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
201 Gerçek	1995	1622	373	1622	198	0	0	96	0	0	2	0
201 Sonuç	1995	1764	231	1764	116	1	21	0	32	7	54	0
Doğru Pozitif				1600	76	0	0	0	0	0	0	0
Sahte Negatif				22	122	0	0	96	0	0	2	0
Sahte Pozitif				164	40	1	21	0	32	7	54	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı	Doğru Sınıflama Kestirimi						
1676	242	319	84.01	15.99	0.8738	0.8401						

Tablo B.13 Düşüm sayısı: 25

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
202 Gerçek	2130	2053	77	2053	19	0	0	19	0	0	1	0
202 Sonuç	2130	2103	27	2103	10	1	0	0	9	3	4	0
Doğru Pozitif				2043	6	0	0	0	0	0	1	0
Sahte Negatif				10	13	0	0	19	0	0	0	0
Sahte Pozitif				60	4	1	0	0	9	3	3	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%	Sınıflama Duyarlılığı	Doğru Sınıflama Kestirimi						
2050	42	80	96.244	3.7559	0.9799	0.9624						

Tablo B.14 Düğüm sayısı: 22

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
203 Gerçek	2998	2520	478	2520	444	0	0	2	0	0	1	0
203 Sonuç	2996	2280	716	2280	497	0	82	3	12	10	103	8
Doğru Pozitif				2059	200	0	0	0	0	0	0	0
Sahte Negatif				461	244	0	0	2	0	0	1	0
Sahte Pozitif				221	297	0	82	3	12	10	103	8
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
2259	708	736	75.401	24.599		0.7614		0.7543				

Tablo B.15 Düğüm sayısı: 21

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
205 Gerçek	2649	2554	95	2554	71	0	0	0	0	0	11	0
205 Sonuç	2640	2551	89	2551	60	10	0	1	0	0	18	0
Doğru Pozitif				2502	26	0	0	0	0	0	0	0
Sahte Negatif				52	45	0	0	0	0	0	11	0
Sahte Pozitif				49	34	10	0	1	0	0	18	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
2528	108	112	95.758	4.2424		0.959		0.9576				

Tablo B.16 Düğüm sayısı: 20

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
207 Gerçek	2336	0	2336	0	105	1457	86	0	0	0	0	105
207 Sonuç	2334	87	2247	87	294	1647	93	4	9	8	8	183
Doğru Pozitif				0	33	1448	85	0	0	0	0	98
Sahte Negatif				0	72	9	1	0	0	0	0	7
Sahte Pozitif				87	261	199	8	4	9	8	8	85
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
1664	89	669	71.294	28.706		0.9492		0.7132				

Tablo B.17 Düğüm sayısı: 20

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
208 Gerçek	2954	1581	1373	1581	988	0	0	0	0	0	371	0
208 Sonuç	2952	1649	1303	1649	1018	3	3	34	64	11	90	80
Doğru Pozitif				1043	488	0	0	0	0	0	22	0
Sahte Negatif				538	500	0	0	0	0	0	349	0
Sahte Pozitif				606	530	3	3	34	64	11	68	80
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
1553	1387	1399	52.608	47.392		0.5282		0.5261				

Tablo B.18 Düğüm sayısı: 20

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
209 Gerçek	3004	2613	391	2613	1	0	0	0	0	0	0	0
209 Sonuç	3004	2992	12	2992	2	0	4	1	2	1	2	0
Doğru Pozitif				2608	0	0	0	0	0	0	0	0
Sahte Negatif				5	1	0	0	0	0	0	0	0
Sahte Pozitif				384	2	0	4	1	2	1	2	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
2608	6	396	86.818	13.182		0.9977		0.8682				

Tablo B.19 Düğüm sayısı: 20

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
210 Gerçek	2643	2416	227	2416	191	0	0	22	0	0	10	1
210 Sonuç	2641	2409	232	2409	107	58	11	11	17	13	9	4
Doğru Pozitif				2271	40	0	0	0	0	0	0	0
Sahte Negatif				145	151	0	0	22	0	0	10	1
Sahte Pozitif				138	67	58	11	11	17	13	9	4
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
2311	329	328	87.505	12.495		0.8754		0.8757				

Tablo B.20 Düğüm sayısı: 26

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
212 Gerçek	2741	915	1826	915	0	0	1825	0	0	0	0	0
212 Sonuç	2744	919	1825	919	1	34	1762	19	1	1	4	0
Doğru Pozitif				891	0	0	1756	0	0	0	0	0
Sahte Negatif				24	0	0	69	0	0	0	0	0
Sahte Pozitif				28	1	34	6	19	1	1	4	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
2647	93	94	96.571	3.4294		0.9661		0.9657				

Tablo B.21 Düğüm sayısı: 20

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
213 Gerçek	3241	2631	610	2631	220	0	0	3	0	0	362	0
213 Sonuç	3240	2616	624	2616	60	7	2	18	15	31	432	59
Doğru Pozitif				2348	44	0	0	0	0	0	109	0
Sahte Negatif				283	176	0	0	3	0	0	253	0
Sahte Pozitif				268	16	7	2	18	15	31	323	59
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
2501	715	739	77.191	22.809		0.7777		0.7719				

Tablo B.22 Düğüm sayısı: 20

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
214 Gerçek	2259	0	2259	0	255	1995	0	0	0	0	1	0
214 Sonuç	2259	13	2246	13	139	2049	10	0	14	3	31	0
Doğru Pozitif				0	134	1976	0	0	0	0	0	0
Sahte Negatif				0	121	19	0	0	0	0	1	0
Sahte Pozitif				13	5	73	10	0	14	3	31	0
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
2110	141	149	93.404	6.5958		0.9374		0.934				

Tablo B.23 Düğüm sayısı: 19

Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
215 Gerçek	3355	3186	169	3186	164	0	0	0	0	0	1	0
215 Sonuç	3356	3157	199	3157	129	12	14	7	0	0	34	3
Doğru Pozitif				3018	21	0	0	0	0	0	0	0
Sahte Negatif				168	143	0	0	0	0	0	1	0
Sahte Pozitif				139	108	12	14	7	0	0	34	3
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
3039	312	317	90.554	9.4458		0.9069		0.9055				

Tablo B.24 Düşüm sayısı: 21


Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
217 Gerçek	2203	244	1959	244	162	0	0	0	1536	260	0	0
217 Sonuç	2203	258	1945	258	176	13	17	8	1526	113	44	48
Doğru Pozitif				223	146	0	0	0	1517	113	0	0
Sahte Negatif				21	16	0	0	0	19	147	0	0
Sahte Pozitif				35	30	13	17	8	9	0	44	48
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
1999	203	204	90.74	9.2601		0.9078		0.9074				

Tablo B.25 Düşüm sayısı: 23


Dosya Adı	Toplam Vuru	Toplam Normal	Toplam Anormal	N	V	L	R	a	P	f	F	E
219 Gerçek	2284	2075	209	2075	63	0	0	0	0	0	1	0
219 Sonuç	2283	2123	160	2123	34	1	41	1	70	8	1	3
Doğru Pozitif				1945	1	0	0	0	0	0	0	0
Sahte Negatif				130	62	0	0	0	0	0	1	0
Sahte Pozitif				178	33	1	41	1	70	8	1	3
Toplam TP	Toplam FN	Toplam FP	Toplam Doğru%	Toplam Yanlış%		Sınıflama Duyarlılığı		Doğru Sınıflama Kestirimi				
1946	193	336	85.239	14.761		0.9098		0.8528				

EK C

GAL ağının eğitim ve unutma algoritmaları



Şekil C.1 a) GAL ağının eğitim algoritması



Şekil C.1. b) GAL ağının unutma algoritması

ÖZGEÇMİŞ

Selin Metin, 1977 yılında Ankara’da doğdu. Orta öğrenimini 1995 yılında Kadıköy Anadolu Lisesinde tamamladı. Lisans öğrenimini 1999 yılında Yıldız Teknik Üniversitesi Elektronik ve Haberleşme Mühendisliği Bölümünde tamamladı. Aynı yıl İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsünde yüksek lisans öğrenimine başladı. Aralık 2000 – Mart 2001 arasında Netaş A.Ş.’de yazılım geliştirme mühendisi olarak çalıştı.