

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**KALP SESLERİNİN ANALİZİ
VE
YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Müh. Özgür SAY

Anabilim Dalı : ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ

Programı : BİYOMEDİKAL MÜHENDİSLİĞİ

HAZİRAN 2002

**KALP SESLERİNİN ANALİZİ
VE
YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ
Müh. Özgür SAY
504991083**

**Tezin Enstitüye Verildiği Tarih : 13 Mayıs 2002
Tezin Savunulduğu Tarih : 6 Haziran 2002**

**Tez Danışmanı : Yrd. Doç. Dr. Zümray DOKUR ÖLMEZ
Diğer Jüri Üyeleri Prof. Dr. Ertuğrul YAZGAN (İ.T.Ü.)
Doç. Dr. Serhat ŞEKER (İ.T.Ü.)**

HAZİRAN 2002

ÖNSÖZ

“Kalp Seslerinin Analizi ve Yapay Sinir Ağları ile Sınıflandırılması” isimli yüksek lisans tez çalışmamın her aşamasında bilgi, yardım ve anlayışını esirgemeyen danışman hocam Sayın Yrd. Doç. Dr. Zümray DOKUR ÖLMEZ’e; görüşleriyle yardımcı olan değerli hocam Sayın Doç. Dr. Tamer ÖLMEZ’e ve eğitimim sırasında emeği geçen tüm hocalarıma katkılarından dolayı çok teşekkür ederim.

Haziran, 2002

Özgür SAY

İÇİNDEKİLER

KISALTMALAR	v
TABLO LİSTESİ	vi
ŞEKİL LİSTESİ	vii
SEMBOL LİSTESİ	ix
ÖZET	x
SUMMARY	xiii
1. GİRİŞ	1
2. KALP SESLERİ	3
2.1 Kalbin Yapısı ve Çalışması	3
2.2 Kalp Sesleri	7
2.2.1 Temel Sesler	10
2.2.1.1 Birinci Kalp Sesi (S1)	11
2.2.1.2 İkinci Kalp Sesi (S2)	11
2.2.1.3 Üçüncü Kalp Sesi (S3)	11
2.2.1.4 Dördüncü Kalp Sesi (S4)	11
2.2.1.5 S1 Çatallaşması	12
2.2.1.6 S2 Çatallaşması	12
2.2.2 Ek Sesler	12
2.2.2.1 Ejeksiyon Sesi (Ej)	12
2.2.2.2 Midsistolik Klik	12
2.2.2.3 S3	15
2.2.2.4 S4	15
2.2.2.5 Açılma Sesi	15
2.2.3 Üfürümler	17
2.2.3.1 Üfürümlerin Özellikleri	17
2.2.3.2 Sistolik Üfürümler	17
2.2.3.4 Diyastolik Üfürümler	20
2.2.4 Kompleks Kalp Sesleri	22
2.2.4.1 Mitral Stenoza (Mitral Darlığı)	22
2.2.4.2 Mitral Regurgitation (Mitral Yetmezliği)	22
2.2.4.3 Mitral Stenoza ve Yetmezliği	23
2.2.4.4 Aort Stenoza (Aort Darlığı)	24
2.2.4.5 Aort Yetmezliği	24
2.2.4.6 Aort Stenoza ve Yetmezliği	25
2.2.4.7 Atrial Septal Defect (ASD)	26
2.2.4.8 Ventricular Septal Defect (VSD)	26
2.2.4.9 Patent Ductus Ateriosus (PDA)	26
2.2.4.10 Venoz Uğultu	28
2.2.4.11 Pulmoner Kapak Stenoza	28

2.2.4.12 Hipertrofik Kardiyomyopati (IHSS)	28
2.2.4.13 Perikardiyal Sürtünme Sesleri	28
2.2.4.14 Mediastinal Gıcırtı Sesi (Hamman İşareti)	30
3. ÖZİNİTELİK ÇIKARTMA YÖNTEMLERİ	31
3.1 Giriş	31
3.2 Fourier Dönüşümü (FD)	32
3.3 Kısa Zaman Fourier Dönüşümü (KZFD)	33
3.4 Dalgacık Dönüşümü	34
3.4.1 Sürekli Dalgacık Dönüşümü (SDD)	34
3.4.2 Ayrık Dalgacık Dönüşümü (ADD)	36
4. SINIFLAYICI OLARAK KULLANILAN YAPAY SİNİR AĞLARI	40
4.1 Yapay Sinir Ağının Tanımı	40
4.2 Yapay Sinir Ağlarında Öğrenme	43
4.3 Büyü ve Öğren (GAL) Yapay Sinir Ağı	44
4.3.1 GAL Ağının Yapısı	45
4.3.2 GAL Ağının Eğitimi	46
4.4 Öğrenen Vektör Nicemleyici (LVQ) Yapay Sinir Ağı	47
4.4.1 LVQ Ağının Yapısı	47
4.4.2 LVQ Ağının Eğitimi	47
5. KALP SESLERİNİN YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI	49
5.1 Giriş	49
5.2 Özneliklerin Belirlenmesi	52
5.2.1 Fourier Dönüşümü	52
5.2.2 Kısa Zaman Fourier Dönüşümü	54
5.2.3 Dalgacık Dönüşümü	58
5.3 Yapay Sinir Ağları ile Sınıflama	64
5.3.1 Örnek Öznelik Uzayı	64
5.3.2 Kalp Seslerinden Elde Edilen Öznelik Uzayı	65
5.4 Sınıflama Sonuçları	65
6. SONUÇLAR	68
KAYNAKLAR	71
EKLER	73
EK A Çalışmada Sınıflandırılan Kalp Sesleri	73
EK B Kalp Seslerinin Fourier Dönüşümleri	75
EK C Kalp Seslerinin Kısa Zaman Fourier Dönüşümleri	79
EK D Kalp Seslerinin 4. Seviye Ayrıntı Katsayıları ve Güçleri	83
EK E Kalp Seslerinin 4. Seviye Yaklaşıklık Katsayıları ve Güçleri	86
EK F Kalp Seslerinin 4 Seviyeli Dalgacık Düzlemi	88
EK G Programlar	DİSKET
ÖZGEÇMİŞ	92

KISALTMALAR

A	: Aortik bölge
ADD	: Ayrık dalgacık dönüşümü
AGF	: Alçak geçiren filtre
ANN	: Artificial neural network
ASD	: Atrial Septal Defect
AV	: Atrio-Ventriküler düğüm
ECG	: Electrocardiogram
EKG	: Elektrokardiogram
FD	: Fourier dönüşümü
GAL	: Grow and learn (büyü ve öğren)
ICS	: Intercostal space
IF	: Instantaneous frequency
KZFD	: Kısa zaman Fourier dönüşümü
LVQ	: Learning vector quantization (öğrenen vektör nicemleyici)
M	: Mitral bölge
OS	: Opening snap
PCG	: Phonocardiogram
P	: Pulmonik bölge
PPN	: Probability neural network
SA	: Sino-Atrial düğüm
SDD	: Sürekli dalgacık dönüşümü
SG	: Somasyon galosu
SOM	: Self organizing map
T	: Triküspid bölge
TM	: Trimmed mean spectrogram
VSD	: Ventricular Septal Defect
WVD	: Wigner-Ville distribution
YGF	: Yüksek geçiren filtre
YSA	: Yapay sinir ağları

TABLO LİSTESİ

	<u>Sayfa No</u>
Tablo 5.1 Örnek öznitelik uzayı sınıflama sonuçları	67
Tablo 5.2 Kalp seslerine ait öznitelik uzayı sınıflama sonuçları.....	67
Tablo 6.1 YSA'ların sınıflama performansları.....	70

ŞEKİL LİSTESİ

	<u>Sayfa No</u>
Şekil 2.1 : Kalbin anatomik yapısı.....	4
Şekil 2.2 : Kalp kapakçıkları.....	4
Şekil 2.3 : Kalbin elektriksel uyarı iletimi.....	6
Şekil 2.4 : Normal EKG.....	6
Şekil 2.5 : Oskültasyon bölgeleri.....	7
Şekil 2.6 : Kalpteki basınç, EKG ve PCG'nin zamanla değişimi.....	9
Şekil 2.7 : Normal kalp sesi.....	10
Şekil 2.8 : S1, S2, S3 ve S4'ten oluşan bir çevrim.....	10
Şekil 2.9 : S1 çatallaşması.....	13
Şekil 2.10 : S2 çatallaşması.....	13
Şekil 2.11 : Ejeksiyon sesi.....	14
Şekil 2.12 : Midsistolik klik sesi.....	14
Şekil 2.13 : S3 sesi.....	15
Şekil 2.14 : S4 sesi.....	16
Şekil 2.15 : Açılma sesi.....	16
Şekil 2.16 : Üfürüm çeşitleri.....	18
Şekil 2.17 : Erken sistolik üfürüm.....	18
Şekil 2.18 : Midsistolik üfürüm.....	19
Şekil 2.19 : Geç sistolik üfürüm.....	19
Şekil 2.20 : Holosistolik üfürüm.....	20
Şekil 2.21 : Erken diyastolik üfürüm.....	20
Şekil 2.22 : Middiyastolik üfürüm.....	21
Şekil 2.23 : Geç diyastolik üfürüm.....	21
Şekil 2.24 : Mitral stenozu.....	22
Şekil 2.25 : Mitral yetmezliği.....	23
Şekil 2.26 : Mitral stenozu ve yetmezliği.....	23
Şekil 2.27 : Aort stenozu	24
Şekil 2.28 : Aort yetmezliği.....	25
Şekil 2.29 : Aort stenozu ve yetmezliği.....	25
Şekil 2.30 : Atrial Septal Defect (ASD)	26
Şekil 2.31 : Ventriküler Septal Defekt (VSD)	27
Şekil 2.32 : Patent Ductus Ateriosus (PDA)	27
Şekil 2.33 : Venoz uğultu.....	28
Şekil 2.34 : Pulmoner stenozu.....	29
Şekil 2.35 : Hipertrofik Kardiyomiyopati (IHSS)	29
Şekil 2.36 : Perikardiyal sürtünme sesleri.....	30
Şekil 2.37 : Mediastinal gıcırtı sesi (Hamman İşareti).....	30

Şekil 3.1	: Morlet dalgacık fonksiyonu.....	35
Şekil 3.2	: Daubechies dalgacık fonksiyonu.....	35
Şekil 3.3	: Meksika Şapkası dalgacık fonksiyonu.....	35
Şekil 3.4	: Dalgacık ağacı.....	38
Şekil 3.5	: Daubechies-10 dalgacık ve ölçek fonksiyonu.....	39
Şekil 4.1	: İşlem elemanı.....	42
Şekil 4.2	: Yapay sinir ağı.....	42
Şekil 4.3	: Perceptron'un yapısı.....	42
Şekil 4.4	: Perceptron'un eğitimi.....	43
Şekil 4.5	: Eğitim yöntemlerine göre yapay sinir ağları.....	44
Şekil 4.6	: GAL ağının yapısı.....	45
Şekil 5.1	: Erken sistolik üfürüm.....	53
Şekil 5.2	: Geç sistolik üfürüm.....	53
Şekil 5.3	: Erken sistolik üfürümün frekans spektrumu.....	54
Şekil 5.4	: Geç sistolik üfürümün frekans spektrumu.....	54
Şekil 5.5	: Erken sistolik üfürümün büyük pencere kullanılarak KZFD ile analizi.....	55
Şekil 5.6	: Erken sistolik üfürümün küçük pencere kullanılarak KZFD ile analizi.....	56
Şekil 5.7	: Erken sistolik üfürümün KZFD ile analizi.....	57
Şekil 5.8	: Geç sistolik üfürüm sesi.....	58
Şekil 5.9	: Geç sistolik üfürüme ait dalgacık düzlemi.....	58
Şekil 5.10	: Birinci seviye ayrıntı katsayıları.....	59
Şekil 5.11	: İkinci seviye ayrıntı katsayıları.....	59
Şekil 5.12	: Üçüncü seviye ayrıntı katsayıları.....	59
Şekil 5.13	: Dördüncü seviye ayrıntı katsayıları.....	59
Şekil 5.14	: Beşinci seviye ayrıntı katsayıları.....	59
Şekil 5.15	: Birinci seviye yaklaşıklık katsayıları.....	60
Şekil 5.16	: İkinci seviye yaklaşıklık katsayıları.....	60
Şekil 5.17	: Üçüncü seviye yaklaşıklık katsayıları.....	60
Şekil 5.18	: Dördüncü seviye yaklaşıklık katsayıları.....	60
Şekil 5.19	: Beşinci seviye yaklaşıklık katsayıları.....	60
Şekil 5.20	: Pencere kullanılarak 4. seviye ayrıntı katsayılarının güç hesabı.....	61
Şekil 5.21	: Üçüncü seviye ayrıntı katsayılarının gücü.....	61
Şekil 5.22	: Dördüncü seviye ayrıntı katsayılarının gücü.....	62
Şekil 5.23	: Üçüncü seviye yaklaşıklık katsayılarının gücü.....	62
Şekil 5.24	: Dördüncü seviye yaklaşıklık katsayılarının gücü.....	62
Şekil 5.25	: Ayrıntı katsayılarının gücü ile elde edilen eğitim kümesi öznitelikleri.....	63
Şekil 5.26	: Yaklaşıklık katsayılarının gücü ile elde edilen eğitim kümesi öznitelikleri.....	63
Şekil 5.27	: Ayrıntı ve yaklaşıklık katsayılarının gücünden elde edilen öznitelikler.....	63
Şekil 5.28	: Örnek öznitelik uzayı ve karar işlemi.....	64
Şekil 5.29	: Kalp seslerinin sınıflandırılması.....	65
Şekil 5.30	: Örnek öznitelik uzayı için GAL ve LVQ sınıflama sonuçları.....	66

SEMBOL LİSTESİ

C	: Sınıf (çıkış) katmanı
D_j	: Düğüm ağırlığı ile giriş vektörü arasındaki mesafe
E_e	: Birinci katman çıkışı
f	: Frekans
F(y)	: Kırpıcı
h(n)	: Alçak geçiren filtre eşdeğeri
g(n)	: Yüksek geçiren filtre eşdeğeri
KZFD(τ,f)	: Kısa zaman Fourier dönüşümü
s	: Ölçek parametresi
SDD(τ,s)	: Sürekli dalgacık dönüşümü
t	: Zaman
T	: Giriş vektörünün sınıfı
T_{ec}	: Bağlantı katsayısı
w_i	: Yerel belleğin i. elemanı
w(t)	: Pencere fonksiyonu
W	: Ağırlık katmanı
x_i	: Giriş vektörünün i. elemanı
x(n)	: Ayrık zaman domeni işareti
x(t)	: Zaman domeni işareti
X(f)	: Frekans domeni işareti
X(k)	: Ayrık frekans domeni işareti
y	: Çıkış fonksiyonu
η	: Öğrenme katsayısı
τ	: Zamanda öteleme
Ψ(t)	: Dönüşüm fonksiyonu

KALP SESLERİNİN ANALİZİ VE YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

ÖZET

Kardiyovasküler hastalıklar, insan sağlığını ciddi olarak tehdit eden hastalıklar arasındadır. Fonokardiyogram (PCG) ve elektrokardiyogram (EKG) gibi non-invasive yöntemler, kalbin çalışması hakkında önemli bilgiler vermektedir. Bundan dolayı kalp sesi analizi doktorlar ve tıp öğrencileri için temel bir ihtiyaç olmuştur. Oskültasyon sırasında, dinleyici kalp sesi bileşenlerini ayrı ayrı belirler ve daha sonra dinleme yeteneği ile sesleri tespit eder. Oskültasyon yardımıyla gerçekleştirilen kalp sesi analizi, çoğunlukla dinleyicinin deneyimlerine ve yeteneğine bağlıdır. Bu nedenle kalp seslerinin bilgisayar aracılığıyla kaydedilmesi ve analiz edilmesi tercih edilen bir yöntemdir.

Bu tez içerisinde, kalp sesleri 10 sınıfa ayrılmıştır: açılma sesi, aort stenozu, erken sistolik üfürüm, geç sistolik üfürüm, normal kalp sesi, S3, S4, Ventricular Septal Defect (VSD), Patent Ductus Ateriosus (PDA) ve Atrial Septal Defect (ASD).

Karar verme üç aşamada gerçekleştirilmiştir: normalizasyon işlemi, öznelilik çıkartma işlemi ve yapay sinir ağları ile sınıflama.

Normalizasyon İşlemi

İlk olarak, uzun kayıtlardan kalp sesinin S1-S1 periyodunun nasıl bulunacağına karar verilmelidir. Literatürde, bu başlı başına bir çalışmadır, bu nedenle S1-S1 periyodunun bilindiği kabul edilmektedir. Daha sonra kayıtların tepeden tepeye genlikleri normalize edilir. Böylece sınıflama kararının kalp seslerinin maksimum genliğinden bağımsız olması sağlanır.

Öznelilik Çıkartma İşlemi

Bu çalışmada, üç farklı öznelilik çıkartma yöntemi incelenmiştir: Fourier dönüşümü, kısa zaman Fourier dönüşümü ve dalgacık dönüşümü.

Fourier dönüşümü (FD) işaret içinde hangi frekans bileşenlerinin var olduğunu belirler. Frekans bilgisi, frekans bileşenlerinin zamandaki yerlerinden bağımsızdır. Bundan dolayı Fourier dönüşümü frekans içeriği zamanla değişen (durağan olmayan) işaretler için uygun değildir. Kalp sesleri de durağan olmayan işaretlerdir ve kalp seslerinin zaman-frekans bilgisi FD ile elde edilemez.

Kısa zaman Fourier dönüşümü (KZFD), işaretin zamanda ötelenen uygun bir pencere ile çarpılarak FD'sinin alınması ile elde edilir. İşaret, her biri içinde işaretin durağan kabul edildiği alt parçalara bölünür ve her parça uygun bir pencere ile çarpılarak her parçaya FD uygulanır. Böylece, durağan olmayan işaret hakkında zaman bilgisi elde edilmiş olur. KZFD'de problem, kullanılan pencere fonksiyonunun genişliğidir. Eğer dar pencere seçilirse, zamanda iyi bir çözünürlük elde edilir fakat frekans çözünürlüğü azalır ya da geniş bir pencere seçilerek iyi bir frekans çözünürlüğü elde edilir fakat zamanda çözünürlük azalır. Bu sebeple kalp sesleri hakkında yeterli bir zaman-frekans bilgisi elde edilemez.

Bu nedenle, analiz sonuçları bizi yeni öznitelik çıkartma yöntemi arayışına yönlendirmiştir. Bu noktada literatürde yaygın olarak kullanılan ayrık dalgacık dönüşümü (ADD)'nün sınıflamada başarı ile kullanıldığı görülmüştür. ADD'de, işaretin zaman-ölçek olarak gösterimi sayısal filtreleme yöntemleri kullanılarak elde edilmiştir. İşaretin çözünürlüğü filtreleme teknikleri ile değiştirilir ve ölçek, alt örnekleme işlemleri ile değiştirilir. Bu çalışmada, öznitelik vektörü oluşturma işleminde pencere fonksiyonu olarak Daubechies-10 dalgacığı kullanılarak, ADD'nin 4. ayrıştırma seviyesindeki ayrıntı ve yaklaşıklık katsayıları kullanılmıştır. Daha sonra 128 örnek uzunluğundaki bir pencerenin ötelenmesi ile bu katsayıların gücü hesaplanmıştır. Ayrıntı katsayılarının güç vektörüne, yaklaşıklık katsayıları güç vektörü eklenerek, sınıflayıcılarda kullanılacak olan öznitelik vektörleri oluşturulmuştur.

Bu çalışmada 25 farklı kayıttan elde edilmiş, 268 kalp sesinden oluşan 10 farklı grup sınıflandırılmış ve bunların 150 tanesi eğitim, 118'i ise test için kullanılmıştır. Her bir öznitelik vektörü, boyutu 37 ayrıntı gücü ve 37 yaklaşıklık gücü olmak üzere toplam 74 elemandan oluşmaktadır.

Sınıflayıcı Olarak Yapay Sinir Ağları

Sınıflayıcı olarak yapay sinir ağları (YSA) iyi bir sınıflama performansı elde etmek amacıyla kullanılmıştır. Yapay sinir ağlarının sınıflayıcı olarak kullanılmasının dört nedeni vardır. i) Çözümleri temsil eden ağırlıklara adım adım eğitimle yaklaşılar. ii) YSA'ların fiziksel olarak gerçekleştirme imkanı bulunmaktadır. iii) YSA'lar karmaşık sınıf dağılımlarını kolaylıkla temsil edebilmektedirler. iv) YSA'lar genelleme özellikleri sayesinde önceden karşılaşmadığı girişler için uygun sonuç üretebilmektedir. Bu çalışmada sınıflayıcı olarak iki yapay sinir ağı kullanılmıştır: GAL (büyü ve öğren) ve LVQ (öğrenen vektör nicemleyici).

GAL ağının düğümleri, eğitim sırasında sınıf sınırlarına yerleşir ve ağdaki düğümlerin ağırlıkları değişmez. Öznitelik uzayında vektörler saçılırsa, eğitim tamamlandıktan sonra ağda aşırı sayıda düğüm üretilir. LVQ ağında vektörler sınıfların iç bölgelerine homojen olarak dağılır ve ağ düğümlerinin ağırlıkları eğitim sırasında değişir. Eğer eğitim öncesinde yeterli sayıda düğüm ataması yapılmamışsa, sınıf sınırları yeterince temsil edilememekte ve ağın sınıflama performansı düşmektedir. Örnek uzay ve kalp sesi kümesinin GAL tarafından LVQ ya göre daha az düğüm kullanılarak, başarıyla sınıflandığı gözlenmektedir (Tablo 1).

Ağ yapıları araştırılırken, test amaçlı iki boyutlu bir örnek uzay tanımlanmıştır. İki boyuttaki analizler, sınıf sınırlarının ağ düğümleri tarafından temsil edilmesinin görsel olarak incelenmesini sağlamaktadır. Bu örnek uzay, aynı zamanda klasik ağ eğitim algoritmalarının düğümleri yönlendirmesi hakkında bilgi vermektedir. Örnek uzayda beyaz, açık-gri ve koyu-gri ile renklendirilmiş 3 tane sınıf vardır. Siyah renkli bölgeler herhangi bir sınıfa ait değildir. Eğitim kümesi, örnek uzayda her sınıftan 100 adet vektör alınarak oluşturulur.

Tablo 1.'de ağların düğüm sayıları ve sınıflama başarımları verilmiştir. Programlar MATLAB paket programı kullanılarak bilgisayar ortamında geliştirilmiştir.

Tablo 1. YSA'ların sınıflama performansları

Yapay Sinir Ağları	Örnek Uzay		Kalp Sesleri		
	İterasyon	Düğüm Sayısı	Başarım (%)	Düğüm Sayısı	Başarım (%)
GAL	1000	24	93,6	22	99,29
LVQ	1000	35	92,3	35	97,11

ANALYSIS OF HEART SOUNDS AND CLASSIFICATION BY USING ARTIFICIAL NEURAL NETWORKS

SUMMARY

Cardiovascular diseases are among those seriously threatening human health. Noninvasive study (diagnosis) methods, such as phonocardiogram (PCG) and electrocardiogram (ECG), offer useful information of functioning heart. So heart sound analysis has been a basic requirement for every doctor and medical student. In auscultation, the listener tries to analyze the heart sound components separately and then synthesize the heard features. Heart sound analysis by auscultation highly depends on the skills and experiences of the listener. Therefore recording of heart sounds and analyzing them by a computerized and objective way would be most desirable.

In this thesis, heart sounds are classified into 10 categories: opening snap, aortic stenosis, early systolic murmurs, late systolic murmurs, normal heart sound, S3, S4, Ventricular Septal Defect (VSD), Patent Ductus Ateriosus (PDA) and Atrial Septal Defect (ASD).

Decision making is performed in three stages: normalization process, feature extraction process, and classification by using artificial neural networks.

Normalization Process

Firstly, it should be decided that how S1-S1 period of heart sounds can be found from long records. In the literature, it is a study all by itself so we assumed that S1-S1 period is known. Then peak to peak magnitude of records are normalized. Thus, it is provided that classification decision does not depend on the maximum amplitude of the heart sounds.

Feature Extraction Process

In this study, three different feature extraction methods, Fourier transform, short time Fourier transform and wavelet analysis are investigated.

The Fourier transform (FT) tells whether a certain frequency component of the signal exists or not. Frequency information is independent of where this component appears in the time. Therefore Fourier transform is not suitable for signal which has time varying frequency (non-stationary). Heart sounds are non-stationary signals and any information about time-frequency of heart sounds can not be obtained by using FT.

Short time Fourier transform (STFT), is obtained from the FT by multiplying the time signal by an appropriate sliding-time window. The signal under study is subdivided into a number of small records where it is assumed that each sub-record is stationary and each sub-record is then multiplied by an appropriate window and then the FT is applied to each sub-record. In this way time information about non-stationary signals can be obtained. The problem with the STFT is the width of the window function that is used. If a narrow window is selected, good time resolution will be obtained, but poor frequency resolution, or if a wide window is selected, good frequency resolution will be obtained, but poor time resolution. Therefore satisfactory information about time-frequency content of heart sounds can not be obtained.

In conclusion, results directed us to find a new feature extraction method. At that point, the discrete wavelet transform (DWT) emerged as a promising feature extraction method that is highly used in the literature. In the DWT, a time-scale representation of a signal is obtained by using digital filtering techniques. The resolution of the signal, is changed by the filtering operations, and the scale is changed by downsampling operations. To form the feature vectors; the 4th level wavelet detail and approximation coefficients are computed by using Daubechies-10 wavelets as the window function. Then power of these coefficients are computed by using a sliding window at data of length 128. The power vectors of approximation coefficients are merged with the power vectors of detail coefficients to form the feature vectors used in the classifiers.

In this study, 10 different heart sound classes obtained from 25 different records, are classified. Among the 268 heart sounds cycles, 150 of them are used for training and 118 of them are used for testing. The size of each feature vector is data of length 74 which consist of 37 detail-power data and 37 approximation-power data.

Artificial Neural Networks as Classifiers

Artificial neural networks (ANNs) are used as classifiers in order to obtain good classification performance. There are four reasons to use artificial neural network as a classifier i) Weights representing the solution are found by iteratively training, ii) ANN has simple structure for physical implementation, iii) ANN can easily map complex class distributions, iv) Generalization property of ANN produces appropriate results for the input vectors that are not present in the training set. In this study, two artificial neural networks are used as classifiers; GAL (grow and learn) and LVQ (learning vector quantization).

The nodes of GAL network locate at the boundaries of the classes and weights of network nodes do not change during the training. If the vectors scatter in the feature space, excessive number of nodes is generated after the training. The nodes of the LVQ network homogeneously move to the inner regions of the classes and weights of network nodes change during the training. If sufficient number of nodes is not assigned before the training, class boundaries can not be sufficiently represented, and the classification performance of the network decreases. It is observed that sample

space and heart sounds sets are successfully classified by the GAL with less number of nodes compared to the LVQ networks (Table 1).

During the search of network structure, a two-dimensional sample space is formed for test purpose. Analysis in two dimensions gives a visual information about the representation of the class boundaries by the nodes. The sample space also gives information about how the training algorithms of the classical networks direct the nodes in the feature space. In the sample space, there are three classes: white, light-gray, and dark-gray. Black coloured regions do not belong to any class. Training set is formed by taking 100 vectors from each class in the sample space.

Table 1. shows the number of nodes (NoN) and classification performances (CP) of the networks. The programs were developed using MATLAB tools on PC.

Table 1. Classification performances of ANNs

Artificial Neural Networks	Sample Space		Heart Sounds		
	Iteration	NoN	CP (%)	NoN	CP (%)
GAL	1000	24	93,6	22	99,29
LVQ	1000	35	92,3	35	97,11

1. GİRİŞ

Kan dolaşım sisteminin vücut içerisinde görevini gerçekleştirebilmesi, sistemi oluşturan parçaların sağlıklı bir şekilde çalışmalarına bağlıdır. Bu sistemin en önemli bölümü olan kalbin çalışması ise insan yaşamı için çok önemlidir. İnsan ölümlerinin büyük bir bölümünü kalp rahatsızlıklarının oluşturduğu göz önüne alınırsa; kalbin çalışması hakkında bilgi edinmek, oluşabilecek kalp rahatsızlıklarını geç kalmadan teşhis ederek, sorunun kalbin hangi bölümünden kaynaklandığının tespiti modern tıbbın önemli bir bölümünü oluşturmaktadır. Teknolojinin gelişmesine bağlı olarak hastaya cerrahi müdahale gerçekleştirmeden en kısa sürede, en fazla bilgiyi almak amacıyla, yeni yöntemler geliştirilmektedir. Elektrokardiyogram ve fonokardiyogram gibi kalbin çalışması hakkında önemli bilgiler veren biyolojik işaretlerin incelendiği yöntemler en çok kullanılanlarıdır.

Elektrokardiyogram (ECG), kalp kaslarının aynı anda kasılması sonucu oluşan genliği büyük elektriksel işarettir [1]. Kalbin elektriksel iletim sisteminin çalışması hakkında bilgi verir ve vücut üzerinden algılanabilir. Fakat kalbin mekanik çalışması hakkında, özellikle kapakçıkların çalışması sırasında oluşabilecek rahatsızlıklar hakkında yeterli bilgi verememektedir. Kalbin çalışması sırasında kalp kapakçıklarının açılıp kapanması (mekanik hareketleri) ve kanın kardiyovasküler sistemde hareketi esnasında meydana gelen değişimler sonucu oluşan sesler, kalp sesleri olarak adlandırılır. Kalbin mekanik çalışması sırasında oluşan seslerin incelenmesiyle elde edilen işaretler ise fonokardiyogram (PCG) olarak adlandırılır [2].

Bu çalışma içerisinde kalbin çalışması ve çeşitli kalp hastalıkları hakkında bilgi edinmek amacıyla 10 farklı kalp sesi işareti (PCG) analiz edilmiştir: açılma sesi, aort stenozu, erken sistolik üfürüm, geç sistolik üfürüm, normal kalp sesi, S3 sesi, S4 sesi, VSD (ventricular septal defect), PDA (patent ductus arteriosus), ASD (atrial septal defect).

Gerçekleştirilen analizlerden kalp seslerini en iyi karakterize eden öznitelikler bulunmuş ve bu özniteliklerden oluşturulan öznitelik vektörleri yardımıyla, kalp seslerinin yapay sinir ağları ile bilgisayar ortamında sınıflandırılması amaçlanmıştır.

İkinci bölümde kalbin çalışması hakkında kısa bir bilgi verilerek, kalbin çalışması sırasında oluşan temel sesler, ek sesler, üfürümler ve kompleks kalp sesleri hakkında bilgi verilmiştir.

Üçüncü bölümde kalp seslerinin zaman ve frekans spektrumu analizleri gerçekleştirilerek; Fourier dönüşümü, kısa zaman Fourier dönüşümü ve dalgacık analizi yöntemleri tanıtılmıştır.

Dördüncü bölümde ise yapay sinir ağları hakkında kısa bir bilgi verilerek, çalışmada kullanılacak olan GAL (grow and learn-büyü ve öğren) ve LVQ (learning vector quantization-öğrenen vektör nicemleyici) yapay sinir ağlarının yapıları ve çalışmaları hakkında bilgi verilmiştir.

Beşinci bölümde, 10 farklı PCG işaretini en iyi karakterize eden öznitelikler araştırılmış, bulunan özniteliklerle yapay sinir ağlarının eğitimi gerçekleştirilmiştir. Daha sonra PCG işaretlerinden oluşan test kümesinin ve örnek öznitelik uzayının sınıflama başarımları karşılaştırmalı olarak incelenmiştir.

2. KALP SESLERİ

2.1 Kalbin Yapısı ve Çalışması


Kan dolaşım sisteminin en önemli organı olan kalp, göğüs kafesinin iki akciğeri birbirinden ayıran orta boşluğunda ve sol tarafta bulunur. Kalp basit olarak, birbirinin benzeri ve sıkıca birbirine kaynaşmış iki organdan oluşur. Bu iki organ arasında kan geçişi yoktur fakat kendi aralarında iki bölüme ayrılır. Üst bölüme atrium (kulakçık), alt bölüme ise ventrikül (karıncık) adı verilmektedir.

Karıncık, kalın çeperli, ucu aşağıya bakan bir huniye benzer, huninin uç tarafına apex denir. Huninin tabanında iki kapakçık bulunur, bu kapakçıklardan büyük olanı kulakçık ile karıncık arasında bağlantıyı sağlar genel olarak atrioventriküler kapak olarak adlandırılır, sol kalpteki kapakçığa mitral kapakçık, sağ kalpte yer alan ise triküspid kapakçık adı verilir. Karıncık içerisinde yer alan küçük kapakçık ise sigmamsı (semilunar) kapakçık olarak adlandırılır. Sağ karıncıkta bulunan ve akciğer atardamarı ile bağlantıyı sağlayan kapakçığa pulmoner kapakçık, sol karıncıkta yer alan ve aort atardamarı ile bağlantıyı sağlayan kapakçığa ise aort kapakçığı denir (Şekil 2.1, 2.2).

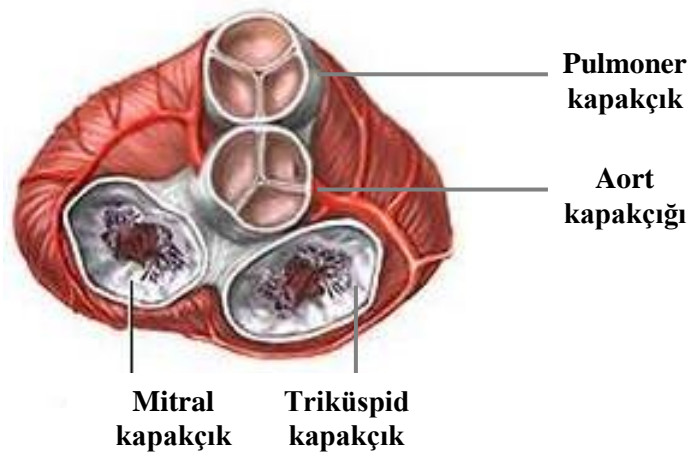
Kulakçıklar ise ince çeperli ve küp biçiminde olup alt yüzlerinde atrioventriküler kapakçıklar, üst yüzlerinde ise toplar damarlar yer alır. Sol kulakçıkta, sağ ve sol akciğer toplardamarları (pulmoner venler), sağ kulakçıkta ise alt (inferior) ve üst (superior) ana toplar damarları (vena cava) yer alır.

Kalbin dış yüzeyi perikart olarak adlandırılan ince bir zarla örtülüdür, iç yüzeyi ise endokart denilen düz, pürüzsüz ince bir zarla kaplıdır. Kalbin kas yapısına ise miyokart denir. Kalp aorttan çıkan sağ ve sol koroner atar damarlar ile beslenir ve kirli kan koroner toplar damarlar aracılığıyla sağ kulakçığa gelir.

Sağ atrium dolduğunda, kasılarak kanın triküspid kapakçıktan sağ ventriküle geçmesini sağlar, sağ ventrikülün de kasılmasıyla pulmoner kapakçıktan geçen kan



Şekil 2.1 Kalbin anatomik yapısı




Şekil 2.2 Kalp kapakçıkları

pulmoner artere pompalanır. Akciğerlere gelen pulmoner arter, arteriol adı verilen küçük kılcal damarlara ayrılarak kanın temizlenme işleminin gerçekleşeceği alveol denilen hava keseciklerine ulaşır. Temizlenen kan, kılcal damarların birleşerek oluşturduğu pulmoner venler aracılığıyla kalbin sol atrium bölümüne ulaşır. Sol atriumun kasılmasıyla mitral kapakçıkta geçerek, sol ventriküle dolan kan, mitral kapağın kapanması ve aort kapakçığının açılarak kanın aorta pompalanmasıyla vücuda gönderilir. Aynı anda kalbin diğer yarısında pulmoner kapakçık da açılarak, sağ ventriküldeki kirli kan pulmoner atardamara basılır.

Kasılma işlemi kalbin kendi iç sinir sistemi tarafından yönetilir. Kalp kasları çizgili (miyokart) kaslardan oluşmuş olsa da kalpte gerçekleşen hareketler isteğimiz dışında meydana gelir. Elektriksel iletim, sağ atriumun arka duvarında yer alan S-A (Sino-Atrial) düğümü tarafından gerçekleştirilir. Oluşturulan potansiyelin frekansı ve genliği S-A düğümünün kendisi tarafından veya içinde bulunan fizyolojik duruma göre merkezi sinir sisteminde yer alan soğan iliği tarafından da düzenlenir. S-A düğümü tarafından oluşturulan potansiyelin, kalp içindeki iletimi ise A-V (Atrio-Ventricular), his demeti (bundle of his), demet kolları (bundle branches) ve purkinje lifleri aracılığıyla gerçekleşir. Kanın kalp içerisinde atriumlardan ventriküllere geçişi sırasında ventriküllerin dolması için gerekli zaman, iletimin bir süre geciktirilmesi ile sağlanır. Bu gecikmeyi A-V düğümü gerçekleştirir. Ventriküllerin uyarılması purkinje lifleri aracılığıyla gerçekleşir. İletim sisteminin görünüşü ve iletim süreleri Şekil 2.3'te gösterilmiştir. İletimin, sadece iletim sistemi üzerinden gerçekleşmesini sağlayan septum bölgesi, yağlı bir dokuya sahip olup elektriksel izolasyonu sağlar. Böylece kalbin çalışması belirli bir düzen içinde gerçekleşmiş olur.

Kalp kaslarının aynı anda kasılması sonucunda oluşan elektriksel işaret, vücut üzerinden belirli yöntemlerle ölçülebilir. Elektrokardiyogram (EKG) olarak da adlandırılan bu elektriksel işaret, kalbin çalışma evrelerine ait belirleyici özellikler içerir. Kalbin çalışması ile ilgili bir çok hastalığın tespitinde kullanılır. Literatürde, QRST dalgası olarak adlandırılır. P dalgası atriumların kasılmasına, QRS kompleksi ventriküllerin depolarize olmasına, ST aralığı ise ventrikül kas hücrelerinin repolarize olmasına karşılık gelir (Şekil 2.4, 2.6).



Şekil 2.3 Kalbin elektriksel uyarı iletimi



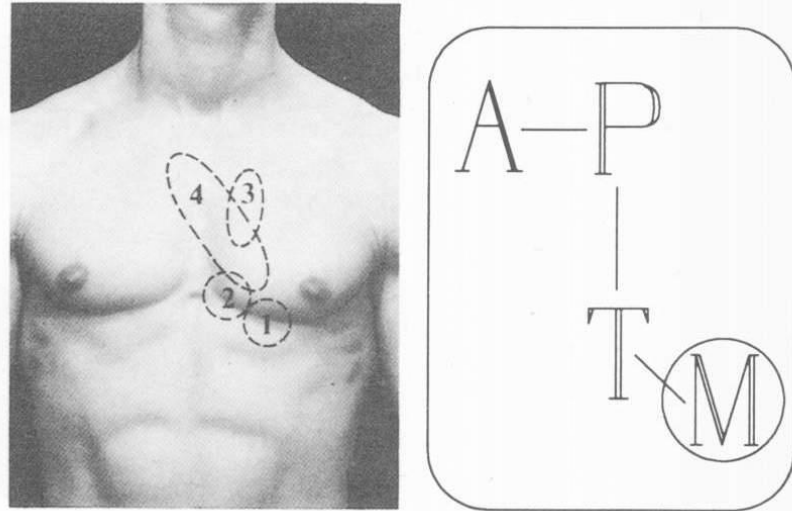
Şekil 2.4 Normal EKG

2.2 Kalp Sesleri

Kalbin çalışması sırasında kalp kapakçıklarının açılıp kapanması (mekanik hareketler) ve kanın kardiyovasküler sistemde hareketi esnasında meydana gelen değişimler sonucu oluşan sesler kalp sesleri olarak adlandırılır.

Kalp seslerinin analizi yardımıyla kalbin mekanik fonksiyonlarının incelenmesi yöntemine fonokardiyografi (phonocardiography), elde edilen kalp sesi işaretlerine ise fonokardiyogram (phonocardiogram) adı verilir.

Kalp sesleri, basit olarak stetoskop göğüs duvarına hafifçe temas ettirilerek dinlenir. Bu yöntem oskültasyon (auscultation) adı verilir. Kalp seslerini analiz edebilmek ve bu sesleri literatürde adlandırabilmek için kalp dört bölüme ayrılmıştır. Böylece her bölümden sesler dinlenerek, diğer bölümlerle karşılaştırılır, sonuç olarak sorunlu bölge ve sorunun nedeni nispeten tespit edilmiş olur. Bu bölgeler kalp kapaklarının anatomik olarak buldukları yerler değil, kapaklardan geçen kanın akışı yönündedir. Bu dört dinleme noktası “ Z ” şeklinde bir patern oluşturur ve bölgelerin baş harfleri ile gösterilir (M-Mitral, T-Triküspid, P-Pulmoner ve A-Aort) (Şekil 2.5).



Şekil 2.5 Oskültasyon bölgeleri

Aortik Bölge; 2. interkostal boşlukta (ICS), kalbin sağ üst tarafında yer alır ve bu bölgede duyulan sesler aort kapakçıkları ile ilgilidir.

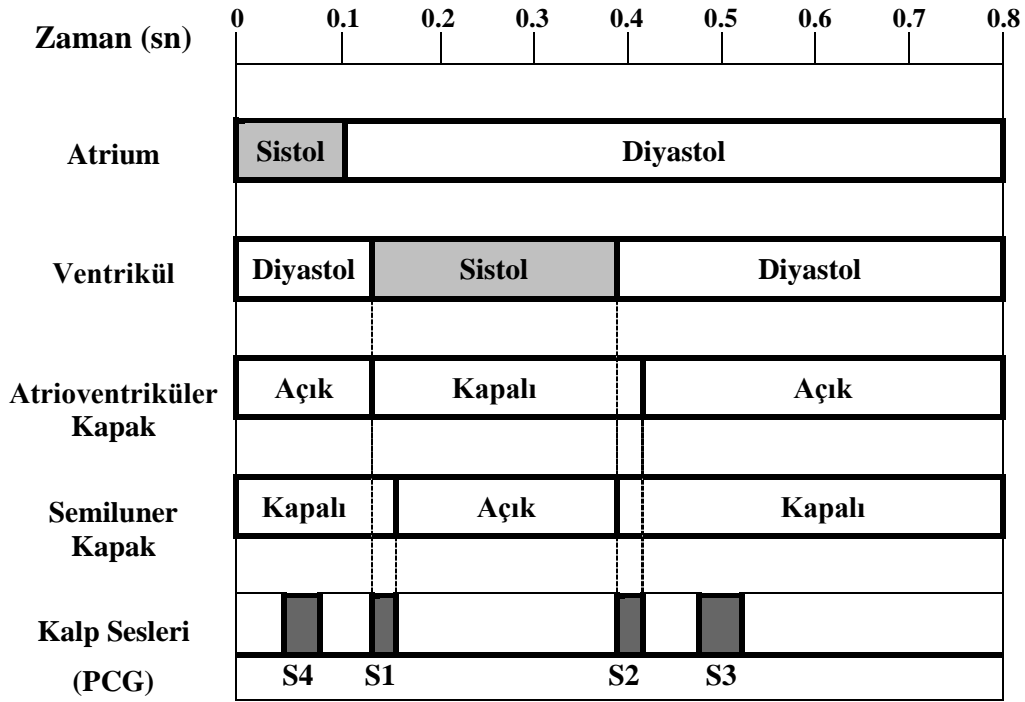

Pulmonik Bölge; 2. interkostal boşlukta (ICS), kalbin sol üst tarafında yer alır ve bu bölgede duyulan sesler pulmoner kapakçıkları ile ilgilidir.

Triküspid Bölge; 4. interkostal boşlukta (ICS), kalbin sağ tarafında yer alır ve bu bölgede duyulan sesler triküspid kapakçıkları ile ilgilidir.

Mitral Bölge; 5. interkostal boşlukta (ICS), kalbin apeks bölümünde yer alır ve bu bölgede duyulan sesler mitral kapakçıklar ve sol ventrikül ile ilgilidir.

Kalp seslerini tanımlarken, sesin frekansına, yoğunluğuna ve kalitesine dikkat edilir. Bu amaçla referans olarak kullanılan birinci (S1) ve ikinci (S2) kalp seslerinin dikkatle dinlenmesi ve dinlenme esnasında yerinin tam olarak belirlenmesi gerekir. Bu sesler kalbin çalışması sırasında sistol ve diyastol evrelerini göstermekte olup bu bölgelerdeki ses farklılaşmaları kalpteki rahatsızlıklar hakkında ön bilgiler verebilmektedir.


Sistol; kalp kaslarının, özellikle sol ventrikül (karıncık) kaslarının kasılarak kanın pulmoner arter ve aorta pompalanması zamanıdır. Diyastol; kalp ventriküllerinin gevşeyerek kanla dolduğu zamandır. Arterlere kanın gönderilmesinden sonra, kalp dinlenme evresindedir ve çıkış kapakları kapanır, bir süre sonra çıkış kapakları açılarak yeni bir çevrim başlar. Sistol ve diyastol evreleri ventriküller ve atriumlar için de ayrı ayrı atrial-sistol, atrial-diyastol, ventriküler-sistol ve ventriküler-diyastol olarak düşünülebilir (Şekil 2.6).




Şekil 2.6 Kalpteki basınç, EKG ve PCG'nin zamanla değişimi

2.2.1 Temel Sesler

Şekil 2.7’de de görüldüğü gibi, kalp sesleri öncelikle kalp kapakçıklarının açılıp kapanması sırasında oluşur. Ayrıca hastanın fizyolojisine bağlı olarak da oluşan kalp sesleri (S3 ve S4) vardır (Şekil 2.8). Kalp sesleri, kalbin çalışmasına göre aşağıdaki şekilde incelenir.



Şekil 2.7 Normal kalp sesi



Şekil 2.8 S1, S2, S3 ve S4’ten oluşan bir çevrim

2.2.1.1 Birinci Kalp Sesi (S1)

Kulakçıkların depolarizasyonu sonunda, karıncıkların depolarizasyonu başında meydana gelir. Bu esnada, halen kapalı bulunan semilunar kapakçıklara (aort ve pulmoner damar kapakçıkları) ek olarak kulakçık-karıncık (atrioventriküler - triküspid ve mitral) kapakçıklarının da kapanması, ventriküllerde oluşan basınç nedeniyle kanın ventriküllerdeki ilk hareketi ve kulakçıklardaki kan hareketinin durması sonucunda meydana gelir. Sistol evresinin başlangıcını belirtir (Şekil 2.6, 2.7).

2.2.1.2 İkinci Kalp Sesi (S2)

Karıncıkların depolarizasyonu sonunda, semilunar kapakçıkların (aort ve pulmoner damar kapakçıkları) kapanması ve kulakçık-karıncık (atrioventriküler - triküspid ve mitral) kapakçıklarının açılması sırasında meydana gelir. Diyastol evresinin başlangıcını belirtir (Şekil 2.6, 2.7).

S1 ve S2'nin şiddeti nereden dinlendiğine göre değişir. Apeks (sol ventrikülün ucu) üzerinden dinlendiğinde S1, S2'den daha şiddetlidir. S1 ve S2 üzerindeki değişiklikler anormallik olduğunu gösterebilir.

Ritimdeki değişimler, aritmi olarak adlandırılır, çoğu normal olmakla beraber sürekli olan değişimler hastalık belirtisi olabileceği gibi oskültasyon sırasında S1 ve S2'lerin ayırımını güçleştirir. S2'nin S1'den daha şiddetli ve yüksek perdeden olması, genellikle pulmoner kapağın daha sert ve hızlı kapandığı pulmoner hiper tansiyona işaret eder.

2.2.1.3 Üçüncü Kalp Sesi (S3)

Karıncıkların kanla dolması sonucunda oluşan anormal basınç nedeniyle oluşur. Diyastol evresinde yer alır (Şekil 2.6, 2.8).

2.2.1.4 Dördüncü Kalp Sesi (S4)

Kulakçıkların depolarizasyonu sonunda oluşur (Şekil 2.6, 2.8). Diyastol evresinde yer alır, çeşitli koroner arter rahatsızlıklarında, kanın çıkışının ani olarak engellenmesi durumlarında görülür.

2.2.1.5 S1 atallaşması

S1’de meydana gelen atallaşmaların nedeni, bu sesi oluşturan mitral (M1) ve triküspid (T1) kapakların kapanmasıdır. Ergenliğe kadar S1’de atallaşma geniştir ve rahatlıkla fark edilir. Erişkinlerde ise atallaşma dardır, bu nedenle iki farklı sestten çok S1’in uzaması şeklinde işitilir. Bu nedenle erişkinlerde atallaşma anormal olarak kabul edilebilir (Şekil 2.9).

2.2.1.6 S2 atallaşması

S2’de meydana gelen atallaşmaların nedeni aort kapağı kapanma sesi (A2) ve pulmoner kapağı kapanma sesi (P2)’dir. P2’nin şiddetlenmesi pulmoner hipertansiyonun belirtisidir. Yaş ilerledikçe S2 atallaşması daha zor duyulur (Şekil 2.10).

2.2.2 Ek Sesler


S1 ve S2’ye ek olarak duyulan klikler ve tok seslere ek sesler adı verilir. Sistolde duyulan ek sesler: ejeksiyon sesi ve midsistolik kliktir. Diyastolde duyulan ek sesler: S3, S4 ve açılma sesidir.

2.2.2.1 Ejeksiyon Sesi (Ej)

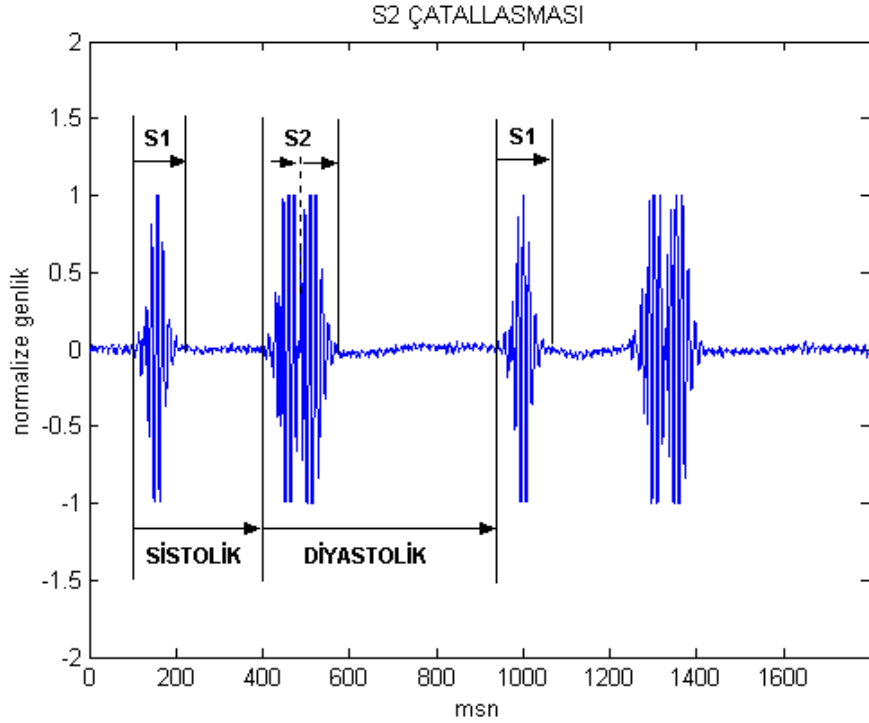
Ejeksiyon sesi (Ej), S1’den hemen sonra duyulan yüksek perdeden bir sestir. Genellikle aort ve pulmoner stenoza ile ilgilidir (Şekil 2.11). A noktasından dinlenebilir.

2.2.2.2 Midsistolik Klik

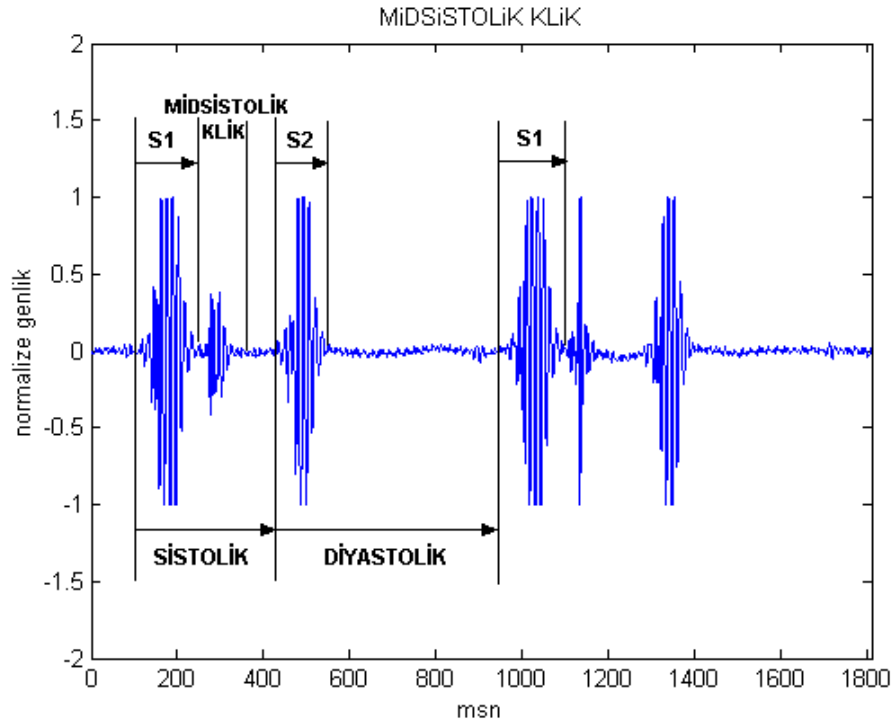
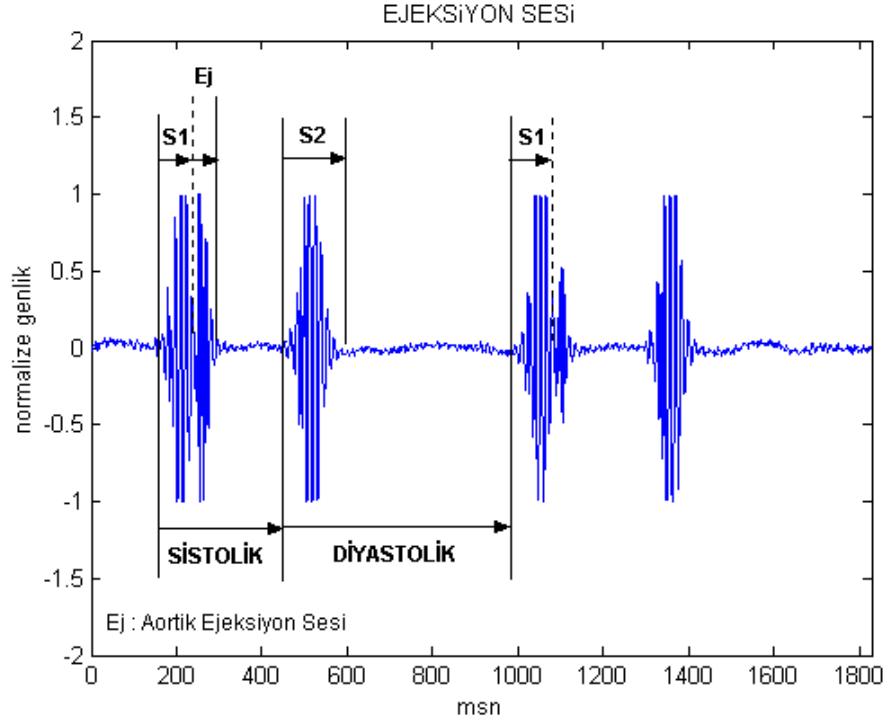
Mitral kapak prolapsında tipik olarak midsistolik klik oluşur. Sistol evresinin geç bölümlerinde görülebileceği gibi, birden fazla sayıda da olabilir (Şekil 2.12). M noktasından dinlenebilir.



Şekil 2.9 S1 çatallaşması



Şekil 2.10 S2 çatallaşması



2.2.2.3 S3


S3, S2'den sonra oluşan düşük perdeli tok bir sestir, ventriküler galo olarak da adlandırılır. Sağ veya sol ventrikülden kaynaklanabilir. M ve T noktalarında daha iyi duyulur. Ventrikül duvarının sertleşmesi veya ventrikülün aşırı dolması nedeniyle oluşur. S3 ergenliğe kadar normal olup daha sonraki yaşlarda pek duyulmaz (Şekil 2.13).

2.2.2.4 S4


S4, S1'den önce oluşan düşük perdeli tok bir sestir, atriyal galo olarak adlandırılır. Genellikle bir anormallik olduğuna işaret eder. Akut miyokard infarktüsünde ve uzun süre hipertansiyonu olan hastaların bazılarında duyulur (Şekil 2.14). M noktasından dinlenebilir. S3 ve S4 middiyastolde birleşerek sumasyon galosunu oluşturabilir.

2.2.2.5 Açılma Sesi


Normalde mitral ve triküspid kapaklarının açılması sırasında ses meydana gelmez. Fakat kalp hastalıklarında, özellikle stenozda, kapakların açılması sırasında bir klik duyulabilir. Buna açılma sesi (OS) denir (Şekil 2.15). M noktasından dinlenebilir.



Şekil 2.13 S3 sesi



Şekil 2.14 S4 sesi



Şekil 2.15 Açılma sesi

2.2.3 Üfürümler

Üfürümler, kalp içindeki türbülans kan akımlarından kaynaklanan uzun süreli seslerdir.

2.2.3.1 Üfürümlerin Özellikleri

Üfürümleri dinleme sırasında en iyi şekilde teşhis etmek için belirleyici özelliklerin bilinmesi gerekir.

Şiddeti: Üfürümler şiddetlerine göre 1~6 arasında seviyelendirilmiş olup, 6.seviye stetoskop olmadan bile duyulabilecek kadar şiddetlidir.

Ses perdesi: Ses perdesi türleri, kendi aralarında düşük, orta ve yüksek olarak 3 seviyeye ayrılmıştır.

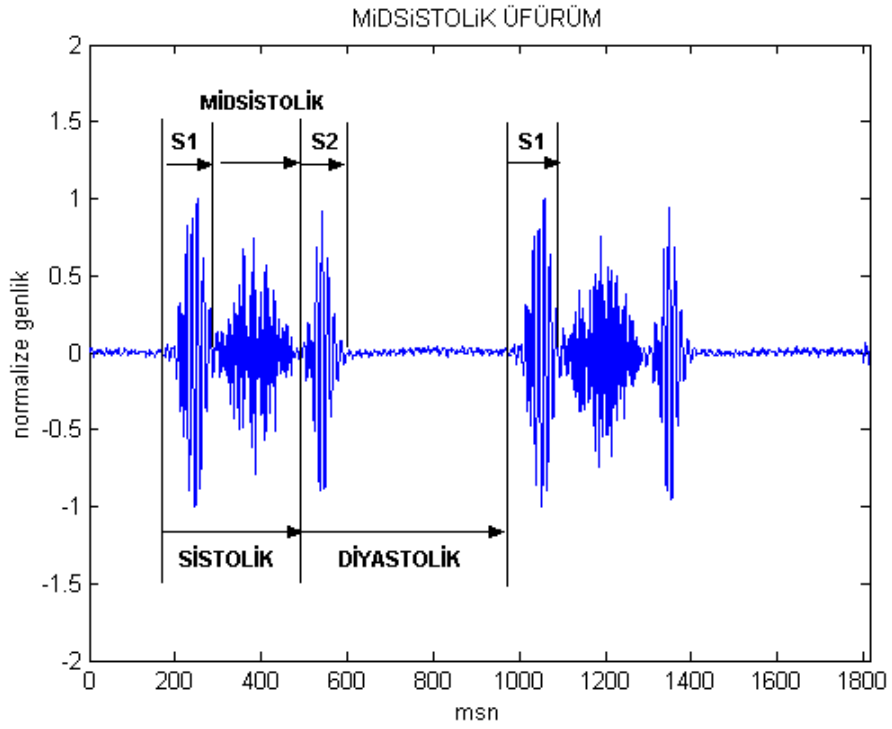
Zamanı (yeri) ve şekli:

En önemli ayırıcı faktör üfürümün bir periyod içerisindeki yeri ve şeklidir.

- 1 Sistolik ya da diyastolik: Üfürümler bir periyod içerisinde sistol veya diyastol evrelerinde erken (Şekil 2.16-1), orta (Şekil 2.16-2) , geç (Şekil 2.16-3) ya da holosistolik (Şekil 2.16-4) olarak bulunabilirler.
- 2 Genlikte meydana gelen değişimler (üfürümün konfigürasyonu): Üfürümün genliğindeki değişim giderek artan bir şekle sahip ise kreşendo (Şekil 2.16-5), zayıflayan bir şekilde ise dekreşendo (Şekil 2.16-6), önce artan sonrada artan şekilde ise elmas (kreşendo-dekreşendo veya ejeksiyon) (Şekil 2.16-7) üfürümü olarak adlandırılır.

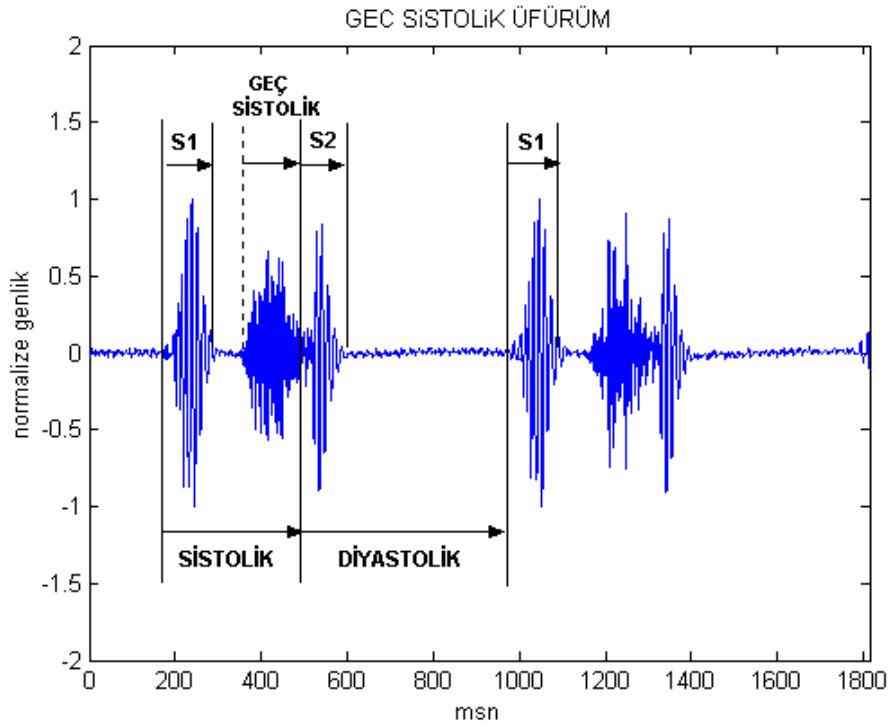
2.2.3.2 Sistolik Üfürümler

Erken sistolik üfürüm, S1 ile başlar ve midsistolde sonlanır (Şekil 2.17). Midsistolik üfürüm, S1'den daha sonra başlar ve S2'den önce sonlanır (Şekil 2.18).

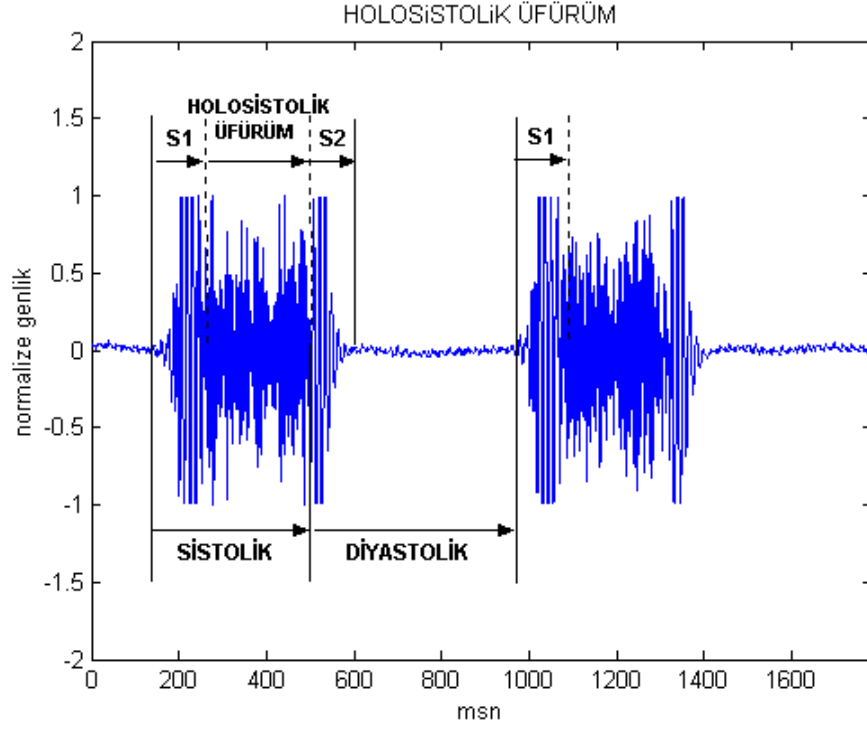


Şekil 2.18 Midsistolik üfürüm

Geç sistolik üfürüm, midsistolde başlar, S2’de sonlanır (Şekil 2.19). Holosistolik üfürüm, tüm sistol boyunca yer alır ve S1 ve S2’nin zayıflamasına neden olur (Şekil 2.20).



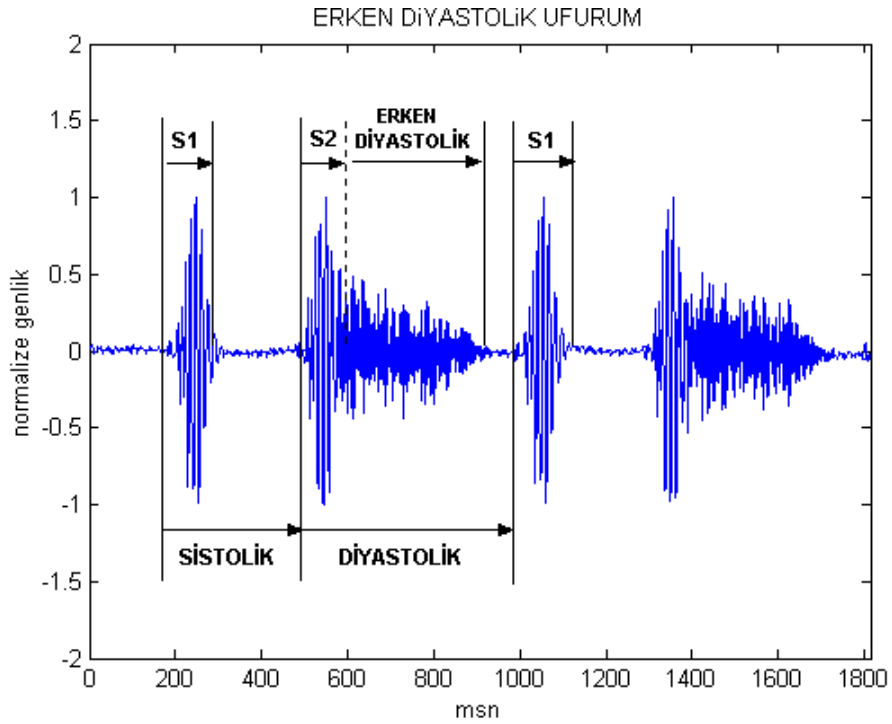
Şekil 2.19 Geç sistolik üfürüm




Şekil 2.20 Holosistolik üfürüm

2.2.3.3 Diyastolik Üfürümler

Erken diyastolik üfürüm, S2 ile başlar (Şekil 2.21). Middiyastolik üfürüm, S2'den sonra başlar ve S1'den önce son bulur (Şekil 2.22).

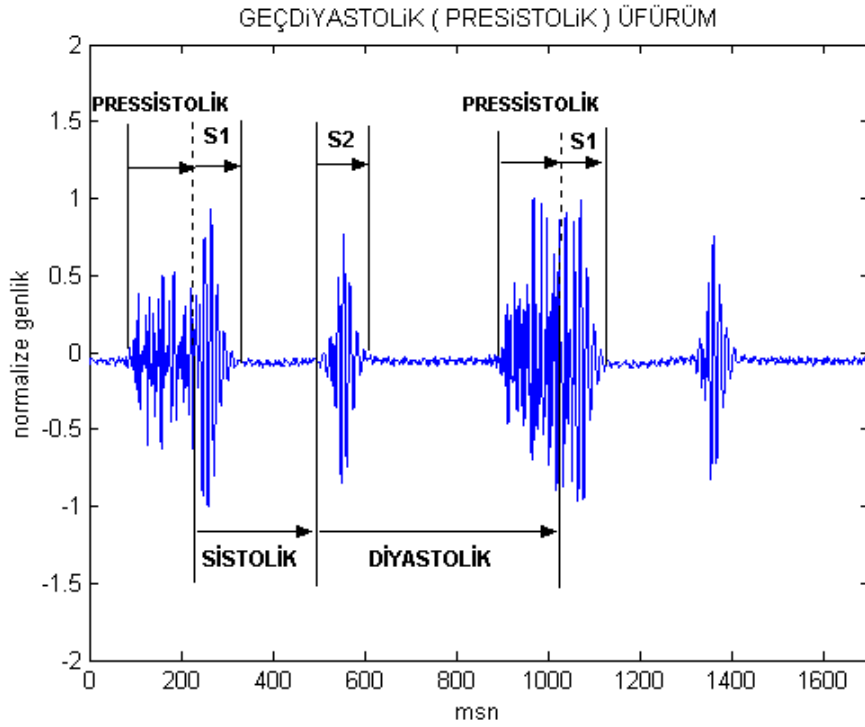


Şekil 2.21 Erken diyastolik üfürüm



Şekil 2.22 Middiyastolik üfürüm

Geç diyastolik üfürüm, S1'den hemen önce biter bu nedenle presistolik üfürüm olarak da adlandırılır (Şekil 2.23).




Şekil 2.23 Geç diyastolik üfürüm

2.2.4 Kompleks Kalp Sesleri

Aynı anda tüm kalp sesi bileşenlerinin ayırt edilmesi çok zordur. Bu nedenle oskültasyon uygulamalarında, kompleks kalp sesi bileşenlerinin ayrı ayrı dinlenmesi yöntemi tercih edilir. Burada kompleks kalp seslerine bazı örnekler verilecek ve bunların bileşenleri belirlenecektir.

2.2.4.1 Mitral Stenozu (Mitral Darlığı)


Sol kulakçıktaki kanın sol karıncığa geçmesini sağlayan ve geri dönmesini önleyen mitral kapakçığın açıklığının azalması sonucunda oluşur. Diyastolde açılma sesine ek olarak middiyastolik ve presistolik olmak üzere iki çeşit üfürüm bulunmaktadır (Şekil 2.24). M noktasından dinlenebilir.



Şekil 2.24 Mitral stenozu

2.2.4.2 Mitral Regurgitation (Mitral Yetmezliği)

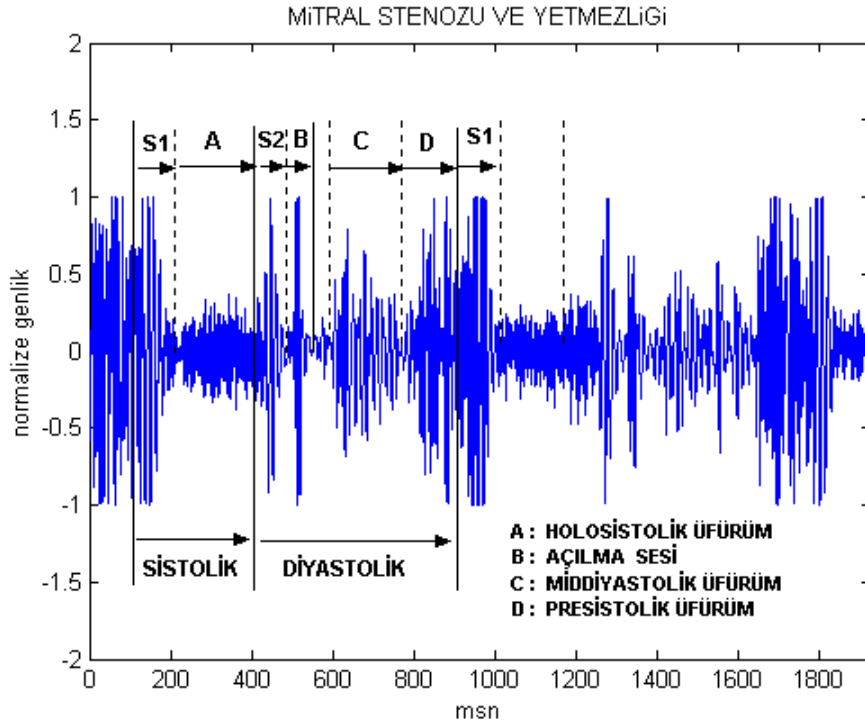
Mitral kapakçığın, sol karıncıktaki kanın sol kulakçığa dönmesini önleme özelliğini kaybetmesi sonucunda oluşur. Sistolde yüksek perdeden üfleme tarzında holosistolik bir üfürüm, diyastolde ise middiyastolik uğultu tarzında bir üfürüm ve S3 ek sesi bulunmaktadır (Şekil 2.25). M noktasından dinlenebilir.



Şekil 2.25 Mitral yetmezliği

2.2.4.3 Mitral Stenozu ve Yetmezliği


Burada presistolik ve sistolik üfürüm birleşmiştir (Şekil 2.26). M noktasından dinlenebilir.



Şekil 2.26 Mitral stenozu ve yetmezliği

2.2.4.4 Aort Stenozu (Aort Darlığı)


Kalbin sol karıncığı ile aort arasındaki aort girişinde veya aort kapakçığındaki daralma nedeniyle oluşur. Darlık kalbin kan pompalama yani kanın aorta geçişini güçleştirir. Sistolde, aortik ejeksiyon ve orta dereceden elmas şeklinde bir ses, diyastolde ise S4 ek sesi bulunmaktadır (Şekil 2.27). A noktasından dinlenebilir.



Şekil 2.27 Aort stenozu

2.2.4.5 Aort Yetmezliği

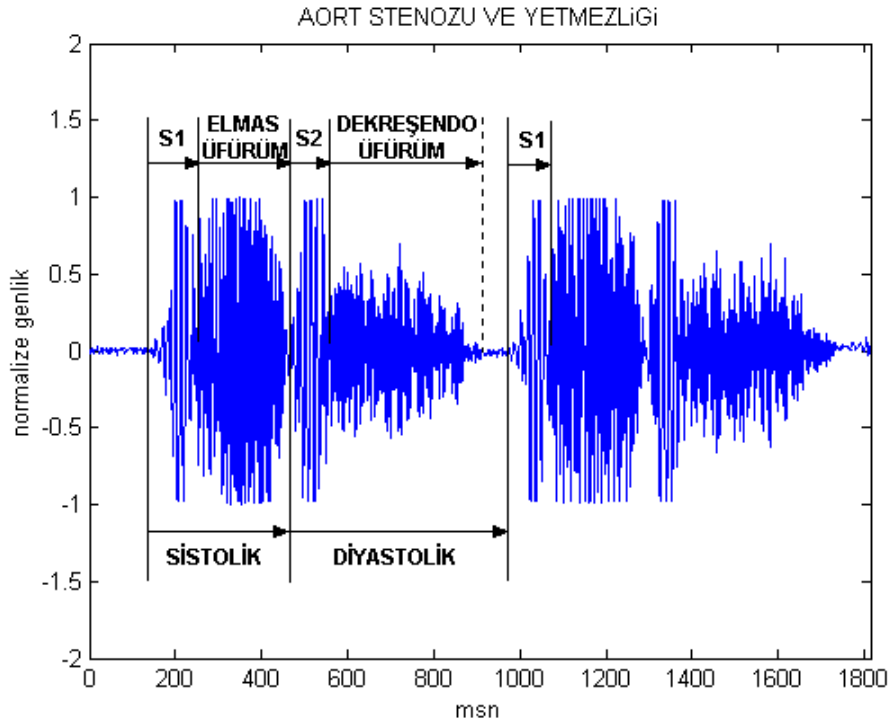
Aort ağzındaki kapakçıkların, kalbin sol karıncığından pompalanan kanın aorttan kalbe geri dönmesini engelleyememesi sonucunda oluşur. Aort yetmezliği tek başına bulunduğu anda, diyastolik dekreşendo bir üfürüme neden olur (Şekil 2.28). A noktasından dinlenebilir.



Şekil 2.28 Aort yetmezliği

2.2.4.6 Aort Stenozu ve Yetmezliği

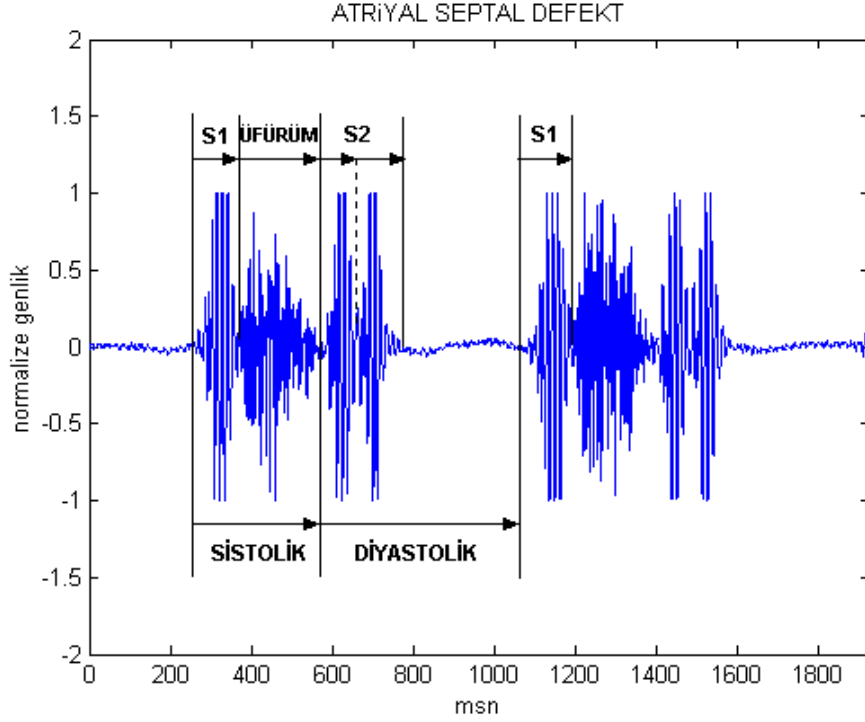
Aort yetmezliği ve aort stenozu birlikte görülürse oluşur (Şekil 2.29). A noktasından dinlenebilir.



Şekil 2.29 Aort stenozu ve yetmezliği

2.2.4.7 Atrial Septal Defect (ASD)

Atrial septal defect üfürümü, sağ ventrikülün aşırı doluşuna baęlı olarak iki bileşeni vardır. Birincisi, S2'de meydana gelen geniş çatallaşma, ikincisi ise pulmoner stenoza baęlı sistolik üfürümdür (Şekil 2.30). P noktasından dinlenebilir.



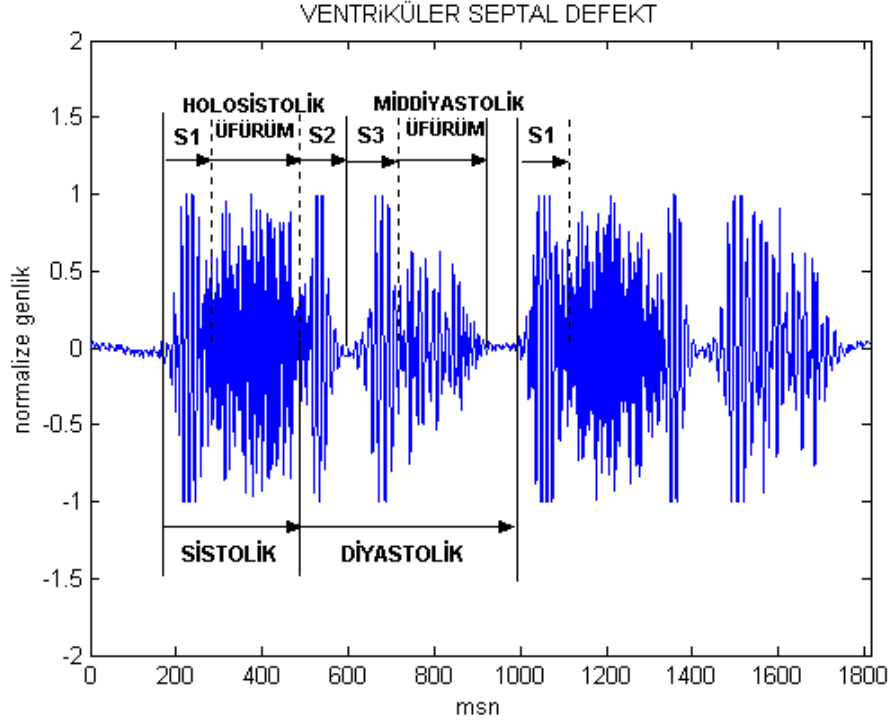
Şekil 2.30 Atrial Septal Defect (ASD)

2.2.4.8 Ventricular Septal Defect (VSD)

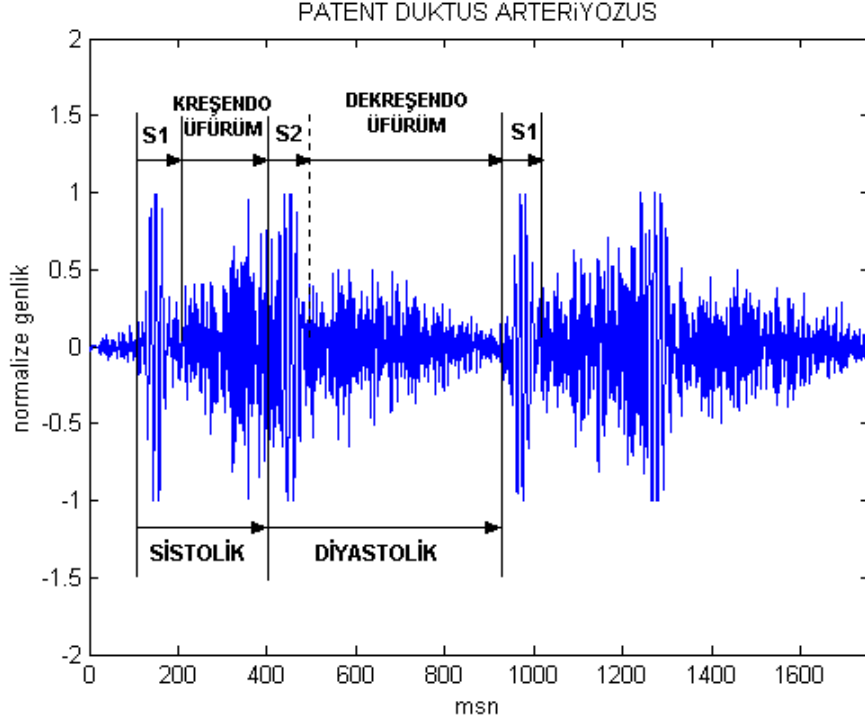
Ventricular septal defect üfürümünde, mitral yetmezlięin üfürümüne benzer şekilde holosistolik bir üfürüm duyulur. Ayrıca S3 ve middiyastolik bir üfürümde duyulabilir. Ventriküler septal defect, mitral yetmezlięinden daha geniş bir alana yayılması ile ayırt edilir (Şekil 2.31). T noktasından dinlenebilir.

2.2.4.9 Patent Ductus Ateriosus (PDA)

Aort ve sol pulmoner arter arasındaki kanalın kalıcı olarak açık kalması nedeniyle oluşur. Sistolde kreşendo, diyastolde ise dekreşendo tarzında üfürüm bulunmaktadır (Şekil 2.32). P noktasından dinlenebilir.



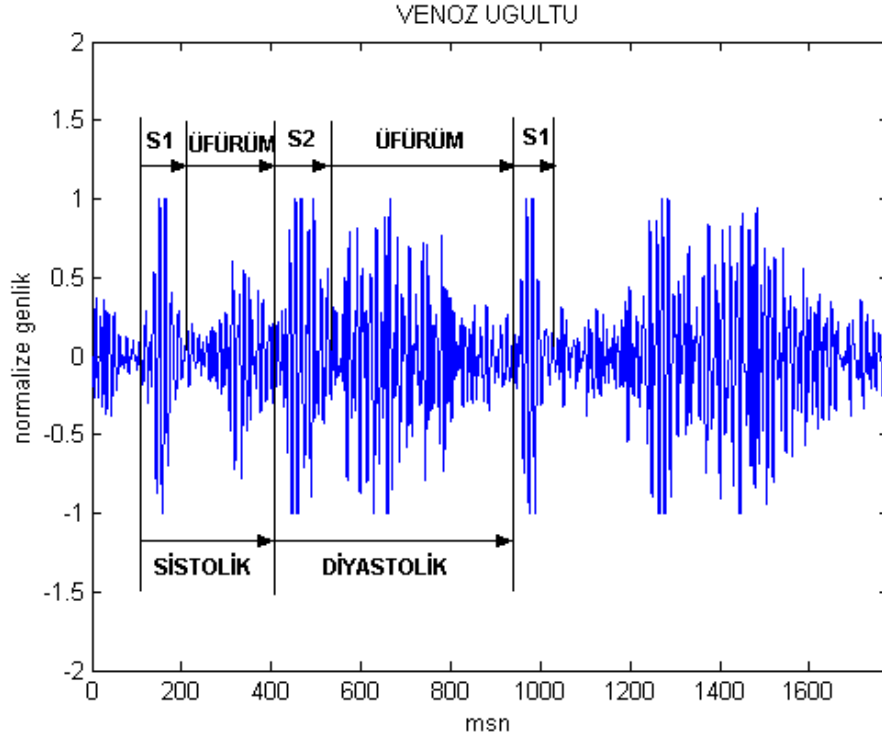
Şekil 2.31 Ventriküler Septal Defekt (VSD)



Şekil 2.32 Patent Ductus Ateriosus (PDA)

2.2.4.10 Venoz Uğultu

Sistol ve diyastolde iki sürekli üfürümden oluşur, çocuklarda ve genç erişkinlerde görülür (Şekil 2.33). A noktasından dinlenebilir.



Şekil 2.33 Venoz uğultu

2.2.4.11 Pulmoner Kapak Stenozu

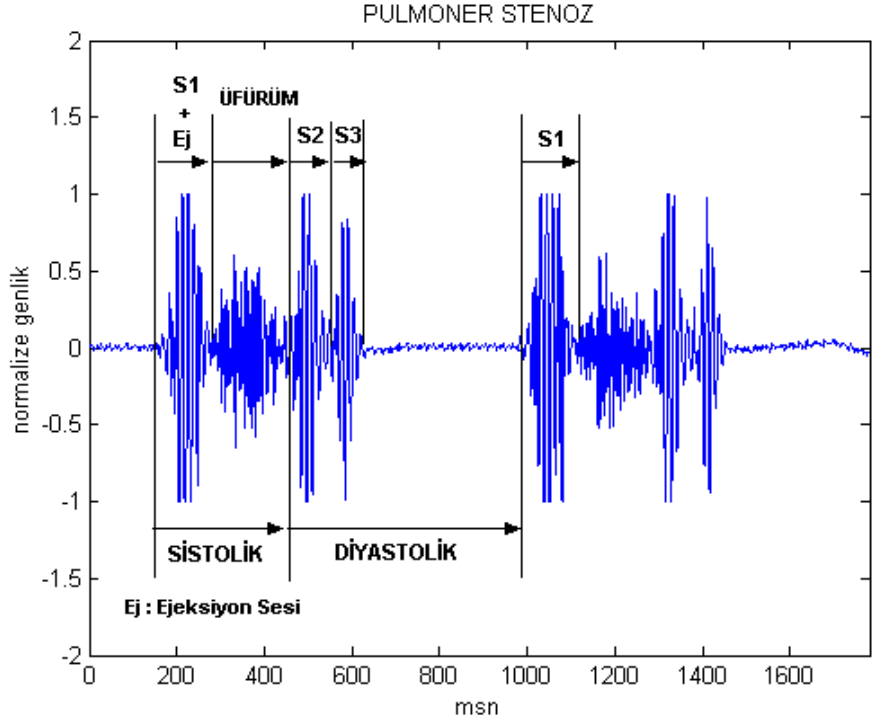
Kalbin sağ karıncık ile akciğer atardamarı arasındaki pulmoner (akciğer) kapakçığının kanın akciğerlere geçişini güçleştirilmesi sonucunda oluşur. Sistolde pulmoner ejeksiyon ve sistolik üfürüm sesi, diyastolde ise geniş çatallaşmış S2 sesi duyulur (Şekil 2.34). P noktasından dinlenebilir.

2.2.4.12 Hipertrofik Kardiyomiyopati (IHSS)


Ejeksiyon tipi sistolik üfürüme ek olarak S4 ek sesinden oluşur (Şekil 2.35). T noktasından dinlenebilir.

2.2.4.13 Perikardiyal Sürtünme Sesleri


Perikardiyal sürtünme sesleri, kan akışına bağlı olarak değil kalbin hareketinden oluşur. İki yada üç bileşenden oluşur (Şekil 2.36). T noktasından dinlenebilir.



Şekil 2.34 Pulmoner stenozu




Şekil 2.35 Hipertrofik Kardiyomiyopati (IHSS)



Şekil 2.36 Perikardiyal sürtünme sesleri

2.2.4.14 Mediastinal Gıcırtı Sesi (Hamman İşareti)

Mediastende hava bulunduğu zaman oluşur (Şekil 2.37). M noktasından dinlenebilir.



Şekil 2.37 Mediastinal gıcırtı sesi (Hamman İşareti)

3. ÖZNETELİK ÇIKARTMA YÖNTEMLERİ

3.1 Giriş

Sınıfları temsil etmek ve sınıfların öznitelik uzayında farklı bölgelerde öbekleşmesini sağlamak amacıyla uygulanan işleme öznitelik çıkartma işlemi denir. Kesin bir yöntemi olmamakla birlikte tasarımcının ilgilenilen konu hakkındaki önsezilerine bağlıdır. Öznitelik çıkartma işleminin performansı, bulunan sınıf öbeklerinin çapına, öbeklerin birbirinden uzaklığına ve işlemler sırasında kullanılacak alt kümedeki örnek sayısına bağlıdır. Karar verme mekanizması içinde minimum öbek çapı ve maksimum öbekler-arası uzaklığı veren öznitelik çıkartma işlemi bulunmalıdır. Özniteliklerin sınıfları birbirinden ayırma yeteneği sayesinde karar verme mekanizması içine genelleme özelliği katılır. Bu özellik sayesinde eğitim kümesi içinde bulunmayan vektörler de doğru olarak sınıflanır. Seçilen özniteliklerin mümkün olduğu kadar basit işlemlerle oluşturulması, sınıflama ve eğitim zamanlarını kısaltarak, algoritmanın hızlı çalışmasını sağlar.

Sınıfları ayırt edici özniteliklerin bulunması işlemi, seçilen problemin yapısına bağlıdır. Az sayıda örnek, sınıfların sınırlarının doğru olarak belirlenmesini zorlaştıracaktır. Ayrıca sınıfları ayırt edici özniteliklerin tam olarak belirlenememesi, öznitelik uzayında sınıfların saçılmasına sebep olmaktadır.

Bu bölüm içerisinde öznitelik çıkartmak amacıyla üç yöntem üzerinde durulmuştur. Bu yöntemler: Fourier dönüşümü, kısa zaman Fourier dönüşümü ve dalgacık dönüşümü yöntemleridir.

3.2 Fourier Dönüşümü (FD)

Uygulamalarda kullanılacak işaretler incelendiğinde pratikte karşılaşılan birçok işaret, zaman domeni işareti olup, ölçülen büyüklük zamanın bir fonksiyonudur. Genelde orijinal işareten yeterli bilgi elde edilemez. Bu nedenle, işaretin

matematiksel bir dönüşüm uygulanarak farklı bir domene taşınması gerekir ve bu domende işareti temsil eden bileşenlerden işaret hakkında bilgi sağlanır. Örneğin elektrik mühendisliğinde sıkça kullanılan Fourier dönüşümü (FD) ile işaretin frekans spektrumu (frekans bileşenleri) elde edilir. Zaman domeninde saklı bilgi, frekans domeninde açığa çıkarılmış olur.

Zaman domenindeki ham işaretin frekans içeriğini belirlemek için kullanılan Fourier dönüşümü aşağıdaki iki eşitlik ile ifade edilmektedir:

$$\begin{aligned} X(\omega) &= \int_{-\infty}^{\infty} x(t) \cdot e^{-j\omega t} \cdot dt \\ x(t) &= \frac{1}{2\pi} \int_{-\infty}^{\infty} X(\omega) \cdot e^{j\omega t} \cdot d\omega \quad \omega = 2\pi f \end{aligned} \quad (3.1)$$

Fourier dönüşümü ile işaret, farklı frekanslara sahip kompleks üstel fonksiyonlara ayrıştırılır. Denklemlerde görülen t , zamanı; ω , açısal frekansı; f ise frekansı belirtmektedir. x , zaman domenindeki işareti, X ise frekans domenindeki işareti göstermektedir. (3.1) eşitliğinde, üstte $x(t)$ 'nin Fourier dönüşümü, altta ise ters Fourier dönüşümü gösterilmektedir.

Denklem (3.1) incelenecek olursa, $x(t)$ işareti belirli bir f frekansındaki üstel bir terim ile çarpılmış ve çarpımın eksi sonsuzdan artı sonsuza tüm zaman üzerinden integrali alınmıştır. Dikkat edilirse, f frekanslı bileşen zamanın hangi anında ortaya çıkarsa çıkısın integrasyona etkisi aynı olacaktır. f frekanslı bileşenin t_1 ya da t_2 anında ortaya çıkması integrasyon sonucunu değiştirmeyecektir. Fourier dönüşümü yalnızca belirli bir frekans bileşeninin var olup olmadığını belirtmektedir (FD ile işaretin sadece spektral içeriği elde edilir).

Çalışma içerisinde ayrık Fourier dönüşümleri kullanılmaktadır. Ayrık Fourier dönüşümleri de $\pm \infty$ aralığında tanımlıdır. İşaretin sabit bir pencere içerisinde ayrık olarak tanımlanması durumunda aşağıdaki ifadeler elde edilir. Denklemlerde görülen $x(n)$, ayrık zaman domeni işareti, $X(k)$ ise ayrık frekans domeni işaretidir.

$$\begin{aligned} X(k) &= \sum_{n=0}^{N-1} x(n) \cdot e^{-j2\pi kn/N} \\ x(n) &= \frac{1}{N} \cdot \sum_{k=0}^{N-1} X(k) \cdot e^{j2\pi kn/N} \end{aligned} \quad \begin{aligned} & k, n \in Z, N=\text{pencere genişliği} \\ & (3.2) \end{aligned}$$

3.3 Kısa Zaman Fourier Dönüşümü (KZFD)

Kısa zaman Fourier dönüşümü, işaretin tanımlanması için önemli olabilecek bileşenlerin zamanın hangi anlarında ortaya çıktığı bilgisini elde etmek amacıyla geliştirilmiş bir yöntemdir.

Fourier dönüşümü, işaretin içerisinde hangi frekans bileşenlerinin olduğunu inceler, bu bileşenlerin zamanın hangi anında ortaya çıktıkları hakkında bir bilgi içermez. Durağan işaretlerde bu yöntem sorun çıkartmamaktadır fakat durağan olmayan işaretlerin incelenmesinde değişim anının belirlenememesi ve ani geçişler sonucunda işaretin Fourier dönüşümünde dalgalanmalar gözlenmektedir.

Bu sorunlarla karşılaşmamak için özellikle durağan olmayan işaretlerin frekans spektrumu analizinde kısa zaman Fourier dönüşümü kullanılmaktadır. Bu yöntem ile incelenecek durağan olmayan işaret, seçilen bir pencere içerisinde durağan kabul edilerek, pencere boyunca işaretin Fourier dönüşümü alınır ve bu işlem seçilen pencere işaret üzerinde gezdirilerek tekrarlanır.

$$\text{KZFD}(\tau, f) = \int_{-\infty}^{\infty} [x(t) \cdot w^*(t - \tau)] \cdot e^{-j2\pi ft} dt \quad (3.3)$$

Denklemden $x(t)$, orijinal işareti; $w(t)$ seçilen pencere fonksiyonunu, $*$ kompleks konjugeyi, f frekansı ve τ ise pencere fonksiyonunun zamanda öteleme miktarıdır. Dönüşüm τ ve f 'in fonksiyonudur.

Her τ ve f için kısa zaman Fourier dönüşümü katsayıları hesaplanır ve elde edilen genlikler de dikkate alınarak 3 boyutlu bir grafik elde edilir. İşaret üzerinde yapılan işlemler sırasında belirlenen pencere genişliğinin büyük önemi vardır.

Pencere genişliği durağanlık varsayımını geçerli kılacak kadar dar olmalıdır. Dar bir pencere seçilmesi durumunda hem bu varsayım geçerliliğini koruyacak hem de FD'de sağlanamayan zamanda çözünürlük iyileşecektir. Fakat dar bir pencere seçilmesi durumunda kötü bir frekans çözünürlüğü elde edilir. Pencere genişledikçe frekans çözünürlüğü artar, ancak zamanda çözünürlük azalır. Sonuçta işarete KZFD'yi uygulamadan önce zamanda yada frekansta çözünürlüğün sağlanması ile ilgili önemli bir karar vermek gerekir.

3.4 Dalgacık Dönüşümü

Kısa zaman Fourier dönüşümünde işaretin zaman-frekans spektrumu elde edilmesine rağmen, seçilen pencerenin genişliği dönüşümün etkinliğinde önemli rol oynamaktadır, bu nedenle pencere genişliği ile ilişkili bir çözünürlük problemi bulunmaktadır.

KZFD, tüm zamanlarda sabit çözünürlük verdiği için KZFD'nin çözünürlük ile ilgili problemlerini gidermek üzere zamanda değişken çözünürlük veren dalgacık dönüşümü geliştirilmiştir. Dalgacık dönüşümüne, frekans cevabı zamanla değişen durağan olmayan işaretlerin analizinde ihtiyaç duyulmaktadır.

Uygulamada dalgacık dönüşümü çeşitli amaçlarla iki farklı yöntemle gerçekleştirilir: Sürekli dalgacık dönüşümü (SDD) ve ayrık dalgacık dönüşümü (ADD). Çalışmada içinde ADD kullanılmıştır.

3.4.1 Sürekli Dalgacık Dönüşümü (SDD)

Dalgacık analizi KZFD'ye benzer şekilde yapılır: İşaret, KZFD'de bir pencere fonksiyonu ile çarpılırken, dalgacık dönüşümünde dalgacık olarak adlandırılan bir fonksiyonla çarpılır. SDD aşağıdaki şekilde ifade edilir:


$$SDD(\tau, s) = W(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \cdot \psi^* \left(\frac{t - \tau}{s} \right) dt \quad (3.4)$$

Görüldüğü gibi SDD, τ ve s değişkenlerinin (öteleme ve ölçek parametreleri) bir fonksiyonudur. $\psi(t)$, dönüşüm fonksiyonudur ve ana dalgacık olarak adlandırılır. Dönüşümde kullanılan farklı genişliğe sahip diğer pencere fonksiyonları ana dalgacıktan ölçekleme yoluyla türetilir. Öteleme terimi, KZFD'de rastlanılan şekliyle pencerenin yerini ifade etmektedir. Pencere, işaret üzerinde gezdirilir. Dönüşümden zaman bilgisi öteleme ile sağlanır. KZFD'deki gibi bir frekans parametresi yoktur; bunun yerini 1/frekans olarak tanımlanan ölçek parametresi (s) almıştır.


Ölçek değeri küçük ise (yüksek frekanslar); işaretin zamanda çözünürlüğü yüksektir, fakat zamanda çözünürlüğün iyi olması, frekans çözünürlüğünün kötü olması anlamına gelir.

Ölçek değeri büyük ise (düşük frekanslar); işaretin frekans çözünürlüğü yüksek olup, zaman çözünürlüğü düşüktür sonuç olarak işaret hakkında global bir bilgi elde edilir.


Ölçek parametresinin değeri değiştirilerek, ana dalgacığın sıkıştırılması ya da genişletilmesiyle SDD’de kullanılan pencereler elde edilir. Morlet (Şekil 3.1), Daubechies (Şekil 3.2) ve Meksika Şapkası (Şekil 3.3) dalgacıkları, pencere fonksiyonu olarak kullanılan fonksiyonlara örnektir.



Şekil 3.1 Morlet dalgacık fonksiyonu



Şekil 3.2 Daubechies dalgacık fonksiyonu



Şekil 3.3 Meksika Şapkası dalgacık fonksiyonu

3.4.2 Ayrık Dalgacık Dönüşümü (ADD)

Ayrık dalgacık dönüşümü (ADD) hesap yükünü azaltmasının yanı sıra orijinal işaretin analiz ve sentezi için yeterli bilgiyi de sağlamaktadır.

Ayrık dalgacık dönüşümünde temel düşünce sürekli dalgacık dönüşümündeki düşünce ile aynıdır. Sayısal filtreleme teknikleri kullanılarak sayısal işaretin zaman-ölçek temsili elde edilmektedir. SDD farklı ölçeklerdeki dalgacık ile işaret arasındaki ilişkiyi (korelasyonu) belirtmektedir. Burada benzerlik ölçütü ölçektir (ya da frekans). SDD, analiz penceresinin ölçeği değiştirilerek ve bu pencere zamanda kaydırılarak, işaretle pencere çarpılıp tüm zaman üzerinden integrali alınarak hesaplanır. ADD'de ise işareti farklı ölçeklerde analiz edebilmek için çeşitli filtreler kullanılmaktadır. İşaretteki yüksek frekanslı değişimleri analiz etmek için işaret yüksek geçiren filtreler serisinden, alçak frekanslı değişimleri analiz etmek için ise alçak geçiren filtreler serisinden geçirilir.

İşaretteki ayrıntı bilgisinin miktarının ölçütü olan işaret çözünürlüğü, filtreleme işlemi ile değiştirilmektedir. Üst-örnekleme ve alt-örnekleme işlemleri ile de ölçek değiştirilmektedir. Alt-örnekleme, örnekleme oranının düşürülmesine ya da işareten bazı örneklerin atılmasına karşılık gelmektedir. Üst-örnekleme ise işarete yeni örnekler ilave edilerek işaretin örnekleme oranının artırılması anlamına gelmektedir.

ADD katsayıları genellikle bir düzlem üzerindeki SDD'den örneklenir. Yani, $s_0=2$ ve $\tau_0=1$ olmak üzere, $s=2^j$ ve $\tau=k.2^j$ ($s=s_0^j$ ve $\tau=k.s_0^j.\tau_0$, $j \in \mathbb{Z}$) alındığında ikili (dyadic) dalgacık dönüşümü elde edilir.

Ayrık zaman işaretini ($x(n)$, n tamsayı) darbe cevabı $h(n)$ olan yarım bantlı sayısal alçak geçiren filtreden geçirerek işlemler başlatılır.

$$x(n) * h(n) = \sum_{k=-\infty}^{\infty} x(k).h(n - k) \quad (3.5)$$

Yarım bantlı alçak geçiren filtre işarettaki en yüksek frekansın yarısından büyük olan tüm frekansları yok eder. Örneğin bir işaret en fazla 1000 Hz'lik bileşene sahipse, yarım bantlı alçak geçiren filtreleme ile 500 Hz'in üzerindeki tüm frekanslar yok edilir. İşarettaki en yüksek frekans bileşeni filtreleme işleminden sonra yarıya düştüğünden, Nyquist kriteri uyarınca, işarettaki örneklerin yarısı atılabilir. Böylece

işaret 2 faktörüyle alt-örneklenir ve yarı sayıda noktaya (örneğe) sahip olur. Sonuç olarak işaretin ölçeği 2 katına çıkmıştır.

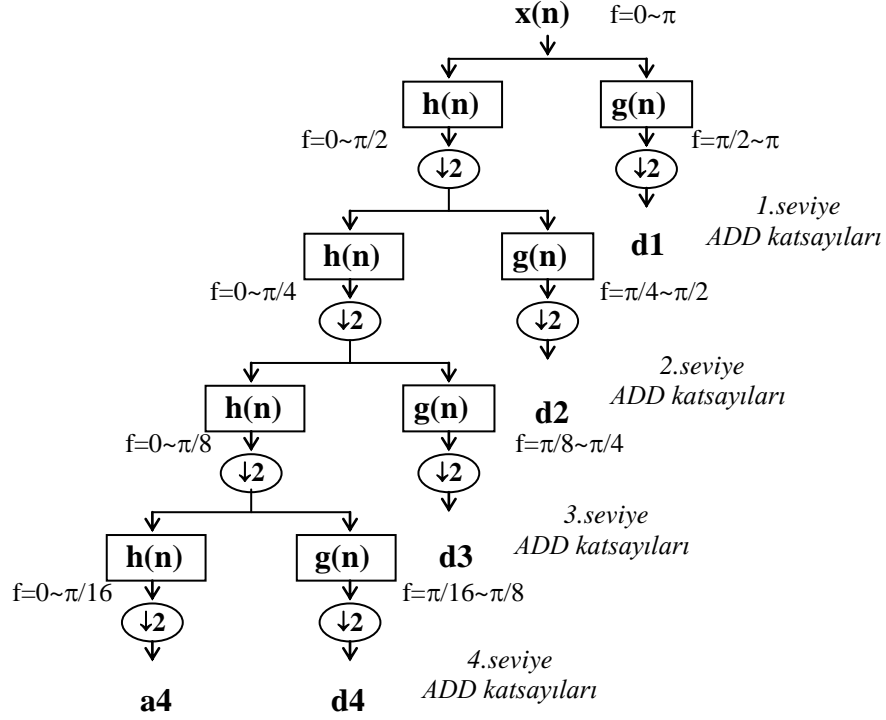
Oysa alçak geçiren filtreleme ile yüksek frekans bilgisi yok edilmiş ama ölçek değişmeden kalmıştı. Ölçek sadece alt-örnekleme ile değişmektedir. Çözünürlük ise işaretteki bilgi miktarıyla ilişkili olduğundan filtreleme işlemlerinden etkilenir. Yarım bantlı alçak geçiren filtreleme, frekansların yarısını yok ederek bilginin de yarısının kaybolmasına neden olur. Böylece filtreleme sonrasında çözünürlük yarıya düşer. Ancak dikkat edilirse, filtrelemenin ardından alt-örnekleme işlemi çözünürlüğü etkilememektedir. Çünkü işaretin spektral bileşenlerinin yarısını çıkarmak zaten örneklerin de yarısını gereksiz kılar. Yarı sayıda örnekten bilgi kaybına uğramadan kurtulmak mümkündür. Özetle alçak geçiren filtreleme çözünürlüğü yarıya düşürürken ölçeği değiştirmez. Yarı sayıda örneğe artık ihtiyaç olmadığından işaret daha sonra 2 ile alt-örneklenir. Böylece ölçek 2 katına çıkar. Anlatılanları matematiksel olarak şöyle ifade edebiliriz;

$$y(n) = \sum_{k=-\infty}^{\infty} h(k).x(2n - k) \quad (3.6)$$

ADD'nin nasıl hesaplandığı incelenirse; ADD, işareti kaba bir yaklaşık işarete ve ayrıntı (detay) işaretine ayrıştırarak işareti farklı frekans bantlarında farklı çözünürlüklerde analiz eder. ADD iki fonksiyon kümesi kullanır; sırasıyla alçak geçiren ve yüksek geçiren filtrelere karşılık gelen ölçek fonksiyonu ve dalgacık fonksiyonu.

İşarete baskın olan frekanslar ait oldukları frekans bandı bölgesinde yüksek genlik gösterirler. Bunların dışında kalan frekans bandlarını saklamak gereksizdir. Bu nedenle orijinal işareti belirli bir hata ile temsil etmek için yüksek genlikli bileşenlerin bulunduğu frekans bantlarına karşılık gelen seviyelerdeki ADD katsayılarını kullanmak yeterli olur.



Şekil 3.4'te ayırık dalgacık dönüşümü kullanılarak elde edilen katsayılar gösterilmektedir. Alçak geçiren filtre çıkışındaki işaretin alt-örneklenmesiyle elde edilen işaret yaklaşıklık katsayıları olarak adlandırılır. Yüksek geçiren filtre çıkışındaki işaretin alt-örneklenmesiyle elde edilen işaret ise ayrıntı (detay) katsayıları olarak adlandırılır.



Şekil 3.4 Dalgacık ağacı

Şekil 3.4'teki $h(n)$ ve $g(n)$ filtreleri için Daubechies dalgacık filtreleri kullanılmıştır. Şekil 3.5'te Daubechies-10 dalgacığın için $g(n)$ yüksek geçiren filtre (YGF) ile ilişkili ana dalgacık fonksiyonu, $h(n)$ alçak geçiren filtre (AGF) ile ilişkili ölçek fonksiyonu gösterilmektedir.

Daubechies tarafından geliştirilen dalgacıklar (Daubechies-M, $M=1,2,\dots$), ortonormaldir. Dalgacıkların ortonormal özelliğe sahip oluşu orijinal işarete geri dönülebilmesini (sıkıştırma tekniklerinde) sağlamaktadır. Çalışma içerisinde Daubechies-10 ($M = 10$) dalgacıkları kullanılmaktadır. M sayısı, temel filtreyi tanımlamaktadır. Daubechies-M dalgacığın ile ilişkili filtreler, $2 \times M$ (çalışmada 20) katsayıdan meydana gelmektedir. M değeri büyüdükçe filtreler, kesim frekanslarında daha keskin geçişler yapar; ancak filtre çıkış değerini bulmak için daha fazla hesaplama yapılmaktadır.



Şekil 3.5 Daubechies-10 dalgacık ve ölçek fonksiyonu

4. SINIFLAYICI OLARAK KULLANILAN YAPAY SİNİR AĞLARI

4.1 Yapay Sinir Ağının Tanımı

Birçok önemli buluşun doğanın taklit edilmesiyle ortaya çıktığı gibi, son 50-60 yıl içerisinde, insan beyninin algılama, öğrenme ve karar verme özelliği de, insan beyni fizyolojisi incelenerek bilgisayar modelleriyle taklit edilmeye çalışılmış ve kendine has bir hesaplama yöntemi bulunan yapay sinir ağları (YSA) adında modeller elde edilmiştir [4]. Bu anlamda yapay sinir ağları konusu üzerinde çalışırken, bir ağ yapısının çözebileceği problem uzayının, insan beyninin çözebildiği problem uzayının oldukça kısıtlanmış bir alt kümesi olacağı gözden kaçırılmamalıdır [5].

Yapay sinir ağlarının araştırmalarda sıkça kullanıldığı gözlenmektedir. Ancak genel olarak ağların, bir uzaydan diğer uzaya geçiş amacıyla kullanıldığı söylenebilir. Yapay sinir ağları ile eğitim kümesindeki öznitelik vektörleri kullanılarak iki uzay arasındaki lineer olmayan transfer fonksiyonuna adım adım yaklaşılmaktadır. YSA'ların sınıflayıcı olarak kullanılmaları durumunda, transfer fonksiyonunun çıkışı ikili kodlar ile temsil edilmektedir [3]. Yapay sinir ağlarının sınıflayıcı olarak kullanılmalarının başlıca nedenleri:

- a) Sonuca adım adım yaklaşılr.
- b) Giriş vektörleri için genelleme yeteneğine sahiptir.
- c) Fiziksel olarak gerçekleştirilebilirler.
- d) Hesaplamalarda paralel bir yapı kullanıldığından sınıflama işlemi hızlıdır.
- e) Karmaşık sınıf dağılımlarını temsil edebilme yeteneğine sahiptir.


Yapay sinir ağı, aşağıdaki tanımlamaları ve sınırlamaları içeren paralel bilgi işleme özelliğine sahip yönlü bir graftır [6].

- a) Yönlü grafın düğümleri işlem elemanı olarak tanımlanır.
- b) Yönlü dallar bağlantılara karşılık düşer ve tek yönlü işaret iletim yolu olarak çalışırlar.
- c) Her bir işlem elemanı, belirli sayıda giriş bağlantısına sahiptir.
- d) Her bir işlem elemanı, belirli sayıda çıkış bağlantısına sahiptir. Ancak çıkış işaretlerinin değeri aynı olmalıdır
- e) İşlem elemanları yerel belleklere sahip olabilir.
- f) Her işlem elemanı, giriş işaretini ve yerel belleği kullanan bir transfer fonksiyonuna sahiptir. Bu fonksiyon işlem elemanının çıkış değerini oluşturur. Transfer fonksiyonu sürekli veya ayrık olarak çalıştırılabilir. Ayrık çalıştırma modunda fonksiyon, aktif işareti ile kontrol edilir.
- g) Yönlü bağlantı ve işlem elemanlarının bir araya gelmesi ile oluşan yapıya, yapay sinir ağı (YSA) adı verilir. Bu yapı, dış çevreden giriş bağlantıları yolu ile işaret alır ve çıkış bağlantıları yolu ile işaret gönderir.


Şekil 4.1'de gösterildiği gibi işlem elemanının transfer fonksiyonu, diğer işlem elemanlarından ve yerel belleğinden gelen bilgileri giriş olarak alır; çıkışını ise diğer elemanlarına gönderilmek üzere kopyalar. Şekil 4.2'de işlem elemanlarının birbirleri ile olan bağlantıları gösterilmiştir. Yapay sinir ağları, aynı yapıdaki ve aynı transfer fonksiyonuna sahip işlem elemanlarının oluşturduğu katmanlardan (alt kümelerden) meydana gelir. Aynı katman içindeki işlem elemanları birbirleriyle ve diğer katmandaki elemanlar ile bağlantı oluşturabilir.

Yapay sinir ağlarının en temel yapı taşı olan perceptron, bir transfer fonksiyonundan, birden fazla giriş, giriş sayısı kadar bellek elemanı ve en az bir çıkıştan oluşan en basit yapay sinir ağıdır (Şekil 4.3). Burada x_i , giriş vektörünün i . elemanını; w_i yerel belleğin i . elemanını; n , boyutu; $F(y)$, ise kırpıcı adı verilen ve lineer olmayan transfer fonksiyonunu temsil etmektedir.

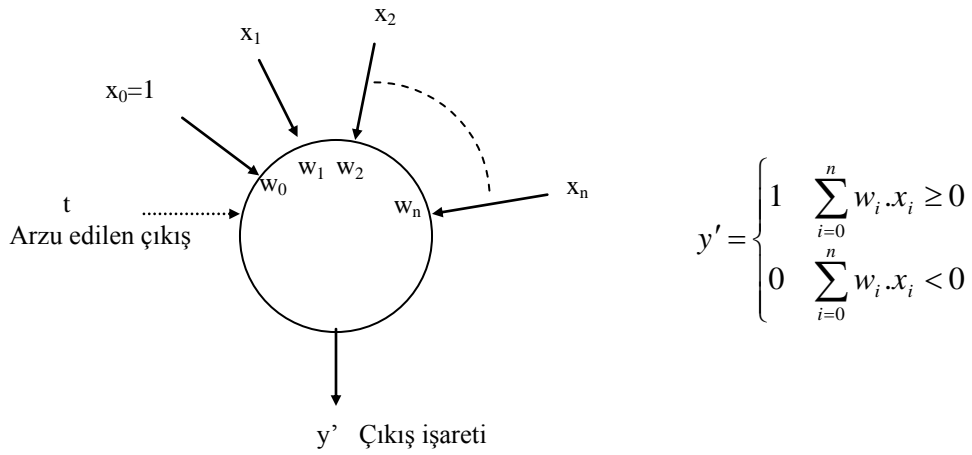
$$y = \sum_{i=0}^n w_i \cdot x_i, \quad x_0 = 1 \quad \Rightarrow \quad y' = F(y) = \begin{cases} 1 & y \geq 0 \\ 0 & y < 0 \end{cases} \quad (4.1)$$



Şekil 4.1 İşlem elemanı



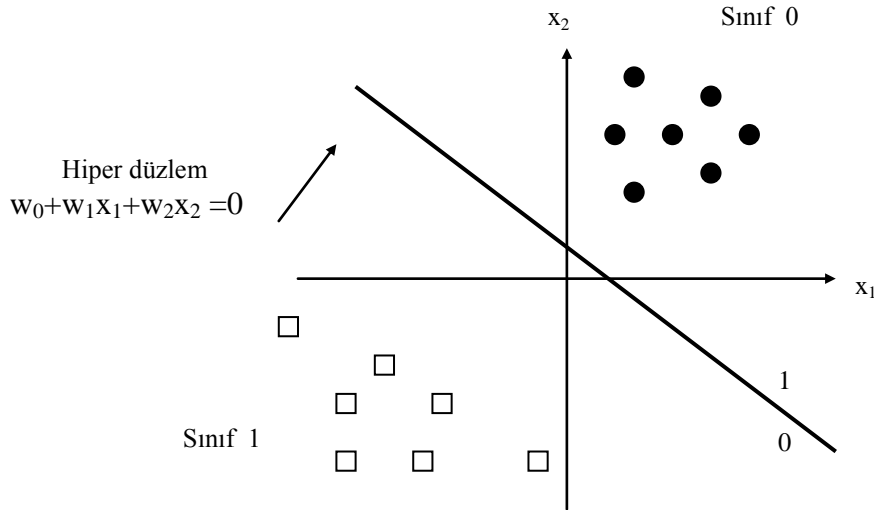
Şekil 4.2 Yapay sinir ağı



Şekil 4.3 Perceptron'un yapısı

Eđitim iřlemi sırasında perceptron iinde sadece w_i yerel bellek elemanları deđiřtirilir. Bu elemanlar ađırlık vektörü olarak adlandırılır ve amaca uygun olarak seilen bir eđitim algoritması ile deđiřtirilir. Amaca en yakın ađırlık vektörüne ufak adımlarla yaklařma iřlemine öđrenme adı verilir.

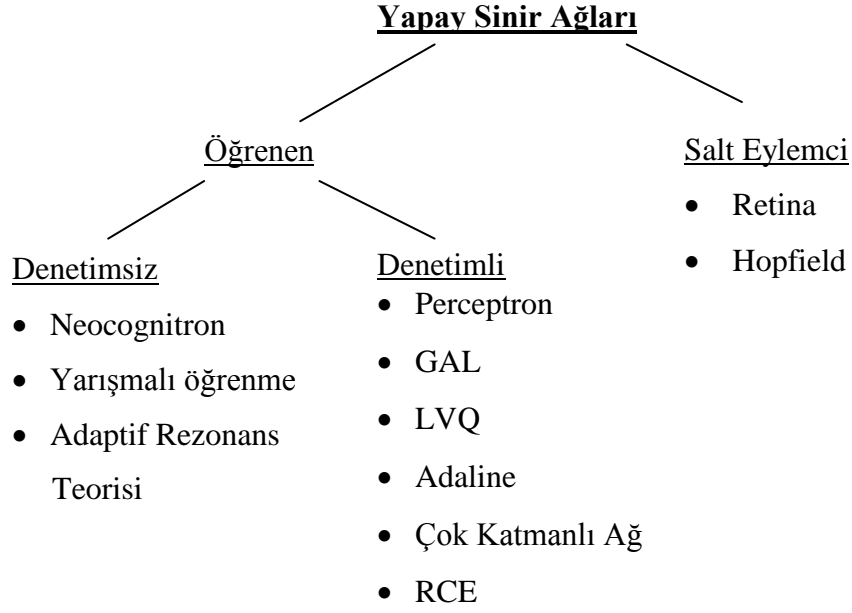
řekil 4.4'te iki boyutlu ($n = 2$), kare ve daire řekillerinden oluřan iki sınıflı bir örnek uzayın eđitimi gosterilmiřtir. Ama, iki sınıfın birbirinden ayrılmasıdır. Her iki kümeden eřit sayıda örnek alınarak oluřturulan eđitim kümesinden elde edilen sınıfların dađılım bilgisi yardımıyla, amaca uygun optimum w_i deđerleri arařtırılır. řekilde dođru, w deđerleri yardımıyla elde edilen sınıfları birbirinden ayıran sınırdır. Burada ayırım tek düđümle gerekleřtirilmiřtir fakat bu her zaman mümkün deđildir. Sınıfların dađılımı ve uzayın boyutuna bađlı olarak deđiřim gosterir.



řekil 4.4 Perceptron'un eđitimi

4.2 Yapay Sinir Ađlarında Öđrenme

Giriř ve ıkıř arasındaki iliřkiyi istenilen řekilde oluřturmak iin deđiřik eđitim algoritmaları kullanılır. Literatürde kullanılan yapay sinir ađları incelendiđinde, her biri iin farklı eđitim algoritmaları kullanıldıđı gözlenmektedir. Bu algoritmaların, öđrenme yöntemlerine göre řekil 4.5'te belirtilen řekilde sınıflanılır [7].



Şekil 4.5 Eğitim yöntemlerine göre yapay sinir ağları

Genel olarak bir yapay sinir ağının öğrenme işlemi, çevreden ve varsa eğiticiden aldığı girişler uyarınca giriş çıkış işlevini, iç yapısını uyarlayarak değiştirmesi olarak açıklanabilir. İç yapıda meydana gelen değişiklikler; yeni bağlantılar oluşturmak, mevcut bağlantıları yok etmek veya mevcut bağlantıların ağırlıklarını değiştirmek şeklinde gerçekleşir.

- Denetimli YSA: Parametrelerini kendi çıkışı ile arzu edilen çıkış arasındaki farkı azaltacak şekilde değiştirir. Eğitim kümesi, her sınıftan rastgele seçilmiş vektörlerden oluşur.
- Denetimsiz YSA: Ağ, sınıfların öznitelik uzayındaki dağılımını inceleyerek kendi parametrelerini değiştirir. Bu yöntemde arzu edilen çıkış yoktur, varsa bile eğitim algoritması tarafından kullanılmaz, eğitimde kullanılan vektörler içinde de gözükmez.

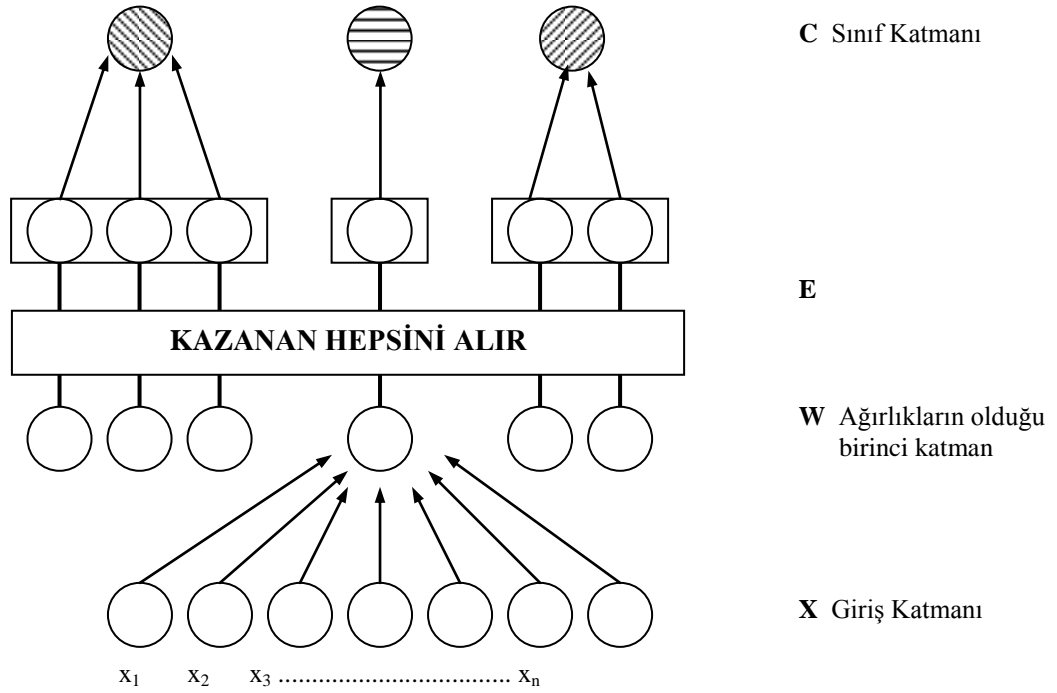
4.3 Büyü ve Öğren (GAL) Yapay Sinir Ağı

GAL (grow and learn-büyü ve öğren) ağı, öznitelik uzayındaki sınıf sınırlarını en yakın mesafe ölçütüne göre belirleyen denetimli yapay sinir ağıdır [3]. Giriş vektörü ile ağdaki tüm düğümlere olan mesafeler hesaplanır. Giriş vektörünün sınıfı, ağdaki

düğümlere en yakın mesafede olan düğümün sınıfı olarak belirlenir. Ağın düğüm sayısı, eğitim sırasında ihtiyaca göre otomatik olarak bulunur.

4.3.1 GAL Ağının Yapısı

Şekil 4.6’da GAL ağının yapısı gösterilmiştir. GAL ağı, iki katmandan meydana gelir.



Şekil 4.6 GAL ağının yapısı

İlk katman, düğüm ağırlıklar ile giriş vektörü arasında minimum mesafeyi bulmada kullanılırken ikinci katman ağdaki düğümlerin ait oldukları sınıfı tanımlamak için kullanılır. İkinci katmandaki ağırlıklar başlangıçta 0 değerini alır, eğitim sırasında bu bağlantılar 1’lenir. İkinci katman, aynı sınıftan çıkışları lojik olarak OR’lamak için kullanılır. Ağın içindeki düğümlerin yapısı (4.2)’deki denklemlerle ifade edilir.

$$D_j = \sum_{i=1}^n [x_i - w_{ji}(k)]^2 \quad E_e = \begin{cases} 1 & D_e = \min\{D_j\} \\ 0 & \text{haricinde} \end{cases} \quad (4.2)$$

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

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

4.3.2 GAL Ağının Eğitimi

GAL ağının en önemli özelliği, düğüm sayısının eğitim sırasında problemin yapısına bağlı olarak kendiliğinden belirlenebilmesidir. GAL ağının yapısı, başlangıçta ağa verilen giriş vektörlerinin sırasına çok bağlıdır. Ağ içinde daha önceden anlamlı olan, ancak ağa yeni düğümlerin ilavesi ile anlamını kaybeden ve bir daha kullanılmayan düğümler oluşmaktadır. Bu düğümler unutma algoritması tarafından ağdan çıkarılır. Unutma algoritmasının amacı, ağdan çıkarıldığı zaman ağın performansını değiştirmeyen düğümleri bulup, bu düğümleri ağdan çıkartmaktır. Aşağıda GAL ağının eğitim algoritması verilmiştir.

Her sınıftan bir vektör alınarak ağın başlangıç düğümleri oluşturulur ve iterasyon sayısı belirlenir.

- Adım 1)** Eğitim kümesinden rasgele bir vektörü ağa giriş olarak ver.
- Adım 2)** Giriş vektörü ile ağın düğümleri arasındaki mesafeleri hesapla. Minimum mesafedeki ağ düğümünün sınıfı, giriş vektörünün sınıfı ile aynı değil ise Adım 4'e git.
- Adım 3)** İterasyon sayısını azalt. İterasyon sayısı sifıra eşit ise öğrenme algoritmasını sonlandır. Aksi taktirde Adım 1'e git.
- Adım 4)** Giriş vektörünü ağa bir düğüm olarak ekle. Giriş vektörünün elemanlarını, birinci katmandaki herhangi boş bir çıkışın ağırlıklarına eşitle ve bu çıkış düğümünün ikinci katmandaki ilişkili bağlantısına 1 değerini ver. Adım 1'e git.

Aşağıda GAL ağının unutma algoritması verilmiştir. İterasyon sayısı ağdaki düğüm sayısı olarak atanır.

- Adım 1)** Sırayla ağdan bir düğümü geçici olarak kaldır ve o düğümü ağa giriş olarak ver.
- Adım 2)** Giriş vektörü ile ağın düğümleri arasındaki mesafeleri hesapla. Minimum mesafedeki ağ düğümünün sınıfı, giriş vektörünün sınıfı ile aynı ise Adım 1'e git.
- Adım 3)** İterasyon sayısını azalt. İterasyon sayısı sifıra eşit ise unutma algoritmasını sonlandır.
- Adım 4)** Geçici olarak çıkarılan düğümü tekrar ağa ilave et. Adım 1'e git.

4.4 Öğrenen Vektör Nicemleyici (LVQ) Yapay Sinir Ağı

LVQ (learning vector quantization-öğrenen vektör nicemleyici) denetimli öğrenme yapısına sahip yapay sinir ağıdır. Sınıf bilgisini düğümleri oluşturan ağırlık vektörlerine ekleyerek, sınıf karar bölgelerinin ayırıcılık özelliğini artırır [8,9]. Düğüm sayısı başlangıçta eğitici tarafından verilir, düğümlerin ağırlıkları ise başlangıçta rastgele olarak girilir.

4.4.1 LVQ Ağının Yapısı

LVQ ağı temel olarak iki katmandan meydana gelir. Birinci katman giriş vektörünün sınıfını mevcut düğümlere olan uzaklıklarından faydalanarak hesaplayan rekabetçi katmandır. İkinci katman ise giriş vektörünün, birinci katmanda belirlenen sınıfı ile gerçek sınıfını karşılaştırır. Giriş vektörünün sınıfını belirleyen düğümün sınıfı ile giriş vektörünün gerçek sınıfı karşılaştırılır. Karşılaştırma sonucu sınıflar aynı ise ağıdaki düğümün ağırlığı girişe yaklaştırılır, sınıflar farklı ise uzaklaştırılır. Bu işlemler lineer katmanda (4.3)'teki denklemlerle gerçekleştirilir.

\bar{x} , girişe uygulanan vektör, \bar{w} ; ağırlık vektörü, η ; öğrenme katsayısı ($0 < \eta < 1$), m ; iterasyon sayısı, i ; vektörün i . elemanı, j ; j . vektör, olarak kullanılmaktadır.

$$w_{ji}(m+1) = \begin{cases} w_{ji}(m) + \eta(x_i - w_{ji}(m)), & \text{dogru} \\ w_{ji}(m) - \eta(x_i - w_{ji}(m)), & \text{hatalı} \end{cases} \quad (4.3)$$

4.4.2 LVQ Ağının Eğitimi

LVQ ağının en büyük dezavantajı, düğüm sayısının eğitim öncesinde eğitici tarafından belirleniyor olmasıdır. Bu nedenle gereğinden fazla veya az düğüm seçmemek için işlemler minimum düğüm sayısı ve en iyi başarıyı verecek kombinasyon bulunana kadar bir çok kez tekrarlanır. Oluşturulan düğümler eğitim sırasında uzayı en iyi ifade edecek pozisyonlara gelene kadar saçılırlar. Bu aşamada fonksiyonlarda kullanılan öğrenme katsayısının seçimi büyük önem kazanmaktadır. Öğrenme katsayısı 0 ile 1 arasında değişim gösteren bir sabittir; büyük seçilmesi durumunda düğümlerin yenilenmesi büyük adımlarla, küçük seçilmesi durumunda ise küçük adımlarla gerçekleşir. Bu durum hedefe ulaşma aşamasında belirlenen

iterasyon sayısının deęişiklik göstermesine ve daha iyi sonuç verebilecek düęüm pozisyonlarının belirlenememesine neden olur. Aşaęıda LVQ aęının eğitim algoritması verilmiştir.

Adım 1) Eğitimin ilk aşamasında öğrenme katsayısı η ve aęı temsil edecek düęüm sayısı belirlenir, düęümleri ifade eden aęırlık vektörleri rastgele oluşturulur.

Adım 2) Girişe uygulanan her bir p-inci x vektörü için kazanan k-ıncı düęüm bulunur, dięer bir ifadeyle giriş vektörüne en yakın düęüm belirlenir.

$$\|\bar{w}_k - \bar{x}_p\| < \|\bar{w}_j - \bar{x}_p\| \quad , \quad j = 1, 2, \dots, m \quad (4.4)$$

Adım 3) Bulunan aęırlık vektörüne göre yeni düęümler hesaplanır. Aęırlık vektörüne göre belirlenen sınıf C_j ile girişe uygulanan vektörünün sınıfı T karşılaştırılır.

$$\bar{w}_k(m+1) = \begin{cases} \bar{w}_k(m) + \eta(\bar{x}_p - \bar{w}_k(m)) & \text{ise } T = C_j \\ \bar{w}_k(m) - \eta(\bar{x}_p - \bar{w}_k(m)) & \text{ise } T \neq C_j \end{cases} \quad (4.5)$$

Adım 4) Öğrenme katsayısı, iterasyon sayısına baęlı olarak, amaca uygun şekilde azaltılır.

Adım 5) Arzu edilen başarı saęlanmış ise eğitim sonlandırılır, devam etmek için Adım 2'ye gidilir.

5. KALP SESLERİNİN YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

5.1 Giriş

Kalp seslerine ait işaretler, 11025 Hz'de örneklenmiş olup MATLAB programı yardımıyla frekansı 5512,5 Hz'e indirgenmiş kayıtlardan oluşmaktadır. Örnek sayısı, S1-S1 periyodu bir pencere içinde bulunacak şekilde, S1 başlangıcı ilk örnek kabul edilerek ayarlanmıştır. İşaretlerin genliği ve pencere boyutları normalize edilmiştir.

Çalışma içerisinde 25 farklı kayıttan alınan 10 farklı grup kalp sesi sınıflandırılmıştır. Sınıflama için kullanılacak sesler sırasıyla; açılma sesi, aort stenozu, erken sistolik üfürüm, geç sistolik üfürüm, normal kalp sesi, S3 sesi, S4 sesi, VSD (Ventricular Septal Defect), PDA (Patent Ductus Ateriosus) ve ASD (Atrial Septal Defect) seslerinden oluşmaktadır. Her sınıfa ait bir örnek ses kaydının gösterildiği şekiller Ek. A'da yer almaktadır.

Literatürde kalp seslerinin analizi ve sınıflandırılması ile ilgili çalışmaları başlıca üç gruba ayırabiliriz. İlk grupta yer alan çalışmalarda uzun süreli ses kayıtlarından S1-S1 aralığının veya kalp sesini oluşturan sistol, diyastol evrelerinin belirlenmesi ile elde edilen kalp sesi işaretlerinin sınıflanması yöntemi incelenmiştir [10-18]. Böylece kalbin, bir çalışma evresi içerisindeki durumu gözlenir. Ses işaretlerinin belirlenmesinde dalgacık, güç analizi ve EKG işaretinin referans alınması gibi çeşitli yöntemler kullanılmaktadır. Daha sonra elde edilen ses işaretleri çeşitli sınıflayıcılar ile sınıflandırılmıştır. Tez içerisinde gerçekleştirilen uygulama bu gruba girmektedir.

İkinci gruptaki çalışmalar ise kalp sesinin sadece S1 veya S2 bileşenlerinin incelenmesi yöntemine dayanır. Böylece kalp kapakçıklarının çalışması ve oluşabilecek problemler hakkında bilgi elde edilir [19, 20]. Üçüncü grupta yer alan çalışmalarda ise kalp seslerinin kayıt edilmesi sırasında solunum sesleri ve çeşitli dış faktörler nedeniyle oluşan gürültülerin temizlenmesiyle ilgili yöntemler geliştirilmiştir [21, 22].

J. Edward Hebden ve J. N. Torry'nin gerçekleştirdiği çalışmada, birinci ve ikinci kalp seslerinin referans bir EKG işareti olmadan elde edilmesine yönelik teknikler tanıtılmış, sınıflayıcılarda kullanılmak üzere çeşitli öznelik çıkarma yöntemleri incelenmiştir [10]. Öznelik çıkartma yöntemi olarak; FFT, S1 ve S2 arasındaki uzaklıklardan elde edilen çeşitli parametreler, sınıflayıcı olarak; lineer diskriminant, en yakın komşuluk, Bayes, parametrik olmayan yoğunluk yaklaşımı, yapay sinir ağları yöntemleri kullanılmıştır. Bu yöntemler yardımıyla normal ve anormal kalp sesleri sınıflandırılarak %5.76 hatayla sınıflandırma gerçekleştirilmiştir. Kalp sesleri S1 ve S2'den daha yüksek frekanslardaki üfürümlerden arındırılmak amacıyla filtreden geçirilmiştir. İlk olarak işarete FFT uygulanmış böylece işaretin frekans dağılımı elde edilmiştir, dağılımda yüksek frekanslardaki genliklerin üfürümlere karşılık geldiği gözlenmiştir. Gözlenen ilk tepe işarete uygulanacak bant geçiren filtrenin kesim frekansını belirlemede kullanılmıştır.

Liang ve arkadaşlarının gerçekleştirdiği çalışmada, kalp seslerini parçalara ayırarak inceleme yolu izlenmiştir [11]. Kalp sesinin bir periyodu; birinci kalp sesi (S1), sistol, ikinci kalp sesi (S2) ve diyastol olarak dört parçaya ayrılmıştır. Bu amaçla sürekli bir kalp sesi kaydından bu ayırma işlemini gerçekleştirecek özellikle S1'in yerini otomatik olarak bulacak bir algoritma geliştirilmiştir. Bu algoritma normalize edilmiş ortalama Shanon enerji yöntemine dayanmaktadır. Çalışmada 37 hastadan alınan uzun süreli kayıtlarda yer alan 515 kalp sesi periyodu, bu yöntem uygulanarak %93 başarı oranı ile tespit edilmiştir.

Liang ve arkadaşlarının gerçekleştirdiği bu çalışmada da, kalp seslerini parçalara ayırarak inceleme yolu izlenmiştir [12]. Fakat burada ayrık dalgacık dönüşümü kullanılmış, elde edilen katsayılara normalize edilmiş ortalama Shanon enerji yöntemi uygulanmıştır. İşareti tekrar elde etmek amacıyla dalgacık dönüşümü sonucunda elde edilen ayrıntı ve yaklaşıklık katsayılarından yararlanılmıştır. Çalışmada 77 uzun süreli kayıttan alınan 1165 kalp sesi, bu yöntem uygulanarak %93 başarı oranı ile tespit edilmiştir.

Obaidat'ın gerçekleştirdiği çalışmada fonokardiyogram için Fourier dönüşümü, dalgacık dönüşümü analizi ve Wigner güç dağılımı yöntemlerinin birbirlerine göre avantaj ve dezavantajları incelenmiştir [13]. S1 ve S2'nin bu yöntemler ile zaman ve frekans domenindeki bileşenleri incelenmiştir.

Leung ve arkadaşlarının çalışmasında, öznitelik çıkartma yöntemi olarak TMS (trimmed mean spectrogram) yöntemi kullanılmış, sınıflayıcı olarak ise PPN (probability neural networks)'den yararlanılmıştır [14]. Uygulama sırasında, eğitim için 21 normal, 35 anormal kalp sesi, test için ise 18 normal, 37 anormal kalp sesi kullanılmıştır. Sesler EKG referans alınarak sistolik ve diyastolik olarak ayrılmıştır. Sınıflama başarımı sınıflara göre normal kalp sesleri için %97.3 (36/37), anormal sesler için ise %94,4 (17/18) olarak elde edilmiştir.

Leung ve arkadaşlarının bir diğer çalışmasında ise ASD, VSD, pulmoner üfürüm ve normal kalp seslerinin karakteristiklerine ait bilgi edinmek ve sınıflayıcılara giriş olarak verilebilecek belirleyici öznitelikleri tesbit etmek amacıyla 10x10 boyutlu SOM (Self-Organizing Map) algoritması kullanılmıştır [15].

Yoshida ve arkadaşlarının gerçekleştirdiği çalışmada, EKG referans alınarak belirlenmiş, S1 ve sistolik kalp sesi kompleksinden oluşan örnek sesler dalgacık yöntemi yardımıyla anormal kalp sesi ve murmur olarak belirlenmiş, kalp seslerinin özniteliklerinin çıkarılması ve sınıflanmasında ani frekans değişimleri incelenmiş, WVD (Wigner-Ville distribution) yönteminden yararlanılmıştır [16].

Cathers'in gerçekleştirdiği çalışmada, kalp sesleri üzerinde belirlenen bir pencerenin gezdirilmesi ile her pencerenin içindeki maksimum değer alınarak işaret düzleştirilmiştir [17]. Daha sonra işaretin ortalama korelasyon katsayısı hesaplanmış ayrıca her bir sınıfa ait vektörlerin sınıf içi ortalama Euclidean uzaklıkları hesaplanarak öznitelikler belirlenmiştir. Elde edilen öznitelikler üç katmanlı yapay sinir ağları ile normal ve anormal kalp sesleri olarak sınıflandırılmıştır. Eğitim için 18 normal, 30 anormal, test için ise 3 normal, 10 anormal kalp sesi kullanılmış, sınıflayıcı tüm test verilerini başarıyla sınıflandırmıştır.

Durand ve arkadaşları ise kalp kapakçıkları ile ilgili sorunları kalp seslerinden teşhis etmek amacıyla 95 hasta üzerinde gerçekleştirdikleri çalışmada, öznitelik çıkartma yöntemi olarak FFT ve AR parametreleri yöntemlerini ve bu yöntemlerle birlikte pencere fonksiyonlarını kullanmışlardır [18]. Elde edilen öznitelikler Bayes ve en yakın komşuluk sınıflayıcıları kullanılarak sınıflandırılmış, sınıflama sonuçları pencere fonksiyonlarına bağlı olarak değişim göstermiş ve en yüksek olarak %94 başarı gözlenmiştir.


5.2 Özniteliklerin Belirlenmesi

Özniteliklerin seçilmesinde, sınıfları en iyi şekilde temsil ederek, sınıfların öznitelik uzayında uzak noktalara saçılmaları ve belirlenen öznitelik vektörlerinin küçük boyuta indirgenerek uygulamalar sırasında maksimum performansın sağlanması amaçlanmıştır. Çalışma içerisinde özniteliklerin belirlenmesi için Fourier, kısa zaman Fourier ve dalgacık dönüşümü yöntemlerinden yararlanılmış ve bu yöntemlerin kalp seslerinin analizinde gösterecekleri ayırıcılık özellikleri incelenmiştir.

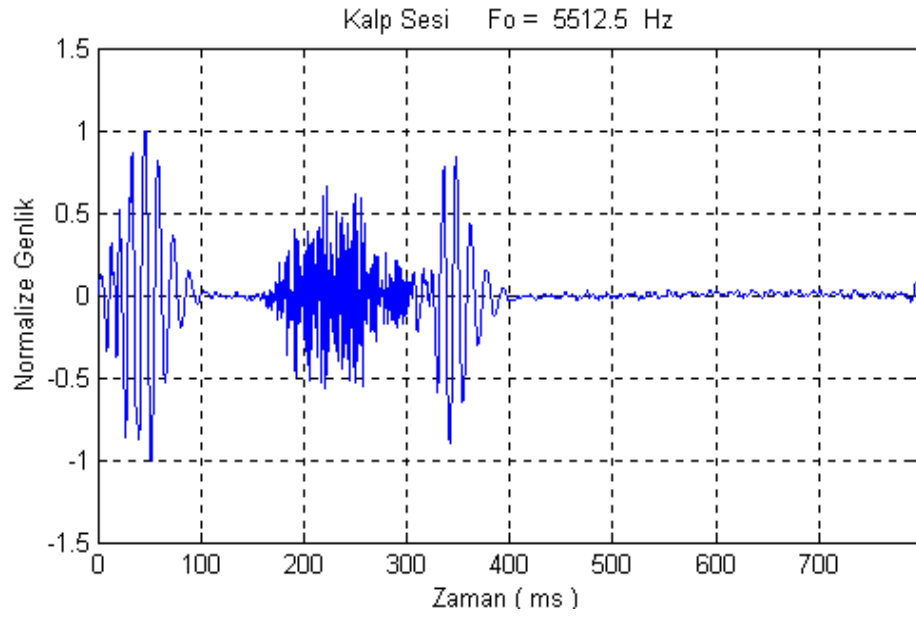
5.2.1 Fourier Dönüşümü

Fourier dönüşümü, işaretin içerisinde hangi frekans bileşenlerinin olduğunu inceler, bu bileşenlerin zamanın hangi anında ortaya çıktıkları hakkında bir bilgi içermez. Fourier dönüşümü yöntemi kullanılarak; S1, S2 temel seslerine ek olarak S3, S4, çeşitli üfürümler, klik ve açılma sesleri, vb., gibi kalbin çalışması sırasında oluşan hastalık belirtisi olabilecek anormal kalp sesi bileşenlerinin, zaman domenindeki konumlarının belirlenmesi mümkün değildir. Aynı frekanslara sahip fakat zaman domeninde farklı bölgelerde oluşan sesler, frekans spektrumunda aynı bölgeye karşılık gelecektir. Bu yöntemle elde edilen öznitelikler, sınıfların birbirlerinden uzak noktalara saçılması koşulunu sağlayamayacak hatta bu karakteristiğe sahip sınıflar öznitelik uzayında birbirleri içerisine girerek, sınıflayıcının hatalı sonuçlar üretmesine neden olacaktır.


Şekil 5.1 ve Şekil 5.2’de gösterilen kalp seslerinin frekans spektrumları Şekil 5.3 ve Şekil 5.4’te gösterilmiştir. İki farklı ses olmasına rağmen, frekans spektrumları birbirine benzer bileşenler içermektedir. Çok sayıda ses işaretinin frekans spektrumları incelendiğinde bu tür ortak frekans bileşenlerinin olduğu gözlemlendiğinden sınıflama başarımı düşük olacaktır. Her sınıfa ait bir örnek ses kaydının frekans spektrumuna ait grafikler Ek. B’de yer almaktadır.




Şekil 5.1 Erken sistolik üfürüm



Şekil 5.2 Geç sistolik üfürüm



Şekil 5.3 Erken sistolik üfürümün frekans spektrumu





Şekil 5.4 Geç sistolik üfürümün frekans spektrumu

5.2.2 Kısa Zaman Fourier Dönüşümü



Fourier dönüşümündeki sorunlarla karşılaşmamak, aynı frekansa sahip fakat zaman domeninde farklı bölgelere karşılık gelen ses bileşenlerini analiz edebilmek amacıyla kısa zaman Fourier dönüşümü kullanılmıştır. Bu yöntem ile incelenen ses işaretleri, seçilen bir pencere içerisinde durağan kabul edilmiş ve pencere boyunca işaretin Fourier dönüşümü alınarak, bu işlem, seçilen pencere işaret üzerinde gezdirilerek tekrarlanmıştır. Bu yöntemle Fourier dönüşümüne göre sınıflar arası ayırıcılık artmıştır ve sınıflayıcılar için başarıyı arttıracak öznelik vektörleri oluşturulmuştur.

Büyük pencere seçiminde frekans ekseninde daha iyi çözünürlük elde edilirken, işaretin bileşenlerinin zamanda temsilleri kötüleşir. Şekil 5.5'te, Şekil 5.1'deki erken sistolik üfürümün, büyük pencere kullanılarak KZFD ile analizi gösterilmiştir.



Şekil 5.5 Erken sistolik üfürümün büyük pencere kullanılarak KZFD ile analizi

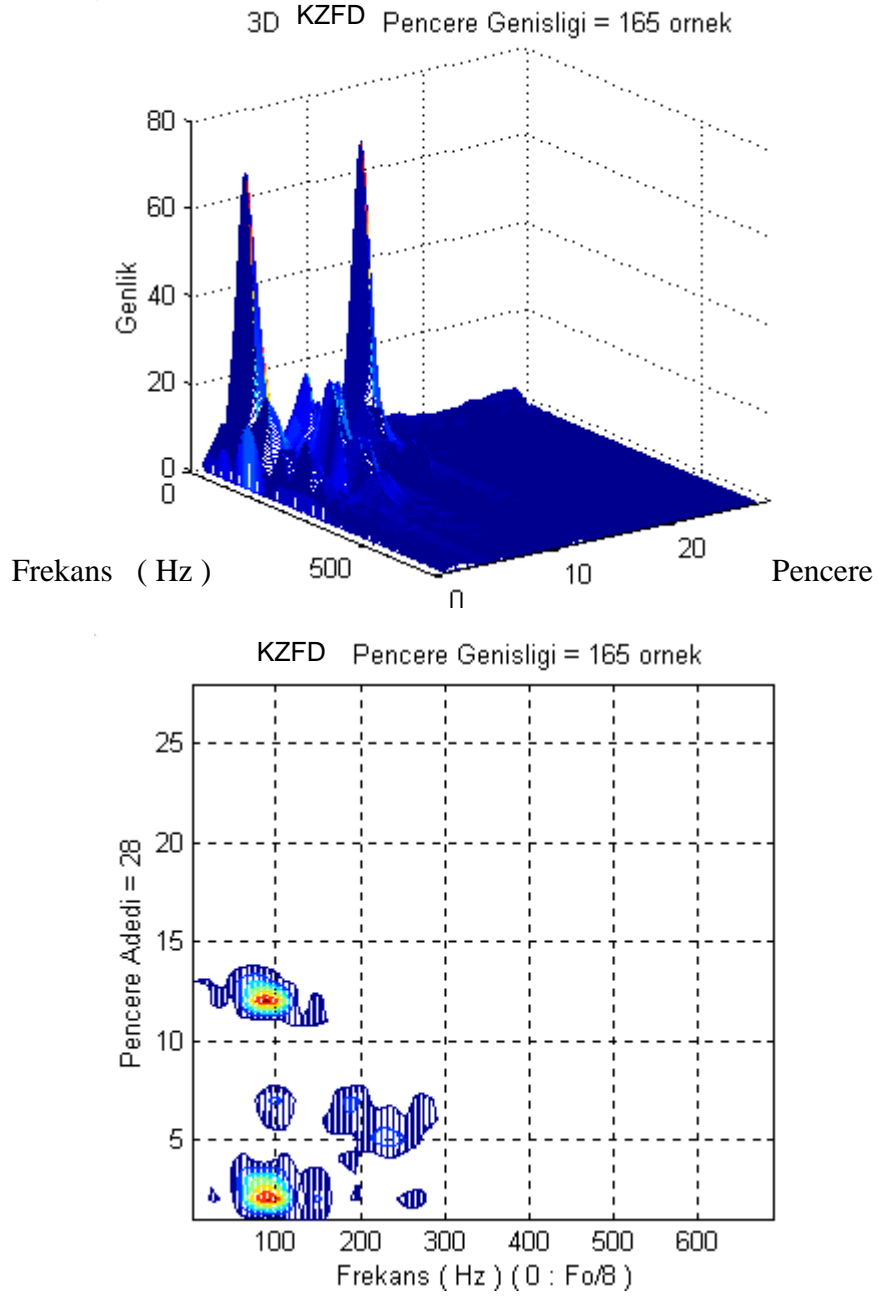
Küçük pencere seçiminde ise frekansta kötü bir çözünürlük elde edilirken, bileşenler zaman domeninde daha iyi temsil edilir. Şekil 5.6'da, Şekil 5.1'deki erken sistolik üfürümün, küçük pencere kullanılarak KZFD ile analizi gösterilmiştir.



Şekil 5.6 Erken sistolik üfürümün küçük pencere kullanılarak KZFD ile analizi

İşlemler sırasında, seçilen pencere fonksiyonu ve pencere fonksiyonun genişliğinin, her bir kalp sesi sınıfı için geçerli olabilecek genişlikte seçilememesi çözünürlük sorununa yol açmaktadır.

Ses işaretinin KZFD analizi, frekans ve zaman domeninde iyi bir çözünürlük elde edecek şekilde, uygun genişlikte bir pencere seçilerek gerçekleştirildiğinde Şekil 5.7'deki sonuçlar elde edilir. Her sınıfa ait bir örnek ses kaydının kısa zaman Fourier dönüşümüne ait grafikler Ek. C'de yer almaktadır.




Şekil 5.7 Erken sistolik üfürümün KZFD ile analizi

5.2.3 Dalgacık Dönüşümü


KZFD, tüm zamanlarda sabit çözünürlük verdiği için KZFD'nin çözünürlük ile ilgili problemlerini gidermek üzere zamanda değişken çözünürlük veren dalgacık dönüşümü kullanılmıştır. Çalışma içerisinde dalgacık dönüşümü olarak, ayrık dalgacık dönüşümü (ADD) yöntemi uygulanmıştır.

Kalp seslerinin, seçilecek bir filtre yardımıyla ayrık dalgacık dönüşümü işlemleri gerçekleştirilerek, sesleri en iyi temsil edecek ayrıntı (detail) ve yaklaşıklık (approximation) katsayıları belirlenir. Çalışmada filtre fonksiyonu olarak Daubechies-10 dalgacığı kullanılmıştır. Dalgacık (2x10) 20 katsayıdan oluşmaktadır.


Çalışmada çeşitli denemeler sonucunda, 10 farklı tipteki kalp seslerini en iyi 3. ve 4. ayrıştırma seviyesindeki dalgacık katsayılarının temsil ettiği gözlenmiştir. Filtre çıkışındaki işaretler, kalp seslerinin yüksek ve alçak frekans bileşenlerini temsil etmektedir. Örnek olarak geç sistolik üfürüme ait kalp sesi analiz edilmiştir (Şekil 5.8). Elde edilen dalgacık düzlemi Şekil 5.9'da, işarete ait ayrıntı Şekil 5.10-14'te ve yaklaşıklık katsayıları Şekil 5.15-19'da gösterilmiştir. Diğer kalp seslerine ait katsayı analizleri EK.D ve E'de dalgacık düzlemleri EK.F'de verilmiştir.



Şekil 5.8 Geç sistolik üfürüm sesi




Şekil 5.9 Geç sistolik üfürüme ait dalgacık düzlemi




Şekil 5.10 Birinci seviye ayrıntı katsayıları

Örnekler




Şekil 5.11 İkinci seviye ayrıntı katsayıları

Örnekler




Şekil 5.12 Üçüncü seviye ayrıntı katsayıları

Örnekler




Şekil 5.13 Dördüncü seviye ayrıntı katsayıları

Örnekler




Şekil 5.14 Beşinci seviye ayrıntı katsayıları


Örnekler




Şekil 5.15 Birinci seviye yaklaşıklık katsayıları




Şekil 5.16 İkinci seviye yaklaşıklık katsayıları



Şekil 5.17 Üçüncü seviye yaklaşıklık katsayıları




Şekil 5.18 Dördüncü seviye yaklaşıklık katsayıları




Şekil 5.19 Beşinci seviye yaklaşıklık katsayıları

Dalgacık düzlemindeki renklendirme bağıl genlik değerlerini ifade etmek için kullanılmaktadır (Şekil 5.9). Düzlemde gösterilen yataydaki (belirli bir ölçeğe ait) işaretler, dalgacık ağacında ifade edilen filtre çıkışlarını göstermektedir.



Çalışmada bütün kalp sesleri için öznitelik olarak 4. seviye katsayılarından elde edilen işaretler alınmıştır. Fakat alınan işaretlerin boyutu 4750 elemandan oluşmaktadır ve sınıflayıcıya verilmek için çok büyüktür. Bu nedenle katsayılarından elde edilen işaretlerin güçlerinin hesaplanarak boyutlarının küçültülmesi amaçlanmıştır. İşaretin gücünü almak amacıyla 128 boyutlu bir pencere katsayılar üzerinde gezdirilerek, işaretin pencere içinde kalan bölümünün gücü hesaplanmıştır (Şekil 5.20). Böylece boyut 4750'den 37'ye indirgenmiştir. Şekil 5.12-13'de gösterilen ayrıntı katsayılarından elde edilen işaretlerin gücü Şekil 5.21-22'de ve Şekil 5.17-18'de gösterilen ayrıntı katsayılarından elde edilen işaretlerin gücü ise Şekil 5.23-24'de gösterilmiştir.




Şekil 5.20 Pencere kullanılarak 4. seviye ayrıntı katsayılarının güç hesabı




Şekil 5.21 Üçüncü seviye ayrıntı katsayılarının gücü




Eğitim kümesi; her sınıftan 15 vektör olmak üzere, 10 sınıfa ait toplam 150 vektörden oluşmaktadır. Vektörler 74 elemandan oluşmaktadır: İlk 37 eleman 4. seviye ayrıntı katsayılarından elde edilen güç vektöründen, diğer 37'lik bölüm ise yaklaşıklık katsayılarından elde edilen güç vektöründen oluşmaktadır. Şekil 5.25'te ayrıntı katsayılarından güç hesabı ile elde edilen eğitim kümesinin öznitelikleri, Şekil 5.26'da yaklaşıklık katsayılarından güç hesabı ile elde edilen eğitim kümesinin öznitelikleri gösterilmiştir. Şekil 5.27'de ise ayrıntı ve yaklaşıklık katsayılarından güç hesabı ile elde edilen ve sınıflayıcıda kullanılacak öznitelik vektörleri bir arada gösterilmektedir.



Şekil 5.25 Ayrıntı katsayılarının gücü ile elde edilen eğitim kümesi öznelikleri



Şekil 5.26 Yaklaşıklık katsayılarının gücü ile elde edilen eğitim kümesi öznelikleri




Şekil 5.27 Ayrıntı ve yaklaşıklık katsayılarının gücünden elde edilen öznelıklar

5.3 Yapay Sinir Ağları ile Sınıflama

Kalp seslerini sınıflandırmak amacıyla 3. Bölüm içerisinde anlatılan GAL (grow and learn) ve LVQ (learning vector quantization) yapay sinir ağları kullanılmıştır. Bu bölümde kalp seslerinin sınıflandırılmasının yanında, yapay sinir ağlarının başarımını analiz etmek amacıyla örnek bir öznitelik uzayından yararlanılmış, böylece yapay sinir ağları için tasarlanan programlar da test edilmiştir.

5.3.1 Örnek Öznitelik Uzayı


Örnek öznitelik uzayı (Şekil 5.28) iki boyutlu 65536 (256x256) adet vektörden oluşan, siyah bölgelerin (18701 vektör) belirsiz olarak tanımlandığı, 3 sınıftan (beyaz 13998, açık-gri 13865 ve koyu-gri 18972 vektör) oluşmaktadır. Eğitim kümesi, örnek öznitelik uzayından her sınıf için eşit dağılımlı olmak üzere toplam 300 vektörden, test kümesi ise siyah bölge dışındaki 3 sınıfa ait vektörlerin tamamından oluşmaktadır. Örnek öznitelik uzayına ait sınıflama sonuçları, kalp seslerinin sınıflandırılması ile ilgili sonuçlar vermez, sadece ağların sınıflama performanslarının karşılaştırmalı olarak incelenmesini sağlar.



Şekil 5.28 Örnek öznitelik uzayı ve karar işlemi

5.3.2 Kalp Seslerinden Elde Edilen Öznitelik Uzayı

Kalp seslerinden elde edilen özniteliklerle oluşturulan öznitelik uzayı ise 25 farklı kayıttan elde edilen, 10 sınıfa ait 74 boyutlu toplam 268 öznitelik vektöründen oluşmaktadır. Bu özniteliklerden her sınıftan 15 vektör olmak üzere 150 vektör yapay sinir ağlarının eğitimi için, geri kalan 118 tanesi ise yapay sinir ağlarının test edilmesi amacıyla kullanılmıştır. Şekil 5.29’da kalp seslerini sınıflandırmak amacıyla yapılan işlemlerin basit bir blok diyagramı gösterilmiştir.



Şekil 5.29 Kalp seslerinin sınıflandırılması

İlk blok içerisinde analiz edilecek kalp sesi işareti için periyot belirlenir, bu aşamada uzun süreli ses kayıtlarından S1-S1 aralığının belirlenmiş olduğu kabul edilir, çünkü literatürde S1-S1 aralığının belirlenmesi ayrı bir çalışma konusudur. İkinci blokta ise bir periyotluk farklı genlik ve uzunluktaki işaretlerin normalizasyonu işlemidir. Burada genlikler ± 1 değerine normalize edilirken, kayıt uzunluğu ise 4750 eleman olarak ayarlanır. Üçüncü blok içerisinde normalize edilmiş işaretlere öznitelik çıkartma işlemi uygulanır, çalışmada bu amaçla dalgacık dönüşümü ve güç hesabı kullanılmıştır. Son blokta ise GAL ve LVQ yapay sinir ağları ile sınıflama işlemi gerçekleştirilir.


5.4 Sınıflama Sonuçları

Analizler sırasında kullanılan yapay sinir ağlarını karşılaştırmak amacıyla, ağların test kümesini doğru sınıflandırma başarımı, düğüm sayısı ve eğitim için geçen süre kullanılmış, bu parametreler örnek uzay ve kalp sesleri için ayrı ayrı hesaplanmıştır.

GAL ağının eğitiminde düğümler eğitim sonucunda ihtiyaca göre belirlense de bulunan düğümler eğitim kümesindeki vektörlerle aynı ağırlıklara sahiptir ve düğüm ağırlıkları eğitim sırasında değiştirilmez, bu nedenle GAL ağı ezberci bir ağ olarak tanımlanır ve sınıflama sonucu eğitim kümesine bağlıdır. Öznitelik uzayında sınıflar birbirine yaklaştığında, sınıf sınırlarını daha iyi temsil etmek amacıyla çok sayıda düğüme ihtiyaç duyulmaktadır.

LVQ ağının eğitiminde ise ağın düğüm sayısı, eğitim aşamasının başlangıcında belirlenen ve ağın performansını etkileyen en önemli parametredir. Fazla sayıda düğüm seçilmesi ağın gereksiz düğümler içermesine, az sayıda düğüm seçimi ise öznitelik uzayının yeterli şekilde ifade edilememesine neden olur. Eğitim sırasında uygulanan işlemlerle ağın düğümlerinin ağırlıkları değiştirilir.

Şekilde örnek öznitelik uzayının (Şekil 5.30 a), GAL (Şekil 5.30 b) ve LVQ (Şekil 5.30 c) sınıflama sonuçları, Tablo 5.1’de ise örnek öznitelik uzayı analiz sonuçları gösterilmiştir. GAL ağında düğümlerin sınırları daha iyi temsil etmek için sınırlara yaklaştığı, LVQ ağında ise sınıf içlerini temsil etmek amacıyla düğümlerin sınıf bölgelerinin içinde dağılım gösterdiği, sınıfların birbirine yakın olduğu bölgelerde sınırların tam olarak belirlenemediği gözlenmektedir. Tablo 5.2’de ise kalp seslerine ait öznitelik uzayı analiz sonuçları gösterilmiştir. LVQ için 25, 30 ve 35 sayıda düğümle üç farklı analiz gerçekleştirilmiştir.



Şekil 5.30 Örnek öznitelik uzayı (a) için GAL (b) ve LVQ (c) sınıflama sonuçları

Tablo 5.1 Örnek öznitelik uzayı sınıflama sonuçları

Analizler	GAL	LVQ
İterasyon	1000	1000
Düğüm sayısı	24	35
Başarım (%)	93.6	92.3
Eğitim Süresi (sn)	1.48	14.47

Tablo 5.2 Kalp seslerine ait öznitelik uzayı sınıflama sonuçları

Analizler	GAL	LVQ		
Açılma Sesi	13/14	8/14	14/14	13/14
Aort Stenozu	15/15	6/15	13/15	15/15
Erken Sistolik Üfürüm	11/11	11/11	11/11	11/11
Geç Sistolik Üfürüm	10/10	8/10	10/10	9/10
Normal Kalp Sesi	17/17	17/17	9/17	15/17
S3 Sesi	20/20	17/20	17/20	20/20
S4 Sesi	13/13	13/13	13/13	13/13
VSD (Ventricular Septal Defect)	6/6	6/6	6/6	6/6
PDA (Patent Ductus Ateriosus)	6/6	6/6	6/6	6/6
ASD (Atrial Septal Defect)	6/6	6/6	6/6	6/6
Genel Başarım (%)	99,29	86,21	92,46	97,11
Düğüm Sayısı	22	25	30	35
Eğitim Süresi (sn)	1,98	0,11	0,53	0,78

Genel başarımın GAL ağında oldukça yüksek olduğu ve düğüm sayısının da LVQ'ya göre çok az olduğu görülmektedir. İşlemler MS-Windows ortamında gerçekleştirildiği için, ağların eğitim sürelerine ait analiz sonuçları gerçekçi bir karşılaştırma imkanı vermemekte, ancak yaklaşık sonuç vermektedir.

6. SONUÇLAR

Kalp seslerinin analizi ve yapay sinir ağları ile sınıflandırılması amacıyla gerçekleştirilen bu çalışmada, uygulamalar başlıca iki ana grup altında toplanabilir.

1. Öznitelik çıkartma işlemi
2. Yapay sinir ağları ile sınıflama

Öznitelik çıkartma işlemi çalışmada başarıya etki eden en önemli bölümdür. Burada belirlenecek öznitelikler, sınıfların öznitelik uzayında farklı bölgelerde öbekleşmelerini sağlayarak, bir sonraki bölüm olan yapay sinir ağları ile sınıflandırma aşamasında performansa etki etmektedir. Bu nedenle çalışma içerisinde özellikle bu bölüm üzerinde durulmuş ve kalp sesleri için ayırıcı özniteliklerin belirlenmesi amacıyla çeşitli işaret işleme yöntemleri kullanılmıştır. Kalp seslerini sınıflandırmak amacıyla, kalbin bir çalışma evresine ait çalışma bilgisini veren S1-S1 aralığındaki bir periyotluk kalp sesi incelenmiştir. Kalp sesleri hakkında doğru bir sınıflama gerçekleştirebilmek için seslerin zaman ve frekans domenine ait hem zaman hem de frekans bilgilerinin belirlenmesi gerekmektedir. Çünkü kalp sesleri, farklı zaman dilimlerinde aynı frekans bileşenlerine sahip olabilen durağan olmayan işaretlerdir.

Öznitelikleri belirlemek amacıyla, kalp seslerine ilk olarak Fourier dönüşümü uygulanmıştır. Elde edilen sonuçlarda, işaretlerin frekans domeni bilgisinin belirlendiği fakat işaretlere ait zaman bilgisinin belirlenmediği görülmüştür. Bu yöntemle elde edilen öznitelikler sınıfların, öznitelik uzayında iç içe girmelerine neden olacak, böylece yapay sinir ağlarında başarımlar istenen düzeyde olmayacaktır.

İkinci öznitelik çıkartma yöntemi olarak, kısa zaman Fourier dönüşümü (KZFD) yöntemi kullanılmıştır. KZFD, belirlenen bir pencerenin, işaret üzerinde gezdirilmesi ve pencere içinde kalan işaretin durağan kabul edilerek Fourier dönüşümünün alınmasıyla gerçekleştirilir. Böylece işaret üzerinde gezdirilen pencere yardımıyla, frekans bilgisinin yanı sıra, işaret hakkında zaman bilgisi de elde edilmektedir. Burada karşılaşılan sorun, KZFD'nin uygulanması sırasında seçilen pencerenin tüm

kalp sesi işaretleri için gerekli çözünürlüğü sağlayamamasıdır. Kalp sesi işaretleri yüksek ve alçak frekanslara ait bileşenler içermekte ve bu bileşenler zamanın farklı bölgelerinde bulunabilmektedir. Bu nedenle seçilen pencerenin büyük olması frekansta çözünürlüğü artırırken, zamanda çözünürlüğü azaltmakta; pencerenin küçük belirlenmesi zamanda çözünürlüğü arttırırken, frekansta çözünürlüğü azaltmaktadır. Kalp sesleri için sabit bir pencere belirlendiğinde, tüm işaretler için çözünürlük sabit kalmaktadır.

Son olarak incelen dalgacık dönüşümü yönteminde ise ayrık dalgacık dönüşümü yöntemi (ADD) kullanılmıştır. Bu yöntemde belirlenen bir dalgacık fonksiyonu (Daubechies-10) yardımıyla ayrıntı ve yaklaşıklık katsayıları hesaplanarak, işaretlere alçak ve yüksek geçiren filtreleme işlemleri uygulanmıştır. Böylece işarete ait frekans ve zaman bilgileri elde edilmiştir. Elde edilen vektörlerin boyutunun çok büyük olması nedeniyle, boyut küçültmek amacıyla vektörlerin gücü hesaplanmıştır. ADD sonucunda elde edilen 4. seviye ayrıntı ve yaklaşıklık katsayılarının pencere yöntemi ile güçleri hesaplanmış ve güç değerlerinden oluşan 37 boyutlu iki adet vektör oluşturulmuştur. Daha sonra bu iki vektör birleştirilerek 74 boyutlu tek bir öznelik vektörü oluşturulmuştur. Ayrıntı katsayıları kalp sesi işaretleri için yüksek frekans bilgisini, yaklaşık katsayıları ise alçak frekans bilgisini içermektedir.

Çalışmanın ikinci bölümünü oluşturan, yapay sinir ağları ile sınıflama aşamasında, belirlenen öznelik vektörleri yardımıyla 10 sınıfa ait kalp sesleri sınıflandırılmıştır. Sınıflamada GAL ve LVQ denetimli yapay sinir ağları kullanılmıştır. GAL ezberci bir ağ olduğu için eğitim algoritması, ağ düğümlerini hiçbir değişiklik yapmadan doğrudan eğitim kümesindeki vektörler arasından seçer. Düğümler ağın ihtiyacına göre sınıfların sınırlarını ayıracak şekilde belirlenmektedir. LVQ'da ise düğüm sayısı kullanıcı tarafından eğitimin başlangıcında belirlenmekte ve ağın ihtiyacı kadar düğümü belirlemek için çok sayıda deneme yapılması gerekmektedir. Düğümlerin ağırlıkları, eğitim sırasında değiştirilerek öznelik uzayını en iyi tanımlayan düğümlerin belirlenmesi sağlanır.

Tablo 6.1’de YSA’ların örnek uzayı ve kalp seslerini sınıflama başarımları ve düğüm sayıları gösterilmiştir.

Tablo 6.1 YSA’ların sınıflama performansları

Yapay Sinir Ağları	Örnek Uzay		Kalp Sesleri		
	İterasyon	Düğüm Sayısı	Başarım (%)	Düğüm Sayısı	Başarım (%)
GAL	1000	24	93,6	22	99,29
LVQ	1000	35	92,3	35	97,11

Çalışmada kullanılan programlar MATLAB paket programı ile yazılarak Pentium III-866 MHz işlemcili MS-Windows işletim sistemi olan bir bilgisayarda çalıştırılmıştır. Kalp sesine ait 4. ayrıştırma seviyesindeki ayrıntı ve yaklaşıklık katsayılarının belirlenmesi 0,33 sn, gücün hesabı 0,05 sn ve sınıflama işlemi ise GAL için 0,05 sn sürmektedir. Elde edilen bu süreler yaklaşık bir bilgi vermektedir. Sonuç olarak, gerçekleştirilen bu çalışma ile kalp sesleri %99,29 gibi yüksek bir başarı oranı ile sınıflandırılmıştır. Fakat çalışmanın genelleştirilebilmesi için kalp seslerine ait sınıf sayısının artırılmasına ihtiyaç vardır. Böylece çeşitli kalp rahatsızlıklarına ait çok çeşitli sesler sınıflandırılarak, doktorlara teşhislerinde tam bir bilgisayar desteği sağlayabilecektir.


KAYNAKLAR

- [1] **Yazgan, E. ve Korürek, M.**, 1996. Tıp Elektronikü, İ.T.Ü Elektrik-Elektronik Fakültesi, Ofset Baskı Atölyesi, İstanbul.
- [2] **Novoy, Donald W.**, 1996. Kalp Sesleri Kılavuzu, Hekimler Yayın Birlięi.
- [3] **Ölmez, T.**, 2000. Makine Öğrenmesi ve Genetik Algoritmalar, Yüksek Lisans Ders Notu, İstanbul Teknik Üniversitesi, İstanbul.
- [4] **Korürek, M.**, 2000. Biyomedikal Mühendisliğinde Özel Konular, Yüksek Lisans Ders Notu, İstanbul Teknik Üniversitesi, İstanbul.
- [5] **Efe, M. Ö. ve Kaynak, O.**, 2000. Yapay Sinir Ağları ve Uygulamaları, Boęaziçi Üniversitesi, İstanbul.
- [6] **Güzeliş, C.**, 1993. Yapay Sinir Ağları, Yüksek Lisans Ders Notu, İstanbul Teknik Üniversitesi, İstanbul.
- [7] **Hecht-Nielsen, R.**, 1990. Neurocomputing, HNC, Inc. and University of California, San Diego.
- [8] **Haykin, S.**, 1999. Neural Networks A Comprehensive Foundation, 466-468.
- [9] **Pandya A. S. and Macy, R. B.**, 1996. Pattern Recognition with Neural Networks in C++, IEEE Press, 259-280.
- [10] **Hebden, J. E. and Torry, J. N.**, 1996. Neural Network and Conventional Classifiers to Distinguish Between First and Second Heart Sounds, *The Graduate Division of Biomedical Engineering*, University of Sussex, published by the IEEE.
- [11] **Liang, H., Lukkarinen, S. and Hartimo I.**, 1997. Heart Sound Segmentation Algorithm Based on Heart Sound Envelopogram, *Computers in Cardiology*, vol. 24.
- [12] **Liang, H., Lukkarinen, S. and Hartimo I.**, 1997. A heart sound segmentation algorithm using wavelet decomposition and reconstruction, *Proceedings - 19th International Conference IEEE-EMBS*, Chicago, USA, October 30 - November 2, 1630-1633.


- [13] **Obaidat, M. S.**, 1993. Phonocardiogram signal analysis: techniques and performance comparison, *Journal of Medical Engineering & Technology*, November / December, vol. 17, no. 6, 221-227.
- [14] **Leung, T. S., White, P. R., Collis, W. B., Brown, E. and Salmon A. P.**, 2000. Classification of heart sounds using time-frequency method and artificial neural networks, *Proceedings of the 22nd Annual IEEE-EMBS International Conference*, Chicago, USA, July 23-28, 998-991.
- [15] **Leung, T. S., White, P. R., Collis, W. B., Brown, E. and Salmon A. P.**, 1999. Characterisation of paediatric heart murmurs using Self-Organizing Map, *Proceedings of the First Joint IEEE-BMES-EMBS Conference Serving Humanity, Advancing Technology*, Atlanta, USA, October 13-16, 926.
- [16] **Yoshida, H., Shino, H. and Yana, K.**, 1997. Instantaneous frequency analysis of systolic murmur for phonocardiogram, *Proceedings - 19th International Conference IEEE-EMBS*, Chicago, USA, October 30 - November 2, 1645-1647.
- [17] **Cathers, I.**, 1995. Neural network assisted cardiac auscultation, *Artificial Intelligence in Medicine* 7, 53-66.
- [18] **Durand, L. G., Guo, Z., Sabbah, H. N. and Stein P. D.**, 1993. Comparison of spectral techniques for computer-assisted classification of spectra of heart sounds in patients with porcine bioprosthetic valves, *Medical & Biological Engineering & Computing*, May, 229-235.
- [19] **Xu, J., Durand, L. G. and Pibarot, P.**, 2001. Extraction of the Aortic and Pulmonary Components of the Second Heart Sound Using a Nonlinear Transient Chirp Signal Model, *IEEE Transactions on Biomedical Engineering*, March, vol. 48, no. 3, 277-283.
- [20] **Kemaloğlu, S., Kara S. ve Tezcaner, T.**, 2000. Kalp seslerinin EKG işaretleri ile eş zamanlı alınması ve bilgisayarla analizi, *Biyomedikal Mühendisliği Ulusal Toplantısı (BİYOMUT 2000)*, 59-62.
- [21] **Hadjileontiadis, L. J. and Panas S. M.**, 1998. A wavelet-based reduction of heart sound noise from lung sounds, *International Journal of Medical Informatics*, vol. 52, 183-189.
- [22] **Messer, S. R., Agzarian J. and Abbott, D.**, 2001. Optimal wavelet denoising for phonocardiograms, *Microelectronics Journal*, vol. 32, 931-941.

EKLER


EK A Çalışmada Sınıflandırılan Kalp Sesleri*




Şekil A.1 Açılma Sesi (Opening Snap)




Şekil A.2 Aort Stenozu (Aortic Stenosis)



Şekil A.3 Erken Sistolik Üfürüm (Early systolic murmur)








Şekil A.4 Geç Sistolik Üfürüm (Late systolic murmur)




Şekil A.5 Normal


* Bir periyotluk kayıtlar gösterilmiştir.




EK B Kalp Seslerinin Fourier Dönüşümleri




Şekil B.1 Açılma Sesi'nin Fourier Dönüşümü




Şekil B.2 Aort Stenozu'nun Fourier Dönüşümü




Şekil B.3 Erken Sistolik Üfürümü'nün Fourier Dönüşümü




Şekil B.4 Geç Sistolik Üfürümü'nün Fourier Dönüşümü




Şekil B.5 Normal Kalp Sesi'nin Fourier Dönüşümü




Şekil B.6 S3'ün Fourier Dönüşümü




Şekil B.7 S4'ün Fourier Dönüşümü



Şekil B.8 VSD'nin Fourier Dönüşümü




Şekil B.9 PDA'nın Fourier Dönüşümü

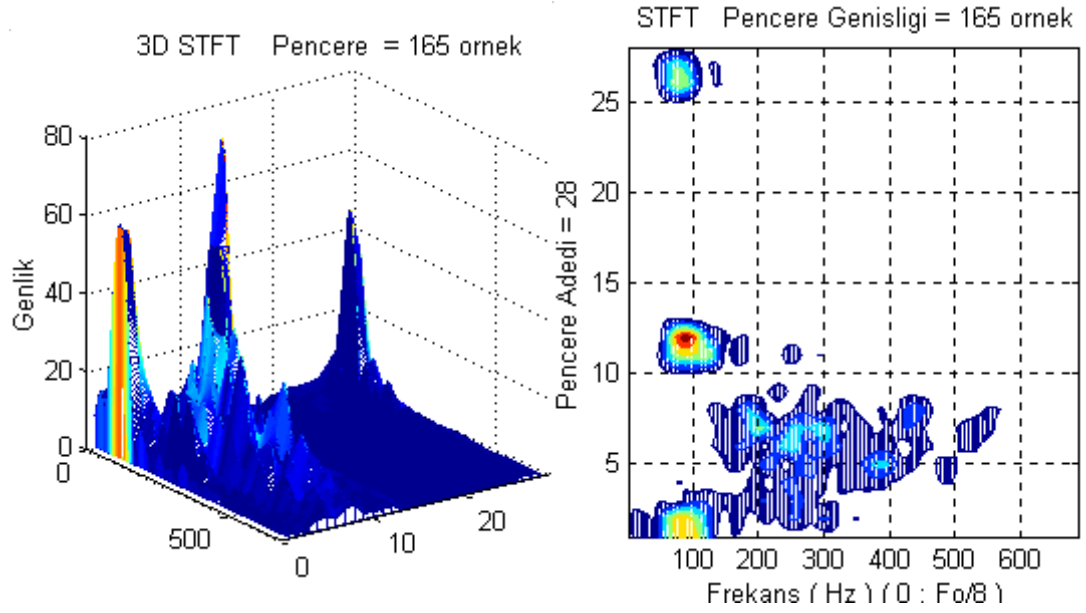


Şekil B.10 ASD'nin Fourier Dönüşümü


EK C Kalp Seslerinin Kısa Zaman Fourier Dönüşümleri




Şekil C.1 Açılma Sesi'nin Kısa Zaman Fourier Dönüşümü




Şekil C.2 Aort Stenozu'nun Kısa Zaman Fourier Dönüşümü



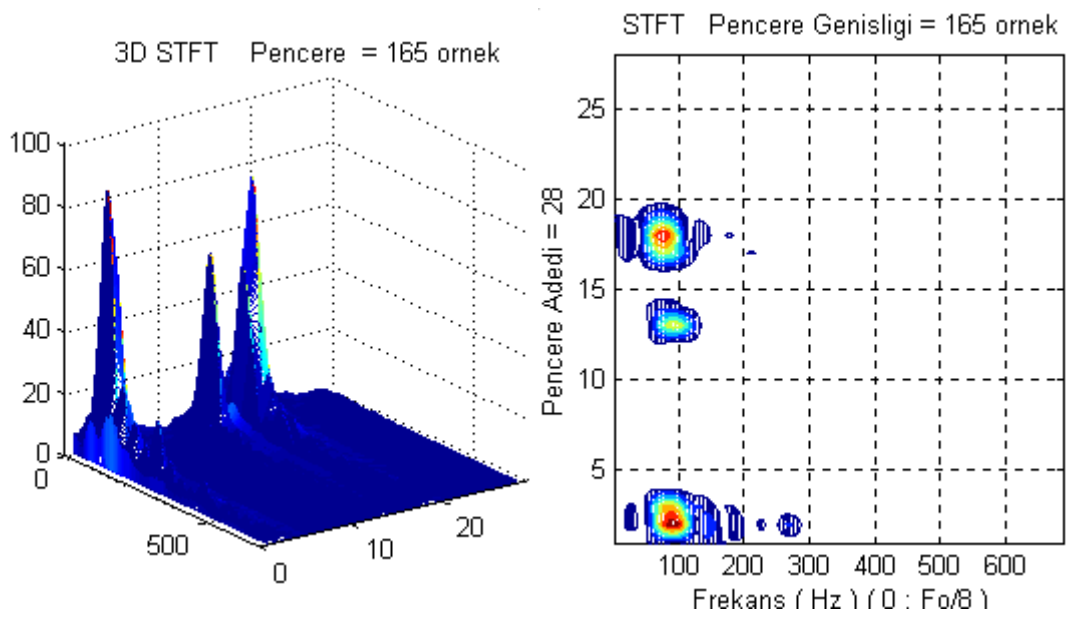
Şekil C.3 Erken Sistolik Üfürümü'nün Kısa Zaman Fourier Dönüşümü




Şekil C.4 Geç Sistolik Üfürümü'nün Kısa Zaman Fourier Dönüşümü



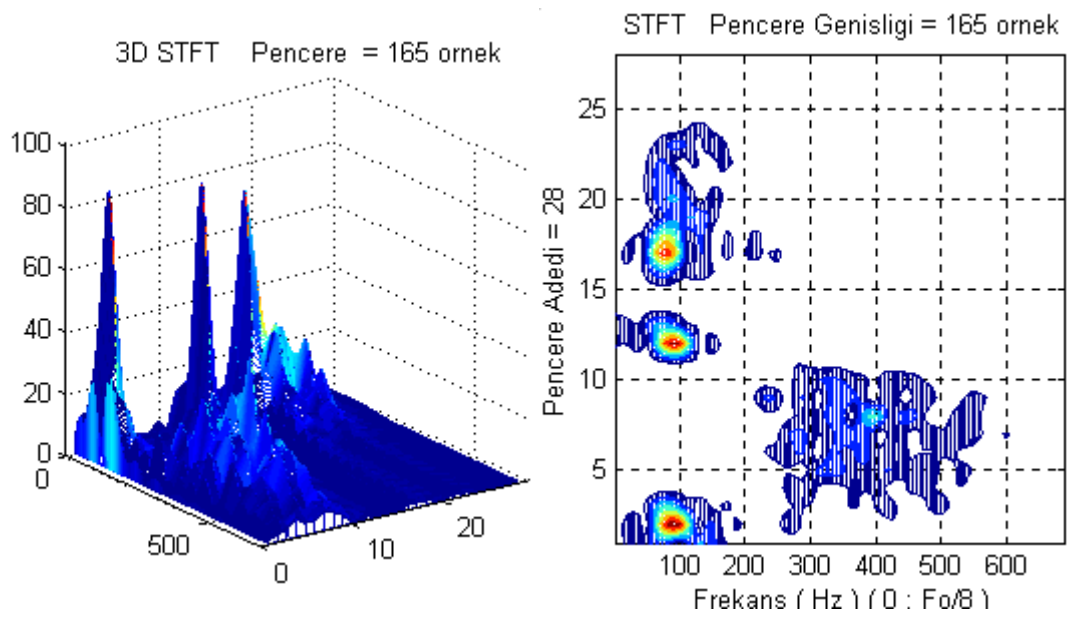
Şekil C.5 Normal Kalp Sesi'nin Kısa Zaman Fourier Dönüşümü



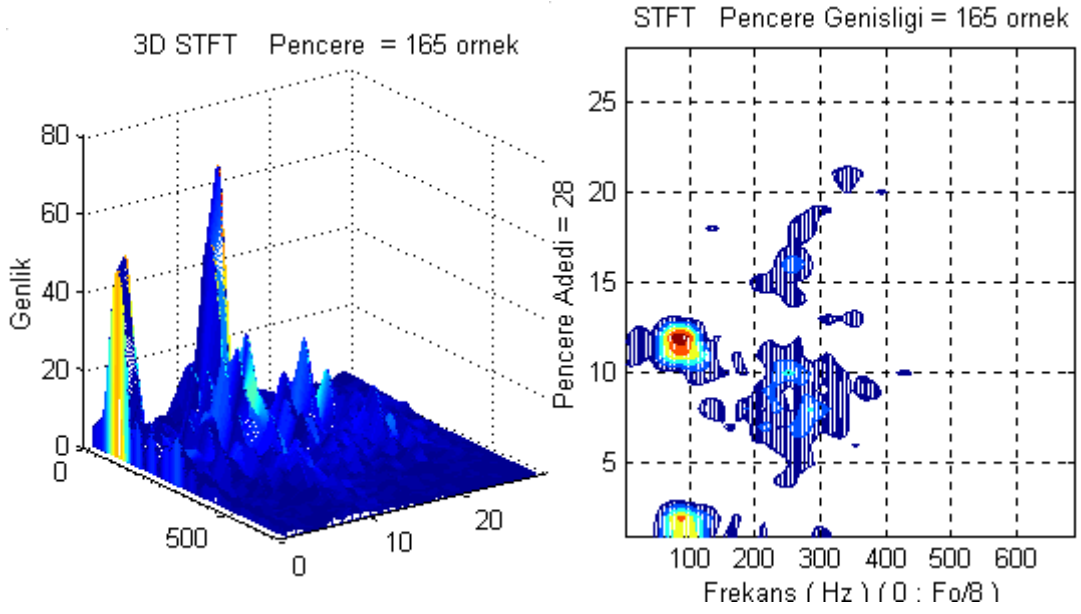
Şekil C.6 S3'ün Kısa Zaman Fourier Dönüşümü



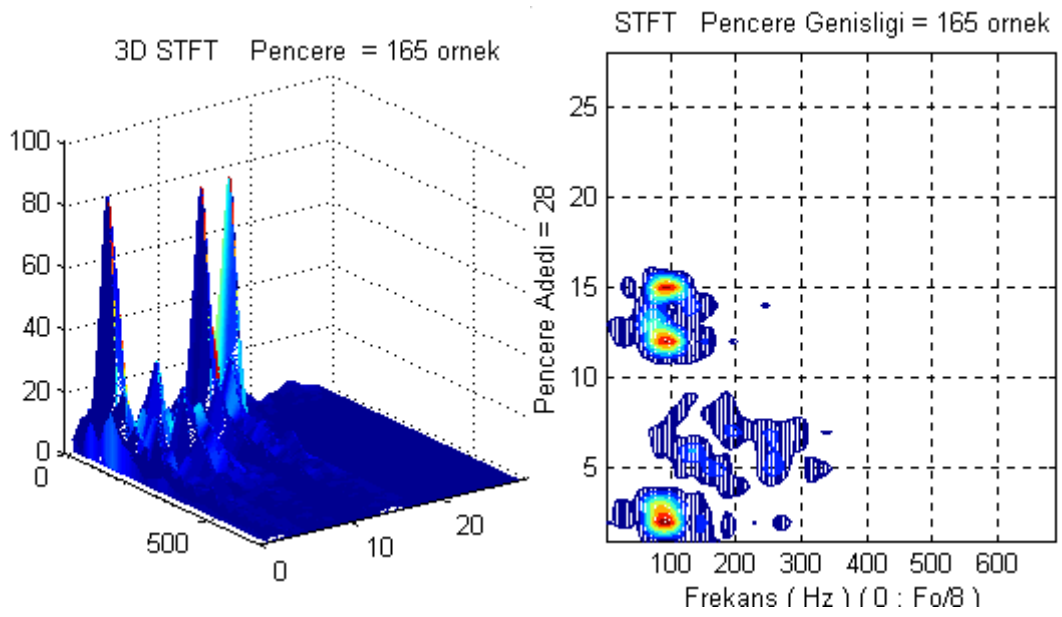
Şekil C.7 S4'ün Kısa Zaman Fourier Dönüşümü



Şekil C.8 VSD'nin Kısa Zaman Fourier Dönüşümü




Şekil C.9 PDA'nın Kısa Zaman Fourier Dönüşümü




Şekil C.10 ASD'nin Kısa Zaman Fourier Dönüşümü


EK D Kalp Seslerinin 4. Seviye Ayrıntı Katsayıları ve Güçleri




Şekil D.1 Açılma Sesi'nin ayrıntı katsayıları ve gücü




Şekil D.2 Aort Stenozu'nun ayrıntı katsayıları ve gücü





Şekil D.3 Erken Sistolik Üfürümü'nün ayrıntı katsayıları ve gücü





Şekil D.4 Geç Sistolik Üfürümü'nün ayrıntı katsayıları ve gücü





Şekil D.5 Normal Kalp Sesi'nin ayrıntı katsayıları ve gücü





Örnek
Şekil D.6 S3'ün ayrıntı katsayıları ve gücü





Örnek
Şekil D.7 S4'ün ayrıntı katsayıları ve gücü



Örnek
Şekil D.8 VSD'nin ayrıntı katsayıları ve gücü




Örnek
Şekil D.9 PDA'nın ayrıntı katsayıları ve gücü




Örnek
Şekil D.10 ASD'nin ayrıntı katsayıları ve gücü


EK E Kalp Seslerinin 4. Seviye Yaklaşıklık Katsayıları ve Güçleri




Şekil E.1 Açılma Sesi'nin yaklaşıklık katsayıları ve gücü




Şekil E.2 Aort Stenozu'nun yaklaşıklık katsayıları ve gücü




Şekil E.3 Erken Sistolik Üfürümü'nün yaklaşıklık katsayıları ve gücü




Şekil E.4 Geç Sistolik Üfürümü'nün yaklaşıklık katsayıları ve gücü




Şekil E.5 Normal Kalp Sesi'nin yaklaşıklık katsayıları ve gücü




Şekil E.6 S3'ün yaklaşık katsayıları ve gücü




Şekil E.7 S4'ün yaklaşık katsayıları ve gücü



Şekil E.8 VSD'nin yaklaşık katsayıları ve gücü




Şekil E.9 PDA'nın yaklaşık katsayıları ve gücü




Şekil E.10 ASD'nin yaklaşık katsayıları ve gücü


EK F Kalp Seslerinin 4 Seviyeli Dalgacık Düzlemi




Şekil F.1 Açılma Sesi'nin Dalgacık Düzlemi



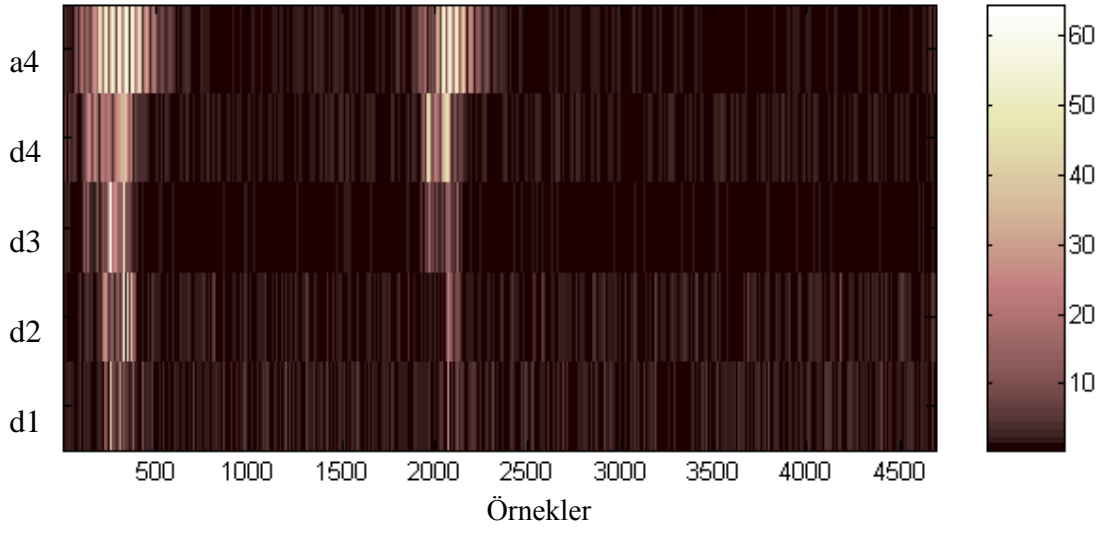
Şekil F.2 Aort Stenozu'nun Dalgacık Düzlemi




Şekil F.3 Erken Sistolik Üfürümü'nün Dalgacık Düzlemi




Şekil F.4 Geç Sistolik Üfürümü'nün Dalgacık Düzlemi




Şekil F.5 Normal Kalp Sesi'nin Dalgacık Düzlemi




Şekil F.6 S3'ün Dalgacık Düzlemi




Şekil F.7 S4'ün Dalgacık Düzlemi



Şekil F.8 VSD'nin Dalgacık Düzlemi



Şekil F.9 PDA'nın Dalgacık Düzlemi



Şekil F.10 ASD'nın Dalgacık Düzlemi

ÖZGEÇMİŞ

Özgür Say, 1978 İstanbul doğumludur. Orta öğrenimini 1994 yılında Bakırköy Yahya Kemal Beyatlı Lisesinde tamamladı. Lisans öğrenimini, 1999 yılında Yıldız Teknik Üniversitesi, Elektronik ve Haberleşme Mühendisliği Bölümünde tamamlayarak, 1999 yılında İstanbul Teknik Üniversitesi, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, Biyomedikal Yüksek Lisans Programına başladı ve halen aynı bölümde eğitimine devam etmektedir.