

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EKG SİNYALLERİNİN DOĞRUSAL OLMAYAN SÜZGEÇLER
YARDIMIYLA GÜRÜLTÜDEN ARINDIRILMASI**

**Tezi Hazırlayan
Selçuk METE**

**Tezi Yöneten
Doç. Dr. Şaban ÖZER**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi**

**Ocak 2010
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**EKG SİNYALLERİNİN DOĞRUSAL OLMAYAN SÜZGEÇLER
YARDIMIYLA GÜRÜLTÜDEN ARINDIRILMASI**

**Tezi Hazırlayan
Selçuk METE**

**Tezi Yöneten
Doç. Dr. Şaban ÖZER**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi**

**Ocak 2010
KAYSERİ**

Doç. Dr. Şaban ÖZER danışmanlığında **Selçuk METE** tarafından hazırlanan “ **EKG Sinyallerinin Doğrusal Olmayan Süzgeçler Yardımıyla Gürültüden Arındırılması** ” adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalında **yüksek lisans** tezi olarak kabul edilmiştir.

25.12.2009
(Tez Savunma Sınav Tarihi)

JÜRİ:

Başkan: Doç. Dr. M. Emin YÜKSEL

M. E. Yüksel

Üye : Doç. Dr. Şaban ÖZER

Şaban Özer

Üye : Yrd. Doç. Dr. F. Latifoğlu

F. Latifoğlu

ONAY:

Bu tezin kabulü, Enstitü Yönetim Kurulunun 26.01/2010 tarih ve 2010/04-02 sayılı kararı ile onaylanmıştır.

26.01. / 2010



Prof. Dr. Nusret AYILDIZ

Enstitü Müdürü

TEŞEKKÜR

Bu tez çalışma danışmanlığını yürüten ve yüksek lisans çalışmalarım süresince gerek danışmanlık gerekse bilgi paylaşımı yönünden yardımlarını hiç esirgemeyen saygıdeğer hocam Doç. Dr. Şaban ÖZER' e ve Arş. Gör. Hasan ZORLU'ya çok teşekkür ederim. Bu çalışma süresince, elde edilen sonuçların uzman gözüyle ne kadar sağlıklı ve başarılı olduğunun yorumlanmasında emeği geçen Erciyes Üniversitesi Tıp Fakültesi Kardiyoloji Bölümü doktoru Sayın Şaban KELEŞOĞLU' na teşekkürlerimi sunarım.

EKG SINYALLERİNİN DOĞRUSAL OLMAYAN SÜZGEÇLER YARDIMIYLA GÜRÜLTÜDEN ARINDIRILMASI

Selçuk METE
Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Aralık 2009
Tez Danışman: Doç. Dr. Şaban ÖZER

ÖZET

Biyomedikal sahada farklı çeşitte birçok sinyal mevcuttur. Bu sinyaller uzmanlara hastalıkların yorumlanması esnasında hayat kurtarıcı bilgiler verirken aynı zamanda diğer sinyaller için doğal gürültü teşkil etmesi sebebiyle hastalara ait teşhislerin konulmasında zorlaştırıcı bir faktör olarak ortaya çıkabilmektedir. Örnek olarak, kasların elektriksel aktivitelerinin dalgalı formu olarak meydana gelen kas sinyali (EMG-Elektromiyogram) EKG (Elektrokardiyogram) sinyaline gürültü olarak karışmaktadır. Bu doğal bozulma genellikle beyaz Gaussian gürültü ile modellenmektedir. Fakat gerçek kas sinyalleri dürtü gürültüsüne benzer keskin ve durağan olmayan karakterli davranışlar sergiledikleri için Gaussian model yetersiz kalmaktadır. Bunun önüne geçilebilmesi için kas sinyalinin en iyi tanımlayabileceği α -bağımlı gürültü ile modellenmesi gerekmektedir.

Yapılan bu çalışmada EKG sinyaline karışan kas gürültüsü (EMG), doğrusal olmayan adaptif ağırlıklandırılmış Myriad ve Median süzgeç ile doğrusal adaptif FIR süzgeç kullanılarak bastırılmış ve başarımları karşılaştırılmıştır. Bu maksatla yüksek çözünürlüklü EKG işaretine gerçek zamanlı olarak kaydedilen EMG işareti ve α -bağımlı yayılım ile modellenen yapay EMG işareti ayrı ayrı eklenmiş ve bu durumlardaki süzgeç performansları incelenmiştir. Yapılan benzetim çalışmalarına göre, Myriad süzgeç yapısının, Median ve FIR süzgeç yapısına göre daha iyi performans sergilediği gözlenmiştir.

Anahtar Kelimeler: EKG, EMG, α -bağımlı gürültü, Myriad süzgeç, Median süzgeç, FIR süzgeç, ağırlıklandırılmış Myriad süzgeç, ağırlıklandırılmış Median süzgeç.

DENOISING ECG SIGNALS BY USING NONLINEAR FILTERING METHOD

Selçuk METE

Erciyes University, Graduate School of Natural and Applied Sciences

M.Sc.Thesis, December 2009

Thesis Supervisor: Assoc. Prof. Şaban ÖZER

ABSTRACT

Many different kinds of signal exist in biomedical environments. These signals give vital information about the interpretation of the disorders but at the same time these signals arise as a compulsive factor in diagnosis due to its natural noise function for other signals. For instance, a wave formed electrical activity of muscles EMG (Electromyogram) blends ECG (Electrocardiogram) as a noise. This natural distortion is usually modeled with a white Gaussian noise. But such assumption is not always true because real life muscle noise has sometimes edged and non-stationary character like an impulsive noise. In order to eliminate these problems, muscle signal have to be modeled with α -stable noise which is the best identification.

In this paper, the muscle noise blended into EKG signal, is suppressed and performed using non-linear adaptive weighted Myriad and Median filters with linear adaptive FIR filters. With this objective; to high resolution ECG signal, real time recorded EMG signal and artificial EMG signal modeled with α -stable distribution are added relatively. Moreover, filter performances in this case are analyzed. Through simulation studies, it is observed that Myriad filter model has preferable performance according to Median and FIR filter models.

Keywords: ECG, EMG, α -Stable Noise, Myriad filter, Median filter, FIR Filter, Weighted Median Filter, Weighted Myriad Filter.

İÇİNDEKİLER

KABUL VE ONAY.....	i
TEŞEKKÜR	ii
ÖZET.....	iii
ABSTRACT.....	iv
KISALTMALAR VE SİMGELER.....	vii
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	ix
 1.BÖLÜM	
GİRİŞ.....	1
1.1. Giriş	1
1.2. Literatür Çalışması.....	2
1.3. Tezin Amacı	8
 2.BÖLÜM	
BİYOLOJİK İŞARETLER.....	9
2.1. Aksiyon Potansiyeli	9
2.2.Biyolojik İşaretler.....	11
2.3. Elektrokardiyografinin Tanımı ve Önemi	12
2.4. Kalbin Anatomisi ve Çalışması	13
2.5. Elektrokardiyogram İşaretlerin Oluşması ve Analizi.....	14
2.5.1. Elektrokardiyogram İşaret Bileşenleri.....	16
2.6. Elektromiyografi Hakkında Genel Bilgi	18
2.7. EMG’ nin Anatomik ve Fizyolojik Altyapısı.....	19
2.8. EMG Analiz Yöntemleri	21
2.8.1. Wavelet Modeli	21
2.8.2. AR Modeli	23
2.8.3. Yapay Zeka Modeli	24
2.8.4. Yüksek Sıralı İstatistik Modeli	25
 3.BÖLÜM	
SİSTEM MODELLEME.....	26

3.1. Sistem ve Model Tanımları	26
3.2. Modelleme İşleminin Yöntemleri	27
3.3. Model Çeşitleri.....	28
3.4. Modellerin Sınıflandırılması	28
3.5. Sistem Modellemenin Temel Basamakları	29
3.6. Adaptif Sistemler	30
3.7. Doğrusal Sistem Modelleme	31
3.7.1. AR Modelleme	31
3.7.2. MA Modelleme	32
3.7.3. ARMA Modelleme.....	32
3.8. Sistem Modelleme İçin Kullanılan Yöntem.....	32
3.8.1.LMS Algoritması	33
3.8.2.RMS Algoritması	33
3.9.FIR Model	34
3.10.Kas Sinyalinin Modellenmesi	34
3.10.1. α -Bağımlı Gürültü	35
3.11.Doğrusal Olmayan Sistem Modelleme	36
3.11.1.Ağırlıklandırılmış Myriad Süzgeç.....	37
3.11.1.1.Temel Myriad.....	38
3.11.1.2.Ağırlıklandırılmış Myriad	39
3.11.1.3. Adaptif Ağırlıklandırılmış Myriad Süzgeç Algoritması	40
3.11.2. Ağırlıklandırılmış Median Süzgeç	42
3.11.2.1. Ağırlıklandırılmış Median Süzgeç Algoritması	45
3.12.Spektral Analiz	46
3.13.Güç Spektral Yoğunluğunun Hesaplanması	47
 4.BÖLÜM	
BENZETİM ÇALIŞMALARI	51
 5.BÖLÜM	
SONUÇLAR	70
KAYNAKLAR.....	72
ÖZGEÇMİŞ.....	86

KISALTMALAR VE SİMGELER

AI	Artificial Inteligent
ANN	Artificial Neural Network
AR	Autoregressive
MA	Moving Average
ARMA	Autoregressive Moving Average
BSS	Blind Source Separation
CWM	Central Weighted Median
DRNN	Dynamical Recurrent Neural Network
EKG	Elektrokardiyogram
EMG	Elektromiyogram
FIR	Finite Impuls Response
HOS	Higher-Order Statistical
LMS	Least Mean Square
MAE	Mean Absolute Error
MSE	Mean Square Error
ML	Maximum Likelihood
MUAP	Motor Ünite Aksiyon Potansiyeli
MISO	Multi Input Single Output
PAR	Polynomial Autoregressive
RLS	Recursive Least Square
SA	Sino Atrial Node
SOS	Second Order Statistics
SISO	Single Input Single Output
WM	Weighted Median
WMF	Weighted Myriad Filter
WMS	Weighted Median Smoother
WT	Wavelet Teorem
WVD	Wigner-Ville Distribution
YSA	Yapay Sinir Ağları

TABLOLAR LİSTESİ

Tablo 2.1.	EKG Parametre Karşılaştırması.	15
Tablo 4.1.	$\alpha = 1,5$ iken MSE değerleri.	59
Tablo 4.2.	$\alpha = 0,5$ iken MSE değerleri.	62
Tablo 4.3.	Gerçek EMG sinyali için MSE değerleri.	65
Tablo 4.4.	Myriad Süzgeç Çıkışlarındaki EKG Bileşen Değerleri.	67
Tablo 4.5.	MedianSüzgeç Çıkışlarındaki EKG Bileşen Değerleri.	68
Tablo 4.6.	FIR Süzgeç Çıkışlarındaki EKG Bileşen Değerleri.	69

ŞEKİLLER LİSTESİ

Şekil 2.1.	Aksiyon Potansiyeli.	10
Şekil 2.2.	Biyolojik İşaretler.	11
Şekil 2.3.	Biyolojik İşaretlere Ait Gerilim ve Frekans Seviyeleri.	12
Şekil 2.4.	Kalp Uyarı İletim Sistemi.	13
Şekil 2.5.	EKG İşareti.	15
Şekil 2.6.	EKG Temel Bileşenleri.	15
Şekil 2.7.	EMG Sinyali ve MUAP'ı Ayırıştırma İşlemi.	21
Şekil 2.8.	Meksika Şapka Wavelet ve Tipik MUAP Şekli.	22
Şekil 2.9.	Deneysel Wavelet Prosedürü.	23
Şekil 3.1.	Dinamik Sistem Şeması.	26
Şekil 3.2.	Adaptif Sistem Model Şeması.	31
Şekil 3.3.	α -Bağımlı Yayılımın Grafiği.	36
Şekil 3.4.	Tipik Myriad Fonksiyon.	40
Şekil 3.5.	Klasik (Parametrik olmayan) Spektral Hesap.	48
Şekil 3.6.	Korelasyon Metodu Blok Diyagramı.	49
Şekil 3.7.	Welch Metodu Blok Diyagramı.	50
Şekil 4.1.	EKG Sinyalinden Kas Gürültüsünün Adaptif Süzgeç Kullanılarak Arındırılması İşlemine ait Blok Şema.	51
Şekil 4.2.	Benzetim Çalışmalarında Kullanılan EKG ve EMG Sinyalleri	53
Şekil 4.3.	EMG İşaretinin α -bağımlı Gürültü Modelleri.	53
Şekil 4.4.	EMG İşaretinin α -bağımlı Gürültü Modellerine ait GSY 'ları.	54
Şekil 4.5.	Gerçek EMG Sinyali ve Gauss Sinyaline ait GSY' ları.	55
Şekil 4.6.	İstenilen EKG işareti.	56
Şekil 4.7.	Yapay EMG işareti eklenen EKG işaretleri.	56
Şekil 4.8.	Yapay gürültülü ($\alpha=1.5$) EKG 'ye ait süzgeç çıkışları.	57
Şekil 4.9.	($\alpha=1.5$) iken Süzgeç Çıkışlarının GSY'ları	59
Şekil 4.10.	Yapay gürültülü ($\alpha=0.5$) EKG' ye ait süzgeç çıkışları.	60
Şekil 4.11.	Yapay gürültülü ($\alpha=0.5$) EKG' ye ait süzgeç çıkışlarının GSY 'ları	61
Şekil 4.12.	Gerçek EMG sinyali ve EKG'ye eklenmiş hali.	62
Şekil 4.13.	Gerçek EMG gürültülü EKG' ye ait süzgeç çıkışları.	63

Şekil 4.14. Gerçek EMG Gürültülü EKG Sinyaline ait Süzgeç Çıkışlarının
GSY'ları

1.BÖLÜM

GİRİŞ

1.1. Giriş

EKG (Elektrokardiyografi) işaretleri, kalp hastalıklarının izlenmesi sürecinde sürekli kaydedilerek değerlendirilmeleri, uygun tanı ve tedavinin belirlenmesi ve uygulanan tedavinin izlenmesi, oluşabilecek anormalliklerin ve komplikasyonların belirlenmesi açılarından oldukça önem taşımaktadır.

Biyomedikal sinyaller kaydedilirken birçok gürültü ortaya çıkabilir çünkü ortamda çeşitli gürültüler mevcuttur ve EKG sinyali çoğu zaman bu gürültülerle bozulabilir. Tanı konulmasında yanlışlıklara neden olmamak için bu gürültülerin EKG sinyalinden arındırılması gerekmektedir. Bu gürültülere örnek olarak; iletim hatlarındaki kayıplar, 50 Hz’lik şebeke gerilimi, EMG (Elektromiyografi) işareti verilebilir. Aslında gürültülerin çoğu kararlı değildir. Yani gürültünün çeşitliliği ile ölçülen gürültü gücü değişiklik gösterebilir [1].

İstatistiksel işaret işleme problemlerinde, en iyi çözümü elde etmek için genel yaklaşım, probleme ait belirli işaret ve gürültü modellerinin oluşturulması şeklindedir. Ancak bu yaklaşım kullanılarak elde edilen en iyi çözümde küçük sapmalar göz ardı edilmektedir. Klasik istatistiksel işaret işleme teorisinde istatistiksel karakteristiklerin modellemesinde Gauss modeller sıklıkla kullanılmaktadır. Gauss model bazı gerçek dünya işlemleri için geçerli olmaktadır. Ancak, gerçek hayatta birçok Gauss olmayan durum meydana gelmektedir. Örneğin, fiziksel işlemlerin büyük bir kısmı doğada dürtü

şeklinde olup Gauss olmayan dağılımlarla daha kesin bir şekilde modellenenilmektedir. Dürtü işaretleri ve gürültüleri, bir veri dizisi içerisinde, keskin, sivri veya arada sırada oluşan durumlar şeklinde karakterize edilmektedir [2]

Kas gürültüsü (EMG), EKG sinyaline karışan ve bastırılması gereken en zor gürültüdür. EMG sinyalleri, genellikle Merkezi Limit Teorisi temel alınarak beyaz Gauss gürültü ile modellenmektedir. Fakat kas gürültüsü çoğunlukla keskin ve dürtü şeklinde meydana geldiğinden Gauss model yetersiz kalmaktadır. Ayrıca, Gauss olmayan gürültülü durumlar Gaussian modellerle optimize edildiğinde performans düşmesi meydana gelmektedir. Son yıllarda, dürtü gürültülü sinyallerin tam bir modeli olarak α -bağımlı dağılıma dayalı gürültü kabul edilmektedir. Bu sebeple kas gürültüsünü α -bağımlı dağılım ile modellemek gerekmektedir [3].

Eğer gürültü ile EKG sinyalinin frekans bandı aynı ise band geçiren süzgeçler gibi geleneksel süzgeçleme yöntemleri kullanılamamaktadır. Bu gibi durumlarda, doğrusal olmayan süzgeçlemeye dayalı gürültü giderme yöntemleri doğrusal süzgeçleme yöntemlerine göre gürültü arındırmada daha başarılıdır [4]. Bu sebeple dürtü gürültüsü doğrusal olmayan süzgeçlerle bastırılabilir. Bu süzgeç yapılarından olan Ağırlıklandırılmış Myriad ve Median süzgeçler son zamanlarda dürtü gürültülü durumlarda güçlü süzgeçleme başarımına sahip oldukları için sıklıkla kullanılmaktadır [5,6].

1.2. Literatür İncelemesi

Sistemlerin modellenmesinde iki tür yöntem mevcuttur, bunlar; doğrusal ve doğrusal olmayan modellerdir. Sistemin giriş-çıkış ilişkisinin doğrusal eşitliklerle ifade edildiği doğrusal modelleme, teorik altyapısının gelişmiş olmasından yaygın bir şekilde kullanılmaktadır [7,8]. Gauss'un 1809'da [9] başlattığı araştırmalar sonucunda sistem modelleme kavramı ilk kez 1962'de Lotfi Zadeh tarafından kullanılmış ve Zadeh bu kavramı "Bir sistemi, giriş ve çıkış ilişkilerinden belirlemek" şeklinde tanımlamıştır [10]. Doğrusal sistemlerin kimliklendirilmesi için autoregressive (AR), moving average (MA) ve autoregressive moving average (ARMA) modeller kullanılmıştır [11,12].

Biyomedikal çevrede, EMG sinyallerinin analizinde bu modellerle ilgili detaylı çalışmalar yapılmıştır.

1975 yılında, Graupe ve Cline [13] EMG sinyallerini ARMA modeli ile kimliklendirmiştir. Graupe ve Cline'nin deneysel sonuçları EMG' nin kısa zamanlı aralıklarda değişken olarak düşünülebileceğini göstermiştir. Sherif [14] 1980'de bu modeli yenilemiştir. Çünkü medikal deltoid'in elektriksel davranışları değişken değildir. Sherif bilimsel incelemesinde EMG' nin değişken özelliği üzerinde durmuş ve AR model kullanarak ARIMA (Integrated Moving Average) modeli bulmuştur. Bu sayede kas aktivitesinin farklı aşamalarında EMG' nin değişken doğasını karakterize etmiştir.

Doerschuk 1983 yılında [15] Graupe ve Cline'nin karşılaştığı benzer problemle karşılaşmıştır; bu ise protez araçların kontrolünde çoklu EMG sinyallerinde AR modelinin kullanılmasıdır. 1986 yılında, Zhou [16], ertelenmiş kas içi EMG sinyallerinin, giriş olması ile birlikte EMG'yi AR modeli olarak göstermiştir. 'Doku süzgeci' olarak adlandırılan model, yüzeysel EMG'den kas içi EMG 'nin formuna bağlıdır. Ayrıca kas içi sinyalleri yüzeysel sinyallere dönüştüren zaman serisi parametreleri de tanımlanmıştır. Tanımlanan model yüzeysel sinyalden kas içi sinyalleri hesaplamada kullanılır. Bu model gerçek EMG dalga formlarını kullanarak açıklamıştır. Hefftner 1988 yılında [17] daha önceki modelleri değerlendirmiş ve EMG sinyal analizi için AR modelini seçmiştir. Bernatos 1986 yılında [18] ARMA ile birlikte istatistiksel doğrusal olmayan bir model kullanmıştır .1992 yılında, Tohru, ARMA ve ARIMA gibi daha kusursuz modellerde, dinamik kas hareketlerinin gerekli olmadığı kanısına varmışlardır. ARIMA modelinin ölçüm maliyeti yüksek ve model sırasının belirlenmesi karışık ve bazen de zordur. Tohru [19] tarafından benzetimde problem olan ölçüm maliyetinden dolayı AR modeli seçmiştir.

Halbuki gerçek hayatta karşılaşılan birçok sistem doğrusal olmayan davranışlara sahiptir. Bu tür sistemlerin kimliklendirilmesinde doğrusal modelleme yöntemleri yetersiz kalmakta ve Volterra, Bilinear ve polynomial autoregressive (PAR) gibi doğrusal olmayan modelleme yöntemlerinin kullanılması gerekmektedir [20,21]. Doğrusal olmayan modellemede, sistemin giriş-çıkış ilişkisi, diferansiyel denklemler, üstel ve logaritmik fonksiyonlar gibi doğrusal olmayan matematiksel ifadelerle

sağlanır. Biyomedikal sahasındaki araştırmalarda Volterra [22-31], Bilinear [32-41] ve PAR [42,43] modellerinin fazla gelişim gösterememesi ve bazı sınırlamalarının olmasından dolayı çok fazla kullanılmamaktadır.

Pratik uygulamalarda kullanılan süzgeçleme algoritmalarının büyük bir çoğunluğu, dürtü yoğunluğunda ciddi performans kayıpları gösteren Gaussian gürültü veya doğrusal işlemlerle sınırlıdır. Biyomedikal sahada EMG gibi ani değişen dürtü sinyallerine uygulanabilen güçlü doğrusal olmayan süzgeçler için esnek bir teori ihtiyacı, biyolojik görüntü işleme sahalarında da ortaya çıkmıştır. Önemli araştırma çabaları, özellikle görüntü işleme alanlarında, ani gürültülere karşı güçlü ve dirençli olan doğrusal süzgeçlere uygun alternatifler bulmaya odaklanmıştır[44]. Bu araştırmalar adaptif sistem modellemesinin keşfiyle başlamıştır, adaptif sistem modelleme 1975 yılında Widrow tarafından En Küçük Ortalama Kareler (Least Mean Square-LMS) algoritması ile başlamıştır [45]. LMS algoritması, ilk olarak 1985 yılında Koh ve Powers tarafından doğrusal olmayan sistemlerin kimliklendirilmesinde kullanılmıştır [46]. Adaptif sistem modellemede İçsel En Küçük Kareler (Recursive Least Square-RLS) algoritmasının geliştirilmesi ile LMS algoritmasının sonuca yakınsamadaki yavaşlığı aşılmış ve daha sonraları Mathews tarafından doğrusal olmayan sistemler için hızlı RLS algoritması geliştirilmiştir [47,48]. Medikal alanda EKG işareti için doğal dürtü gürültüsü teşkil eden EMG sinyalinin giderilmesinde, Widrow öncülüğünde kullanılan adaptif süzgeç yapıları [49-74] zaman içinde gelişmiştir.

Dürtü gürültülü sinyalleri en iyi modelleyen yöntem olarak α -bağımlı yayılım kabul edilmektedir. Çünkü dürtü gürültüsü içerisinde Laplacian veya Gauss dağılımları bulundurabilmektedir. α , ($0 < \alpha < 2$) yayılımın en önemli parametresi olan karakteristik katsayısıdır çünkü α , yayılım kanallarının ağırlığını kontrol etmektedir. ($0 < \alpha < 2$) için, α bağımlı rastgele değişkenlerin sonsuz değişeni bulunmaktadır. $\alpha=1$ olduğu durumlarda Cauchy dağılım özelliği gözlemlenirken, $\alpha=2$ durumunda ise Gauss dağılım gözlemlenmektedir. Myriad ve Median süzgeç yaklaşımları son yıllarda, α -bağımlı gürültü ortamları için güçlü süzgeç yapıları olarak kullanılmaktadır. Bu süzgeç yapıları haberleşme, işaret ve görüntü işleme alanlarına başarıyla uygulanmıştır [75]. Median ve Myriad süzgeçler ilk tasarlandıklarında alçak geçiren süzgeç tipinde gürültü giderme özelliğine sahiptiler [76,77]. Son zamanlarda bu süzgeçlere negatif ağırlıklandırma

özelliği kazandırılarak daha güçlü süzgeçleme karakteristiği eklenmiştir [78-81]. Bu sayede süzgeçler alçak geçiren, yüksek geçiren, band durduran, band geçiren davranışları da sergileyebilmektedir.

1970 yılında Tukey tarafından ortaya konulan median süzgeç, görüntüler üzerindeki dürtü gürültülerinin giderilmesinde etkili bir yöntem olarak kullanılmış ve günümüze kadar gelmiştir. Bu süzgeç sıralı istatistik [82] temeline dayanmaktadır. Median süzgeç zaman içinde geliştirilerek çeşitli türleri sırasıyla ortaya çıkmıştır bunlar; ağırlıklandırılmış median (Weighted Median-WM) [83], merkezi ağırlıklandırılmış median (Central Weighted Median-CWM) [84], son olarak Un ve Neuvo [85] ile Florencio ve Schafer [86] tarafından ortaya konulan anahtar temelli median (Switched Median-SM) süzgeçlerdir.

Myriad süzgeç elektronik sistemler üzerinde, güçlü dürtü gürültüsü bastırma özelliğine sahiptir. 2000 yılından bugüne kadar Myriad süzgeç; sinyal işlemleri [87], dijital video [88], endüstriyel kontrol sistemleri [89], görüntü süzme işlemleri [90] ve EKG sinyalinden dürtü gürültülerinin giderilmesi gibi farklı alanlarda başarıyla uygulanmıştır. Myriad süzgecin en önemli avantajı; Gauss yayılım olmayan gürültülü işaretlere, özellikle anlık değişim gösteren tetiklemeli gürültülere karşı sistem parametrelerini doğru kestirebilmesidir. Ayrıca lineerlik katsayısına sahip olması, gürültü giderme işleminde Median süzgece göre daha başarılı olmasını sağlamaktadır. EKG sinyaline dürtü gürültüsü olarak karışan EMG sinyallerinin bastırılmasında Pander tarafından geliştirilen ağırlıklandırılmış Myriad süzgeç (Weighted Myriad Filter-WMF) [91-94] uygulamaları etkin olarak kullanılmaktadır.

Raphisak ve Schuckers [95] görüntü işleme alanında sıklıkla kullanılan Morfolojik süzgeci EKG işareti karışan EMG sinyalini tespit etmek ve süzmek için kullanmıştır. Bu tip süzgeçler EMG gibi beklenmeyen yani ani şekilsel değişimler gösteren sinyalleri süzgeçleyebilme yeteneğine sahiptir. Süzgeçlerde kullanılan algoritma az kompleks hesaplama yöntemleri tercih edildiğinden hızlı geri bildirimler elde edilebilmektedir. Chen ve arkadaşları [96] ilerleyen zamanlarda QRS tespiti için matematiksel morfoloji metodunu sunmuştur. Daha sonra Sun ve arkadaşları [97] gelişmiş bir morfolojik yaklaşım ortaya koymuştur.

Gürültü giderilmesinde gün geçtikçe yeni yaklaşımlar ortaya çıkmaktadır. Bu yeni yaklaşımlardan biriside Wavelet teoremidir(WT). Waveletlerin Fourier Dönüşümleri Fourier'in 1807 de ortogonal Fourier serilerini tanımlamasıyla başlayan süreç içerisinde yapılan çalışmalar, 1873'de Fourier serileriyle başka bir değere yakınsanamayan bir fonksiyonun bulunmasına yol açmıştır . Bu problem Haar'ın 1909'da, herhangi bir $f(x)$ fonksiyonuna düzgün dağılımlı olarak yakınsanabilecek yeni bir ortogonal seri oluşturmaya yol açmıştır. Haar serileri Fourier serilerinde karşılaşılan yakınsama güçlüğü çözerken, fonksiyonlarda karşılaşılan eğimlerin ifade edilmesinde yetersiz kalmaktadır. Çünkü küçük bir eğim ancak çok sayıda taban fonksiyonu kullanılarak ifade edilebilmektedir.

1980'lere kadar matematikçiler Haar serilerinde karşılaşılan bu sorunu çözmeye çalışmışlar, 1980'lerin sonlarında ise "dalgacık" kavramını ortaya atmışlardır.

Dalgacık analizi, bir sinyale ait zaman ve frekansla tanımlı bölgelerde yer alan bilgileri eşzamanlı olarak gösterdiği için sinyaldeki eğilimleri, çöküm noktalarını ve süreksizlikleri belirlemek açısından diğer dönüşüm tekniklerine göre daha avantajlıdır. Biyolojik işaretlerin analizinde sıklıkla kullanılan bu analiz yönteminin sahip olduğu en önemli özelliği yüksek frekanslarda yüksek zaman ve düşük frekans çözünürlüğü sağlarken alçak frekanslarda yüksek frekans ve düşük zaman çözünürlüğü sağlamasıdır. Guglielminotti and Merletti [98] şunu teorikleştirmişlerdir; eğer wavelet analizi MUAP (Motor Unit Action Potential)'ın şeklini eşleştirmek için seçilmişse, sonuç WT'si zaman düzleminde maksimum enerji lokasyonunu sağlar. 1997 yılında, Lazerta ve Olmo WT' nin doğrusallık, çoklu çözünürlük sağlama ve karşıt terimlerden etkilememe gibi avantajlarıyla diğer zaman frekans göstergelerine bir alternatif oluşturmuştur. Belirli koşullarda, EMG sinyali tek bir prototipin ölçeklenmiş ve ertelenmiş bir versiyonu olarak düşünülebilir. Guglielminotti'nin teorisine dayanarak, Lazerta ve Olmo [99] Wavelet analizini MUAP' ın şeklini eşleştirmede kullanmışlardır. 1999 yılında, Pattichis [100], WT'nin farklı karar aşamalarında sinyalleri analiz etmek için kullanılabileceğini de göstermişlerdir. Bu araştırmacılar, Wavelet katsayısı ve zaman frekans düzlemi arasında ki bağlantıyı da analiz etmişlerdir. 2003 yılında, Kumar, WT'nin Wavelet Fonksiyonu(WF) denilen önermesiyle karşımıza çıkmıştır. WF,

sEMG' nin zaman domeninde iki boyutlu karşılıklı korelasyonu alınarak hem açıklanır hem de dönüştürülür. EKG sinyalinden gürültü giderilmesinde yakın zamanlarda Wavelet modeli [101-89] sıklıkla kullanılmaktadır.

Nikolaev ve Gotchev [116-120] EKG sinyalinin yüksek genlikli olması sebebiyle EMG sinyaline karıştığı anda kas sinyalini bozucu yönde etki yaptığını tespit etmiştir. Bu sebeple ECG sinyalinin arındırılması için , Wiener süzgeç metodunu önermişlerdir.

Son 10 yılda bağımsız bileşen analizine (ICA-Independent Component Analysis) dayalı sinyal ayırt etme metodları oldukça kullanışlı bir hale gelmiştir. Bu nedenle bağımsız bileşen analiz, EKG sinyali ile EMG sinyalini [121-125] ayırtmak amacıyla da kullanılmıştır.

Son yıllarda yapılan çalışmalarda doğrusal yada doğrusal olmayan sistemlerin modellenmesinde ve parametrelerinin belirlenmesinde yapay zekaya dayalı yöntemler önem taşımaktadır. Sistemlerin modellenmesinde, model yapısı ve istatistik değerlerin (model derecesi,giriş ve gürültünün dağılımı vb.) iyi bilinmesi halinde iyi çözümler sunar .Yapay sinir ağları (Artificial Neural Network-ANN)), model yapısının tam olarak bilinmesi zorunluluğu ortadan kaldırmaktadır [126]. Miyoelektrik sinyalleri (Myoelectric Signal) tanıyabilen yapay sinir ağlarının gerçek zamanlı uygulamaları 1994 yılında Del ve Park [127] tarafından önerilmiştir. Sinir ağ yapısı bazı avantajlar sunar; hastaya hızlı bir sistem uyarlaması ve sisteme daha iyi bir hasta adaptasyonudur. 1996 yılında Cheron ve arkadaşları tarafından ANN temelli yeni bir metod ortaya konmuştur. Bu metod, kol kineomatikleri ile kas EMG aktivitesi arasındaki bağlantıyı ifade etmek için yapay dinamik devirli sinir ağ (Dynamical Recurrent Neural Network) (DRNN)'lara dayanır. Araştırmacının amacı, bu DRNN ifadesinin biyomekanik olarak inandırıcılığını kanıtlamaktır. EMG sinyalleri gibi biyomedikal sinyaller her zaman tekrarlanabilir değildir ve hatta bazen tutarsız olabilirler. Bu amaçla Kumar [128-130] EMG sinyaline karışan ECG sinyalini ayırt etmek için yapay zeka temeline dayanan çeşitli yaklaşımlar sunmuştur.

EMG sinyaline karışan ECG yi gerçek zamanlı olarak ayırt edebilmek son zamanlarda ortaya çıkan yüksek süzgeçleme başarımı gösteren Hybrid süzgeç [131-133] metodu kullanılmaktadır .

1.3. Tezin Amacı

Bu çalışmada, EKG sinyaline doğal olarak bozucu etkide bulunan kas gürültüsü (EMG), son zamanlarda literatüre yeni katılan doğrusal olmayan sistem modellerinden adaptif ağırlıklandırılmış Myriad ve Median süzgeçler ile bastırılmıştır. Bu yeni model yaklaşımlarının performans başarımlarını gözlemlemek için, sonuçlar doğrusal adaptif FIR(Finite Impuls Response) süzgeç sonuçları ile karşılaştırılmıştır. Bu amaçla, EKG işaretine gerçek zamanlı olarak kaydedilen EMG işareti ve α -bağımlı yayılım ile modellenen yapay EMG işareti ayrı ayrı eklenmiş ve bu durumlardaki süzgeç performansları incelenmiştir. Yapılan benzetim çalışmalarına göre, Myriad süzgeç yapısının, Median ve FIR süzgeç yapılarına göre daha iyi performans sergilediği gözlemlenmiştir.

Tez çalışması bölümleri şu şekilde oluşturulmuştur: İkinci bölümde, çalışmalarda sistemlere giriş verisi olarak kullanılan EKG ve EMG biyomedikal sinyallerinin analizi hakkında bilgi verilmiştir. Doğrusal olmayan sistem modellerinden Ağırlıklandırılmış Median ve Myriad süzgeçler ile doğrusal FIR süzgecin özellikleri ve bu modellerin eğitiminde kullanılan algoritmalar hakkında üçüncü bölümde bahsedilmiştir. Dördüncü bölümde, Sistem benzetim çalışmaları ve uygulamalara ait sonuçların karşılaştırılmaları yapılmıştır. Son bölümde ise tez çalışmasında ulaşılan sonuçlar değerlendirilmiştir.

2.BÖLÜM


BİYOLOJİK İŞARETLER

2.1. Aksiyon Potansiyeli

Bütün canlı hücreler gibi kalp hücrelerinin iç yüzeylerinde hücrenin dış yüzeyi ile kıyaslandığında negatif elektrik yükleri bulunur . Hücre membranlarının iki yüzeyi arasında oluşan bu voltaj farkı , membran potansiyeli olarak adlandırılır. İstirahat membran potansiyeli (Kalp hücrelerinde eksi 80mV ile 90mV arasındadır), negatif yüklü moleküllerin (iyon) hücre membranı içinde birikiminin bir sonucudur.

Hücreler uyarıldıklarında hücre membranındaki küçük kanalcıklar ya da delikler birbirini izleyerek ardı ardına açılır ve kapanır. Bu kanalların açılması iyonların hücre membranı boyunca dışarı ve içeri düzenli bir şekilde hareketine izin verir ve böylece hücre membran potansiyeli değişir. Bu voltaj değişikliklerinin zamana karşı grafiği çizildiğinde kardiyak aksiyon potansiyeli ortaya çıkar.

Aksiyon potansiyeli tek bir kalp hücresinin elektriksel aktivitesinin şekil üzerinde yansımasıdır. Klasik olarak 5 faza ayrılan aksiyon potansiyeli Şekil 2.1’de görülmektedir. Aksiyon potansiyelinin anlaşılmasında en fazla yardımcı olan 3 genel faz ; depolarizasyon , repolarizasyon ve istirahat fazlarıdır[134].



Şekil 2.1. Aksiyon Potansiyeli.

Depolarizasyon :

Depolarizasyon fazı (0. faz) aksiyon potansiyelinin aksiyon fazıdır. Depolarizasyon hücre membranındaki hızla çalışan Na kanallarının uyarılarak açılmasıyla oluşur. Bu kanallar açıldığında Na iyonları hücre içinde dolar ve hücre potansiyelinde hızlı ve pozitif yönde bir değişim olur. Oluşan voltaj değişikliği depolarizasyon olarak adlandırılır[135,136].

Repolarizasyon:

Bir hücre depolarize olunca , depolarizasyon sırasında oluşan iyonik girişler geri dönünceye kadar tekrar depolarize olamaz. İyonların başladıkları yere geri dönme işlemi “repolarizasyon” olarak adlandırılır. Kalp hücresinin repolarizasyonu, aksiyon potansiyelinin 1, 2 ve 3 . fazlarını oluşturur. Repolarizasyon kardiyak aksiyon potansiyelini, istirahat membran potansiyeline döndürür. [137,138]

İstirahat :


Çoğu kalp hücresi için istirahat fazı (4. Faz olarak ifade edilen, aksiyon potansiyelleri arasında zaman periyodu) pasif bir devredir ve hücre membranları iç ve dış yüzeyleri arasında net bir iyon geçişi hareketi yoktur.

Elektrik kökenli biyolojik işaretlerin algılanmasında kullanılan elektrokimyasal dönüştürücülere, biyopotansiyel elektrot veya sadece elektrot adı verilir. Vücudumuzdaki biyopotansiyeller, iyon hareketleri sonucunda oluşurlar. Elektrotlar da

iyon akımlarını elektron akımlarına dönüştürerek, kimyasal enerjinin elektriksel enerjiye dönüşmesini sağlarlar. Elektrotların iyon akımını elektron akımına dönüştürme işlemi, elektrotlar elektrolit içinde iken, elektroda yakın olan arayüzde gerçekleşir[139-141].


2.2. Biyolojik İşaretler

En genel manada işaret, bilgi taşıyan, zamana göre değişen veya değişmeyen büyüklükler olarak tanımlanabilir. Biyolojik işaret ise canlı vücudundan elektrotlar veya dönüştürücüler aracılığıyla algılanan, elektrik kökenli olan veya olmayan işaretlerdir. Biyolojik işaretlerin temelini, hücrelerdeki elektrokimyasal olayların sonucunda oluşan aksiyon potansiyeli oluşturur. Şekil 2.2’de biyolojik işaretler gösterilmiştir.



Şekil 2.2. Biyolojik İşaretler.

Elektrik kökenli işaretler elektrotlar aracılığıyla canlı vücudundan algılanırlar ve yalıtım oldukça önemlidir, genlikleri küçüktür; (100 μ V ile 1 mV arasında), spektrumu (0,1 Hz ile 2000 Hz arasında) alçak frekanslar bölgesinde fark işareti şeklinde bulunur. Şekil 2.3’de biyolojik işaretlere ait gerilim ve frekans seviyeleri gösterilmiştir. Ayrıca gürültülü işaretlerdir; temel gürültü kaynakları: ortak mod şeklindeki 50 Hz’lik şebeke gürültüleri, fark işaret şeklinde bulunan diğer biyolojik işaret kaynakları ve elektronik eleman gürültüleri olarak sıralanabilir.



Şekil 2.3. Biyolojik İşaretlere Ait Gerilim ve Frekans Seviyeleri.

Biyolojik işaretlerden , ECG sinyali 0.5Hz ile 100Hz arasında frekans bandına ve 0mV ile 5mV arasında genlik değerine sahipken, EMG sinyali ise 50 μ V ile 5mV arasında genliklere ve 10Hz ile 1kHz arasında bir frekans bandına sahiptir[142].

Biyolojik işaretler genellikle, yaşayan organizmalardan ve çoğunlukla insanlardan alınır. Bu nedenle ölçme sistemi, ölçülen sisteme zarar ve acı vermeyecek şekilde olmalıdır. Bu şekilde elde edilecek işaretler direkt olarak kaynaktan değil de, dolaylı olarak vücut yüzeyinden alınacağı için işaretlerin daha zayıf ve gürültülü olacağı kesindir.

İşaret, bazen, direkt olarak orijinal bilgi kaynağından üretilir ve bu durumda, işarete bakarak kaynağın yapısı veya işleyişi hakkında bilgi elde edilebilir. Bazen de elde edilen işaret, direkt olarak istenen bilgiyi vermeyebilir bu durumda hem işaret üzerinden isteneni elde edebilmek için hemde yukarıda da bahsedilen gürültü oranını azaltmak için çeşitli işlemler uygulanır [143].

2.3. Elektrokardiyografinin Tanımı ve Önemi

İnsan vücudu üzerinden algılanan ve kalbin elektriksel aktivitesinin sonucu olarak ortaya çıkan belli tipteki biyolojik işaretlere elektrokardiyografik (EKG) işaret adı


verilir. EKG işaretinin gösterilmesini veya kaydedilmesini sağlayan cihazlara “Elektrokardiyograf” ve EKG ile ilgili sistem ve olgulara da genel olarak “Elektrokardiyografi” denir.

Kayıt edilen EKG’lerin normal EKG’lerle karşılaştırılmasıyla, kalbin çalışmasıyla ilgili bazı normal dışı durumlar belirlenebilir. Bir doktorun hastada yapılmasını istediği temel ölçümlerden birisi EKG ve kalp vuru hızının ölçümüdür. EKG’de her kalp atımının karşılığı olan P,Q,R,S,T dalgalarından oluşmuş bir işaret görülür[144].

EKG İşaretlerinin Önemi ; Atrial ve ventriküler iletim bozuklukları, Ritim bozukluklarının ojininin saptanması ve monitorize edilmesi, Perikarditler, Kalbi etkileyen sistemik hastalıklar, Kardiyak pacemakerların fonksiyonlarının takibinde kullanılımsındandır.

2.4. Kalbin Anatomisi ve Çalışması

Kalbin sol tarafında temiz sağ tarafında ise kirli kan bulunur. Sol karıncıktan çıkan temiz kan Aort atar damarı ile vücuda besin taşıyıp sağ kulakçığa gelir, buradan kan sağ karıncığa iner , sağ karıncıktan alt ve üst ana toplar damarlar ile temizlenmek üzere akciğerlere gelir oradan da sol kulakçığa gelerek sol karıncığa geçer ve böylece dolaşımını tamamlamış olur. Şekil 2.4’de kalp uyarı iletim sistemi gösterilmiştir.




Şekil 2.4. Kalp Uyarı İletim Sistemi.

Alt ve üst ana toplar damarların sağ kulakçığa açıldığı ağızlar arasında yer alan ve kendi kendine uyarılan özel düğümsü dokuya Sinüs Düğümü (Sino Atrial Node - SA) denir. Bu düğümün karşısında sağ karıncığın hemen üstünde bir düğüm daha vardır. Bu düğümüne ise Kulakçık Karıncık Düğümü (Atrio Ventriküler Node - AV) denir. SA düğümünden uyarıyı AV düğümüne purkinje lifleri ulaştırır sonra uyarı his demeti ile yoluna devam eder .His demeti karıncıklarda sağ ve sol olmak üzere iki kola ayrılır ve purkinje lifleri ile bütün karıncıklara dağılır[146].


2.5. Elektrokardiyogram İşaretlerin Oluşması ve Analizi

Bütün vücut kasları içinde bir tek kalp kası, otomatik kasılma yeteneğine sahiptir. Kalbin elektrik sistemi, her bir kalp atışı ile miyokardın ardı ardına kasılmasının devamlılığını sağlamak üzere düzenlenmiştir. Elektriksel uyarı AV oluğa doğru kulakçıklara yayıldığında kulakçıklar kasılır. AV düğüm tarafından sağlanan gecikme , elektriksel uyarıların karıncıklara ulaşmasından önce kulakçıkların boşalmalarını tamamlamasına izin verir. Uyarı akımları AV düğümü terk eder etmez , purkinje lifleri yoluyla hızla karıncık kasına yayılır ve böylece canlılık için gerekli düzenli karıncık kasılmaları sağlar.Bu elektriksel dürtüler vücut yüzeyinin çeşitli bölgelerine konan elektrotlar aracılığı ile kayıt edilmektedir.

Elektrokardiyogram işareti Şekil 2.5'de ve EKG temel bileşenleri Şekil 2.6'da görülmektedir. Yüzüncü yıl üniversitesinin yaptığı bir araştırmaya göre [145] sigara içen ve içmeyen bireylere (n; verilerin alındığı denek sayısını ifade etmektedir) ait EKG işaret bileşenlerinin değerleri Tablo 2.1'de verilmiştir. Dalgalar arasındaki elektrokardiyogram parçasına SEGMENT (Parça), bir dalganın başlangıcı ile diğer dalganın başlangıcı arasındaki mesafeye ise INTERVAL(Aralık) denir. Dalgaların, segmentlerin ve intervallerin süreleri saniye cinsinden ifade edilir.



Şekil 2.5. EKG İşareti.



Şekil 2.6. EKG Temel Bileşenleri.

Tablo 2.1. EKG Parametre Karşılaştırması.

Ölçülen Parametreler	Kontrol (Sigara içmeyen) grubu (n=10)	Deneme (Sigara içen) grubu (n=20)
P (sn)	0.09 ± 0.00	0.09 ± 0.00
P (mV)	0.20 ± 0.02	0.18 ± 0.01
P-R (sn)	0.16 ± 0.01	0.15 ± 0.00
QRS (sn)	0.08 ± 0.00	0.09 ± 0.01
QRS (mV)	0.90 ± 0.02	0.90 ± 0.00
T (sn)	0.21 ± 0.01	0.20 ± 0.02
T (mv)	0.40 ± 0.01	0.39 ± 0.01
Q-T (sn)	0.36 ± 0.02	0.32 ± 0.01
Kalp Atım Sayısı (Atım/dk)	62.7 ± 10	90.3 ± 15
Elektiriksel Eksen (°)	+70 ± 10.33	+68 ± 15.10
Arteriyel Kan Basıncı (mm/Hg)		
Sistolik	110.4 ± 5	128.1 ± 10
Diyastolik	70.3 ± 6	80.3 ± 10

2.5.1. Elektrokardiyogram İşaret Bileşenleri

Eksen (Axis):

Eksen, kalbe doğru olan elektriksel gücün genel yönüdür.

- Aşırı sapmalar normal değildir ve dal bloğu (bundle branch block), ventriküler hipertropi veya sağda ise pulmonary embolizm olduğunu belirtir[147].
- Kalbin yüzeyindeki dektrokardi veya yönün ters dönmesini teşhis edebilir. Aslında bu durum çok nadirdir ve genelde başka yollarda teşhis edilir (göğüs röntgeni gibi).

P Dalgası :

Bu dalga dalga elektrokardiyogramın ilk dalgası olup Kulakçıkların kasılmasına sebep olan sinüs kaynaklı uyarının atrium içinde yayılması ile oluşur. Sinüs düğümünden çıkan uyarının AV düğümüne ulaşması için geçen süre P dalgasının süresini belirler. P dalgasının genliği normalde 0.18 mV ile 0.22 mV arasındadır. Süresi de yaşa göre değişmektedir[141]. Düzenli olmayan veya hiç olmayan P dalgaları ritm bozukluğunu gösterir.

Q Dalgası :

Normal Q dalgasının gerilim kriteri üzerinde otoriterler arasında fikir birliği yoktur. Süre kriteri üzerindeki anlaşmazlıklar ise daha azdır. Süre kriterinin , gerilim kriterinden daha önemli olduğu kabul edilir.

QRS Kompleksi :

Şekil 2.5’de görüldüğü gibi Q dalgası aşağıya doğru olan ilk negatif dalgadır. Q dalgası, ortaya çıktığında, küçük yatay akımı (soldan sağa) temsil eder, çünkü hareket potansiyeli karıncıklar arasındaki bölgede ilerler. Çok geniş ve derin Q dalgalarının septal başlangıcı yoktur, fakat çok derin miyokardiyum içeren miyokardiyal enfarktüs belirtir. R dalgası yukarıya doğru olan ilk dalgadır. S dalgası ise R dalgasını izleyen ilk negatif dalgadır. R ve S dalgaları miyokardiyum kasılmasını belirtir. QRS kompleksi, sol ve sağ karıncığın kasılmasına neden olan akımı belirtir[147]. QRS kompleksindeki anormallikler tachycardia, ventriküler hipertropi ve bazı diğer karıncık anormalliklerini

gösterir. Perikard iltihabında veya perikard efüzyonunda QRS genliği genelde küçüktür.

ST Parçası:

QRS kompleksinin sonu ile T dalgasının başlangıcı arasındaki bölüme ST parçası denir. ST parçası normalde izo elektrik çizgidedir. Fakat anormal ST parçası izo elektrik çizgide olabileceği gibi normal ST parçası da izo elektrik çizginin altında veya üstünde olabilir[141].

QT Parçası :

Bu süre karıncıkların depolarizasyonu ve repolarizasyonu için gerekli olan zamanın ifadesidir. QT aralığı yaş , cins , kalp hızına göre değişim gösterir . Yetişkinlerde genellikle 0,35 – 0,44 sn. arasındadır. QT aralığı QRS kompleksinin başlangıcından T dalgasının sonuna kadar geçen süredir.

PR Parçası :

P dalgasının bitiminden QRS kompleksinin ister Q , ister R olsun başlangıç dalgasına kadar sürer.

PR Aralığı :

P dalgasının başlangıcından QRS kompleksinin başlangıcına kadar olan elektrokardiyogram bölümüne denir. Uyarının sinüs düğümünden karıncıklara iletilmesi için geçen süreyi gösterir. QRS kompleksi Q dalgası ile başladığı zaman PR aralığı yerine PQ aralığı deyimini kullanılabilir. PR aralığının süresi yaşa ve kalp hızına göre değişmektedir.

T Dalgası :

Karıncıkların repolarizasyonunu belirtir. QRS kompleksi genelde kulakçık repolarizasyon dalgasını gizler, ve görünmez olur. Birçok derivasyonda, T dalgası pozitifdir. T dalgası normalde hafifçe asimetriktir. İnen kol çıkan kola göre biraz daha diktir. Ters bir T dalgası (negatif) bir rahatsızlığın belirtisi olabilir. T dalgasındaki anormallikler, hyperkalemia veya hypokalemia gibi elektrolit rahatsızlıkları belirtisi olabilir.

U Dalgası :

U dalgası her zaman görülmez. Oldukça küçüktür ve T dalgasını yakından takip eder. Belirgin U dalgaları, hypokalemia ‘da sık sık görülür. Ters çevrilmiş bir U dalgası miyokardiyal ischemia veya sol karıncık hacminin aşırı büyüdüğünü gösterir[147].

2.6.Elektromiyografi Hakkında Genel Bilgi

Elektromiyogram (EMG), kasın kasılması sonucu ortaya çıkan biyopotansiyel işaretlerdir. İğne veya yüzey elektrodlarla alınan, kasın hareketi esnasında oluşan elektriksel işaretlere “Elektromiyogram” veya kısaca EMG denir. Büzülme ve gevşeme gibi kas aktiviteleri her zaman sinir sistemi tarafından kontrol edilmektedir. Bu yüzden, EMG sinyali kasların anatomik ve fizyolojik özelliklerine bağlı olarak sinir sistemi tarafından kontrol edilen karmaşık bir sinyaldir.

Güçlü ve gelişmiş metodolojiye sahip olan EMG sinyalleri biyomedikal mühendislikte önemli bir gereksinim haline gelmiştir. EMG sinyal analizlerine olan bu ilginin temel sebebi; klinik teşhisler ve biyomedikal uygulamalardır. Bir diğer önemli uygulama alanı olarak da motor nöronları yetersizliklerindeki yönetim ve rehabilitasyon sahasıdır. Kasların kasılması, sinirler aracılığıyla beyinden iletilmiş olan uyarıcı potansiyellerin kaslarda oluşturduğu Motor Ünite Aksiyon Potansiyelleri (MUAP) olarak bilinen elektriksel potansiyeller sayesinde olur. EMG sinyallerindeki MUAP’ların şekli ve atış oranları nöromuskular rahatsızlıkların teşhisinde önemli bir bilgi kaynağı olarak kullanılmaktadır.

Sinyal uygulamalarında ve matematiksel modellerdeki son ilerlemeler, EMG ölçümleri ve analiz tekniklerinin geliştirilmesine kolaylıklar sunmuştur. Çeşitli matematiksel teknikler ve Yapay Zeka (Artificial Intelligence -AI) geniş ilgi uyandırmaktadır. Matematiksel modeller Wavelet dönüşümünü, zaman frekans yaklaşımlarını, Fourier dönüşümünü, Wigner-Ville Yayılımlarını (Wigner-Ville Distribution -WVD), istatistiksel ölçümleri ve yüksek sıralı istatistikleri (Higher-Order Statistical -HOS) içermektedir. Sinyal tanımlamadaki yapay zeka yaklaşımları ANN, DRNN ve bulanık mantık

sistemlerini kapsamaktadır. Genetik algoritmalar (GA) istenen el hareketlerini elde etmek için EMG girişlerini eşleştirmek amacıyla mikroçiplerde kullanılmaktadır[148].

Yüzey EMG sinyalinin algılanması ve yüzeyde var olan doğrusal olmayan durumların karakterize edilmesinde hala sınırlamalar bulunmaktadır (sEMG, kas sinyal çalışmalarında özel bir teknik)[149,150]. Geleneksel yeniden sistem tanımlama algoritmalarında sınırlamalar, sayısal zorluklar ve çeşitli değişkenler bulunmaktadır.

EMG sinyali, hastalık teşhislerinde tedavi edici özelliğinin yanında farklı dokularda yayılırken diğer biyolojik sinyaller için gürültü teşkil ederek zarar veren bir özelliği de bulunmaktadır. Örnek olarak kas gürültüsü (EMG), EKG sinyaline karışan ve bastırılması gereken en zor gürültüdür. Kas gürültüsü, kaslardaki aksiyon potansiyeli, EKG ve diğer sinyallere ait dalga formlarının çakışmasının bir sonucudur. EMG sinyalleri, genellikle Merkezi Limit Teorisi temel alınarak beyaz Gaussian gürültü ile modellenmektedir. Fakat kas gürültüsü çoğunlukla keskin ve dürtü şeklinde meydana geldiğinden Gaussian model yetersiz kalmaktadır. Ayrıca, Gaussian olmayan gürültülü durumlar Gaussian modellerle optimize edildiğinde performans düşmesi meydana gelmektedir. Son yıllarda, dürtü gürültülü sinyallerin tam bir modeli olarak α -sabitli dağılıma dayalı gürültü kabul edilmektedir. Bu sebeple kas gürültüsünü α -sabitli dağılım ile modellemek gerekmektedir.

2.7.EMG' nin Anatomik ve Fizyolojik Altyapısı

EMG, miyoelektrik aktivitesi olarak da tanımlanabilmektedir. Kas dokusu , sinirlerin yaptığına benzer şekilde elektrik potansiyeli üretir ve bu elektrik sinyallerine verilen kas hareket potansiyeli denir. Yüzeysel EMG , bu kas hareket potansiyelinin bir çeşit kayıt edilme metodudur. EMG sinyallerini belirlerken ve kaydederken, sinyalin gerçeğine uygunluğunu etkileyen iki şey vardır. İlki; sinyal - gürültü oranıdır yani, EMG sinyallerinin enerjisi ile gürültü sinyallerinin enerjisinin oranıdır. Genelde gürültü, istenilen EMG sinyalinin bir parçası olmayan elektrik sinyal olarak tanımlanır. İkincisi ise; sinyalin bozulmasıdır yani EMG sinyalindeki herhangi bir bileşenin değişmesi veya dejenere olmasıdır. Kas sinyalini elde etmek için invazif ve invazif olmayan iki çeşit elektrod kullanılır. EMG sinyali cilde doğrudan bağlanmış bir elektrottan elde edildiği zaman, sinyal cildin altındaki kaslarda oluşan bütün lif potansiyellerinin bir bileşimi

olur. Bu hareket potansiyelleri rastgele aralıklarla oluşur. Bu yüzden herhangi bir zamanda, EMG sinyali negatif ya da pozitif voltajda olabilir. Kas lif hareket potansiyelleri bazen kasa direkt yerleştirilen tel yada iğne elektrodları kullanarak elde edilebilir. MUAP; tek bir motor ünitesinin bütün kas liflerinden gelen potansiyel lif hareketlerinin bileşimidir ki bu cilt yüzeyindeki elektrod (invasif olmayan) 'la yada kasın içine yerleştirilen iğne elektrod (invasif olan)'la tespit edilebilir[151]. Denklem 1'de EMG sinyalinin basit bir modeli gösterilmektedir;

$$x(n) = \sum_{r=0}^{n-1} h(r)e(n-r) + w(n) \quad (1)$$

Burada $x(n)$; modellenen EMG sinyalinin, $e(n)$; atışleme dürtüsünü, $h(r)$; MUAP'ı, $w(n)$; beyaz Gaussian gürültüyü, N ; motor ünite sayısını ifade eder.


Sinir sistemi, vücudun hem kontrol hem de iletişim sistemidir. Bu sistem nöron denilen vücudun farklı bölgeleriyle elektrik sinyaller vasıtasıyla iletişim kurabilen çok sayıda uyarıcı hücreleri içermektedir. Nöronlar sinir sisteminin ana yapısal ünitesidir, boyut ve şekil olarak çeşitlilik gösterir.

Kas büzülebilen ve gevşeyebilen hücre topluluğudur. Bu hücrelerin öncelikli fonksiyonu güç, hareket ve konuşma yazma gibi ifade biçimleri üretmektir. Kas dokusunun açılabilme ve esneyebilme özelliği vardır. Uyarıcıları algılayabilir ve cevap verebilir ayrıca kısaltılabilir ya da büzülebilirler. Yapısal olarak, kasılabilme özelliği ve kontrol mekanizma farklılığına sahip üç çeşit kas dokusu vardır; (i) iskelet kasları, (ii) yumuşak kaslar ve (iii) kalp kaslarıdır. EMG iskelet kaslarının çalışmasını ilgilendirir. İskelet kas dokusu kemiğe tutturulmuştur ve büzülerek iskeleti hareket ettirir. İskelet kasının büzülmesi nöronların kası dürtmesiyle başlar ve genellikle istemli şekilde kontrol altındadır. İskelet kas liflerinin büzülmesi nöronlar tarafından sağlanır. Bu nöronlara 'motor nöron' adı verilir ve kas dokusuna yakındır, fakat kas dokusuyla direkt bağlı değildir. Bir motor nöronu genellikle birçok kas lifine dürtü sağlar.

İnsan vücudu bütün olarak nötrdür; eşit sayıda negatif ve pozitif yük vardır. Fakat istirahat aşamasında, plazma zarındaki odaklanma ve iyonik birleşimdeki farklılıklardan dolayı sinir hücre zarı kutuplaşır. Hücre-içi ve hücre dışı sıvı arasında potansiyel bir farklılık ortaya çıkar. Nörondan gelen dürtüye cevap olarak lifler sinyali yüzey boyunca

yayarak kutuplaşmayı ortadan kaldırır. İyonların hareketleriyle beraber ilerleyen kutuplaşmayı ortadan kaldırma işlemi , her bir kas lifinin yakınında bir elektrik alan üretmesini sağlar. EMG sinyal, nöron dürtüsüne cevap veren kası göstererek Hareket Potansiyeli Motor Ünitesinin (MUAP) bir donanımı haline gelir.

EMG sinyali gerçekte rastgele ve genellikle süzgeçlenmiş dürtü işlemi olarak modellenir ki burada süzgeç olarak MUAP süzgeç kullanılır[151]. Şekil 2.7’ de EMG sinyalinin elde edilme sürecini ve MUAP’lardaki ayrıştırmaı gösterir.



Şekil 2.7. EMG Sinyali ve MUAP’ı Ayrıştırma İşlemi.

2.8. EMG Analiz Yöntemleri


Son yıllarda hem kas içinden hem deri üzerinden alınan EMG sinyallerinin analizinde kullanılabilen bir çok metod geliştirildi. EMG sinyalleri ne periyodik ne de deterministik bir sinyaldir [152]. Başka bir deyişle ayrı ayrı zamanlarda, keyfi olarak seçilecek EMG sinyallerinin istatistiksel davranışı tam olarak aynı değildir. Belirli zaman aralıklarında EMG sinyalleri kendilerini tekrarlamazlar ve tek bir matematiksel ifade, kayıt süresinin tamamı boyunca elde edilen EMG sinyalini temsil edemez.

2.8.1. Wavelet Modeli

Wavelet analizi, bir sinyale ait zaman ve frekansla tanımlı bölgelerde yer alan bilgileri eşzamanlı olarak gösterdiği için sinyaldeki eğilimleri, çöküm noktalarını ve

süreksizlikleri belirlemek açısından diğer dönüşüm tekniklerine göre daha avantajlıdır. Fourier'in 1807'de ortogonal Fourier serilerini tanımlamasıyla başlayan süreç içerisinde yapılan çalışmalar, 1873'de Fourier serileriyle başka bir değere yakınsanamayan bir fonksiyonun bulunmasına yol açmıştır [153].

Gabor tarafından 1946 [154] yılında yayımlanan bir hipotezde, tek kutuplu bir sinyal tipik MUAP şekli Gaussain dağıtıcısının ikinci sıralı türevi olarak karşımıza çıkmaktadır. Mexican şapka waveleti ve tipik tek kutuplu MUAP şeklinin karşılaştırılması Şekil 2.8'de gösterilmiştir.



Şekil 2.8. Meksika Şapka Wavelet ve Tipik MUAP Şekli.


1998 yılında, Ismail ve Asfour [155], EMG' nin frekans spektrumunu belirlemedeki en yaygın metodların hızlı ve kısa zamanlı Fourier dönüşümünün (FFT ve SFT) olduğu teorisiyle karşımıza çıkarlar. Fakat, bu araştırmacılar aynı zamanda bu dönüşüm metodlarının en önemli dezavantajının bu sinyallerinin değişken olması olduğunu vurgulamışlardır.

1999 yılında, Pattichis [100] WT (Wavelet Transform)' nin her aşamasının katsayılarının orijinal sinyale fonksiyonel olarak nasıl yaklaştığını açıklamışlardır. Sürekli zamanlı bir sinyale ait $x_0, x_1, x_2, \dots$ gibi giriş örnekleri aşağıdaki ifade edilir;

$$f^0(t) = \sum_k x_k \phi(t - k) \quad (2)$$

Burada x_i ; ise giriş verilerini, $\phi(t - k)$; ölçeklendirme fonksiyonu, $f^0(t)$; sürekli zamanlı sinyal değerlerini ifade eder. Bu kabule dayanarak sinyal örnekleri sürekli zaman sinyallerinin ağırlıklı ortalamasıdır denilmektedir.

2003 yılında, Kumar, WT'nin Wavelet Fonksiyonu (WF) denilen önermesiyle karşımıza çıkmıştır. sEMG (Surface EMG) WF ile zaman domeninde iki boyutlu karşılıklı korelasyon alınarak hem açıklanır hem de dönüştürülür. Bu teknik, sinyalin zaman-frekans varyasyonu ile alakalı olan bir bilgi sağlar. Yapılan bütün bu araştırmaların sonucunda, EMG ve Wavelet dönüşümlerini kullanarak kas yorgunlukları belirlenebilir hale gelmiştir. Şekil 2.9'da deneysel Wavelet prosedürü göstermektedir.



Şekil 2.9. Deneysel Wavelet Prosedürü.

2.8.2.AR Modeli

AR zaman serileri modeli EMG sinyal çalışmalarında kullanılmıştır. Yüzeysel bir elektrod, kas içi EMG'sinin hassas olduğu durumlarda, EMG aktivitesini aktif kaslardan toplayabilir. Bu yüzden, uygunluğu ve doğruluğu kombine etmek için kas içi EMG'yi ölçmek ve bunların yüzeysel ölçümlerdeki spektral özelliklerini belirlemek için bir teknik geliştirmek ihtiyacı doğmuştur.

1975 yılında, Graupe ve Cline EMG sinyallerini ARMA modeli ile tanımlamışlardır. Graupe ve Cline'nin deneysel sonuçları EMG'nin kısa zaman aralıklarında değişken olarak düşünülebileceğini göstermiştir. Sherif 1980'de bu modeli yenilemiştir çünkü medikal deltoidin elektriksel davranışları değişken değildir. Sherif bilimsel incelemesinde EMG'nin değişken özelliği üzerinde durmuş ve AR'ı kullanarak ARIMA'yı bulmuştur. Bu sayede kas aktivitesinin farklı aşamaları esnasında EMG'nin değişken doğasını karakterize etmiştir.

Doerschuk 1983 yılında Graupe ve Cline'nin karşılaştığı benzer problemle; çoklu EMG sinyallerini AR modeli kullanılarak protez araçların kontrolünde karşılaştırmıştır. 1986 yılında, Zhou, ertelenmiş kas içi EMG sinyallerinin giriş olması ile birlikte yüzeysel

EMG' yi AR modeli olarak göstermiştir. Tanımlanan bu model ile yüzeysel sinyalden kas içi sinyalleri hesaplamak mümkün hale gelmiştir. Heffner 1988 yılında daha önceki modelleri değerlendirmiş ve EMG sinyal analizi için sayısal başarımından dolayı AR modelini seçmiş. 1992 yılında, Tohr ARMA ve ARIMA gibi daha kusursuz modellerde dinamik kas hareketlerinin daha başarılı analiz edilebildiği kanısına varmışlardır. ARIMA modelinin ölçüm maliyeti yüksektir ve model sırasının belirlenmesi karışık ve zor olabilmektedir. Tohr tarafından benzetimde problem olan ölçüm maliyetinden dolayı AR modeli seçmiştir. Araştırmaları AR model parametresine dayanır.

2.8.3. Yapay Zeka Modeli

Son yıllarda yapılan çalışmalarda doğrusal yada doğrusal olmayan sistemlerin modellenmesinde ve parametrelerinin belirlenmesinde yapay zekaya dayalı yöntemler önem taşımaktadır. Sistemlerin modellenmesinde, model yapısı ve istatistik değerlerin (model derecesi,giriş ve gürültünün dağılımı vb.) iyi bilinmesi halinde iyi çözümler sunar .Yapay sinir ağları (Artificial Neural Network-ANN)), model yapısının tam olarak bilinmesi zorunluluğu ortadan kaldırmaktadır .

Miyoelektrik sinyalleri (Myoelectric Signal-MSE) tanıyabilen yapay sinir ağların gerçek zamanlı uygulamaları 1994 yılında Del ve Park tarafından önerilmiştir. Errorback yayılma (Errorback Estimation) metodunun geliştirilmesiyle sistem ağ giriş ve çıkış setlerini haritalayabilmeyi öğrenmektedir.

Bir diğer yaklaşım 1996 yılında Cheron [156] tarafından yapılmıştır. Bu metod, kol kineomatikleri ile kas EMG aktivitesi arasındaki bağlantıyı ifade etmek için DRNN'lara dayanır.Araştırmacının amacı, bu DRNN ifadesinin biyomekanik olarak inandırıcı olduğunu kanıtlamaktır.

2001 yılında Belouchrani [157] tarafından önerilen Kör kaynak ayrımı (Blind Source Separation) metodu, öğrenme algoritmasında daha yüksek sıralı istatistiksel momentler kullanarak farklı sensörlerden alınan değişken olmayan bağımsız kaynakların doğrusal harmanlamasının ayrımını ifade eder. 2004 yılında Farina [158] farklı kaslar tarafından üretilen EMG sinyallerinin zaman-frekans domenlerinde çakıştığını keşfetmiştir. Bu

yüzden klasik doğrusal süzgeçleme yaklaşımları kaynak ayırımı amacına uygun olmadığını savunmuştur.

2.8.4.Yüksek Sıralı İstatistik Modeli

Yüksek sıralı istatistikler (High Order Statistic -HOS) rastgele süreçlerin doğasını ve özelliklerini analiz eden bir tekniktir. HOS'un konusu beklenti teorisine dayanır. Bunun sebebi şu sınırlamalardır;

- sEMG sinyallerinde mevcut olan doğrusal olmayışların tespiti ve özellikleri
- Aşamaları değerlendirme
- Normalizasyondan kaynaklanan kesin bilgi

Son zamanlarda, yüksek sıralı istatistik (HOS)'leri kullanmaya olan ilgi artmaktadır. 1991 yılında, Giannakis ve Tsatsasis [159] EMG sinyal analizleri için HOS kullanmışlardır. 1995 yılında, Yana [160] MUAP dalga formlarını ve bunların frekanslarını değerlendiren metodu genelleştirmiştir. Metod başlangıç MUAP dalga formlarının parametrik modelleriyle birlikte ikinci ve dördüncü sıralı momentlerini kullanmıştır. Düşük sıralı modeller ikinci sıralı istatistikler (Second Order Statistics - SOS) kullanılarak elde edilmiştir ve gerçek verilerin sınırlı tanımlamasını yapabilmıştır.

1987 yılından sonra HOS metodu, Nikias, Mendal, Raghuveer ve Petropulu gibi araştırmacılar tarafından geliştirilmiştir. 1990'larda, Nikias [161,162] SOS'e göre HOS'un başlıca avantajının ; parametre değerlendirmesi ve sınıflandırmadaki Gaussian gürültüleri bastırabilmesi olduğunu keşfetmiştir. 2000 yılında, Kaplanis [163] HOS kullanarak sEMG sinyal analizi teorilerini ortaya koymuştur.

3.BÖLÜM

SİSTEM MODELLEME

3.1. Sistem ve Model Tanımları

Gerçek hayat ile kendi iç yapısı arasındaki ilişkilendirmelerin yapıldığı yapılara sistem denir. Sistemin daha basit, genellikle matematiksel olarak hesaplanabilir yapıdaki gösterimine model adı verilir. Modelde herhangi bir olayı zaman ve mekan kısıtlaması yoktur. Fiziksel olayların modelini kurmak için gerçekte, bu olayları, bir takım matematiksel ifadelerle dönüştürmek gerekmektedir. Sistem modelleme, deneysel yolla elde edilmiş verilerden faydalanarak sistemlerin modelinin ortaya çıkarılmasıdır. Modellemenin temel gayesi bilinmeyen bir sistemin girişi ile çıkışı arasındaki ilişkiyi belirlemektir.

Şekil 3.1 'de bir dinamik sistemin temel yapısı gösterilmiştir. Sistem, $x(n)$ giriş işareti ve $w(n)$ bozucu işaretinden etkilenecek şekilde $y(n)$ çıkış işareti üretir.



Şekil 3.1. Dinamik Sistem Temel Yapısı.

Herhangi bir sistemin modelinin elde edilmesi işlemi, $x(n)$ ve $w(n)$ işaretlerinden faydalanılarak, $d(n)$ istenilen model çıkış işareti elde etmektir. x çıkış dizisinin n . Elemanı olan $x[n]$ in değerini bulmak için daha önceki değerleri kullanılırsa, bu doğrusal kestirim yöntemi olmaktadır. Eğer sistemlerde giriş işareti bilinmiyorsa, çıkış işareti kullanılarak modelleme yapılabilir. Kontrol edilecek sistemin matematik

modelinin bilinmesi zorunludur. Böylece sistemin modeli kullanılarak sistemin çıkışı, arzu edilen şekilde tasarlanabilir.

İşaret işlemenin bir çok uygulamasında kestirim, veri haberleşmesi, ses işaretleri işleme ve elektrokardiyogram analizi gibi ele alınan veriler bazı yollarla ve yüksek geçiren, alçak geçiren, rezonans frekansının durumu gibi işaretlerin özelliklerini yansıtabilen iyi tasarlanmış süzgeç yapıları ile süzgeçlenir. Spektral özelliklerinin belirlenmesi için işaretin modeline ihtiyaç duyulur .

3.2. Modelleme İşleminin Yöntemleri

Model oluşturmanın iki yolu vardır:

1. **Matematik Modelleme:** Analitik bir yaklaşımdır. Bir olayın veya bir işlemin davranışını tanımlamada örneğin Newton Kanunları gibi fiziğin temel kuralları temel alınır.
2. **Sistem Modelleme:** Deneye dayalı bir yaklaşımdır. Sisteme birçok deney uygulanır, sonrasında model, kaydedilen verilerle parametreler yardımıyla uygunlaştırılır.

Bu iki model oluşturma metodu karşılaştırılacak olursa, sadece fiziksel kavramlar kullanılarak uygun model elde etmenin mümkün olmadığı birçok durumda bu işlemler çok karmaşıktır. Bazı durumlarda, matematik modellemenin modelleme amaçlı kullanımı zordur. Bir çok model yapısı, fiziksel kanunlardan elde edilmiş dahi olsa, bilinmeyen birçok parametre değerine bağlıdır. Modelleme de amaç, bilinmeyen parametreleri tahmin etme uygulamasıdır. Sistem modelleme ile elde edilen modeller, matematik modellemeden farklı olarak aşağıda sıralanan özelliklere sahiptir;

- Sistem modelleme metodu matematik modellemeye göre daha kolay uygulanır ve daha kolay kullanılır.
- Sistem modelleme metodunda çok küçük fiziksel kavramları ifade ederler, çünkü bir çok durumda model parametreleri fiziksel bir anlam ifade etmemektedir. Parametreler, sistemin davranışını iyi bir şekilde tanımlamak için bir araç olarak kullanılır.

Modelleme, modelleme yapan kişi tarafından çok fazla etkilenmektedir. Bunun modelleme yapısına etkileri aşağıda sıralanmıştır;

- a) Modelleme yapılırken, uygun bir model yapısı bulunmak zorundadır. Eğer sistem dinamikleri doğrusal olmayan yapıda ise bu durum oldukça zorlaşır.
- b) Gerçek hayattaki veriler kesinlikle mükemmel değildir. Gürültü tarafından bozulan veriler dikkate alınmak zorundadır.
- c) İşlemler zamanla değişmektedir. Bunun sonucu olarak da, modelleri zamanla değişmeyen yapıda tanımlamak gerekmektedir.
- d) Modelin karakteristiğini ihtiva eden bazı işaretleri/değişkenleri ölçmek zor hatta imkansızdır [164].

3.3. Model Çeşitleri

Literatürde bir çok model çeşitleri mevcuttur. Dinamik ve Statik model bunlara örnek olarak verilebilir. Zaman, dinamik modellerin temel elemanıdır. Dinamik modellerde, statik olanların aksine, zaman, modelin temel elemanı olarak tanımlanır. Bir dinamik model, belli bir zamandaki sistemin durumu, bu andaki sistemi etkileyen dış faktörleri ve bir sonraki duruma ulaşmak için geçiş ilişkilerini içerir.

Tanımlayıcı modeller, sistemin çalışmasını, sistemin temel prensipleri kullanarak ortaya çıkarma amacıyla kullanılırlar.

Açıklayıcı modeller, sistemin iç yapısının tanımlanması yerine, sistemin karakteristiğini elde etmek için kullanılırlar.

Model parametreleri, modelin çalışması esnasında sabit kabul edilen matematik yapıda kullanılan sayılardır. Model verisi ise modelin durum değiştirmesini sağlayan giriş zaman serileridir. Bu veriler belli çalışma şartlarında modelin davranışını belirlemede kullanılırlar [165-167].

3.4. Modellerin Sınıflandırılması

Giriş-çıkış durumuna göre;

- a) SISO (Single Input Single Output): Tek girişi ve tek çıkışı olan modellerdir.
- b) MISO (Multi Input Single Output): Çok girişi tek çıkışı olan modellerdir.

Zamana göre;

- a) Zamana bağlı modeller: Sistem zamanla değişiyorsa bu tip sistemlere zamana bağlı modeller denir.

b) Zamandan bağımsız modeller: Sistemin iç yapısı ve karakteristiği zamana göre değişmiyorsa bu tip modeller zamandan bağımsız olarak kullanılır.

Domene göre;

a) Zaman domeni: Diferansiyel veya fark denklemleri ile sistemlerin modellenmesinde kullanılır.

b) Frekans domeni: Spektral yoğunluk veya Bode eğrisi gibi sistemin karakteristiğini frekans domeninde belirleyen modellerdir.

Doğrusallık durumuna göre;

a) Doğrusal modeller: Sistemin giriş-çıkış ilişkisinin doğrusal eşitliklerle ifade edildiği modellerdir.

b) Doğrusal olmayan modeller: Sistemin giriş-çıkış ilişkisi, diferansiyel denklemler, üstel ve logaritmik fonksiyonlar gibi doğrusal olmayan matematiksel eşitliklerle ifade edildiği modellerdir.

Bozucu etkilere göre;

a) Deterministik modeller: Deterministik modellerde giriş bilinirse çıkış tam olarak hesaplanabilir.

b) Stokastik modeller: Sistemlerde dış etkenlerin sonucunda oluşan rastgele terimlerin yer aldığı modellerdir [167]

3.5. Sistem Modellemenin Temel Basamakları

Aşağıda genel olarak bir sistemin modellemesinin temel basamakları verilmektedir;

a. Sistemin girişine herhangi bir işaret (darbe, basamak, sinüs veya rasgele işaretler) uygulanıp, sistemin bu işarete cevabı çıkış işareti olarak kaydedilir.

b. Sisteme uygun bir model yapısı tespit edilir. Bu model yapısı doğrusal olabileceği gibi, çoğu fiziksel sistemin davranışını gösteren doğrusal olmayan model yapısı da kullanılabilir.

c. Elde edilen modelin parametreleri, bazı istatistiki veya tahmini yöntemlerle belirlenir. Modelleme işleminin en önemli aşaması, bu parametrelerin doğru şekilde belirlenmesidir.

d. Parametreleri belirlenen modelin girişine, sisteme uygulanmış olan giriş işareti uygulanıp, modelden alınan çıkış işareti ile sistemin gerçek çıkışı arasındaki fark bulunur. Eğer fark büyükse, başka bir model yapısı veya yeni bir parametre tespit

yöntemi belirlenmesi için b. basamaktaki işleme geri dönülür. Eğer fark çok küçükse bu model sistemi tanımlamak ve kontrol etmek için kullanılabilir .


3.6. Adaptif Sistemler

Adaptif sistemler değişen şartlara göre kendini en iyiye doğru kanalize eden sistemlerdir. Bu sistemler işaret işleme sahasında daha fazla kullanılmaktadır [168-170]. Adaptif sistemlerin en önemli özelliği zamanla değişen sistemlere rahatlıkla uygulanabilmesi ve yeni durumlara göre kendi kendini ayarlayabilmesidir. Doğrusal sistemlerde karşılaşılan, sadece belirli girişlere karşı çıkışın istenen şekilde olması, diğer tür girişlerin uygulandığı durumlarda veya kontrol edilen sistemin zamanla, çevre şartlarından etkilenecek özelliklerinin değişmesi durumunda sistemin kararsız davranması durumu adaptif sistemlerde daha az gözlenmektedir.

Adaptif sistemlerin ortak özellikleri aşağıda sıralanmıştır;

- Çevre şartlarının ve sistemden istenilen özelliklerin değişmesiyle, sistem kendi kendisini otomatik olarak ayarlayabilir.
- Genellikle zamanla değişen sistemler olarak tanımlanır.
- Çoğu zaman karmaşık bir yapıya sahiptirler ve analiz edilmeleri adaptif olmayan sistemlere göre daha zordur. Fakat giriş işaretinin özellikleri bilinmediği veya zamanla değiştiği durumlarda yüksek performans elde edilmektedir.

Adaptif sistemlerdeki temel yaklaşım, modellenen sistem parametrelerinin elde edilmesi aşamasında, her bir iterasyon sonucunda oluşan hata değerinin minimize edilmesi için sistem parametrelerini belirli bir şekilde değiştirmektir. Hata değerinin minimuma indirilmesi için genellikle sistemin amaç fonksiyonunun (hatayı veren fonksiyonun) türevi kullanılır. Bu türev değerini her iterasyonda sıfır yapan parametre değerleri adaptif olarak bulunur. Sistemin çıkışının arzu edilen şekilde olması için gereken adaptif kontrol sistemi tasarımı Şekil 3.2’de gösterilmiştir.



Şekil 3.2. Adaptif Sistem Model Yapısı.

Adaptif modelleme, sistem parametrelerini, hatayı sıfır yapacak şekilde ayarlamak için kullanılır [164-167].

3.7. Doğrusal Sistem Modelleme

Doğrusal sistem modellemede AR , MA ve ARMA modelleri gibi klasik yöntemler kullanılmaktadır.

3.7.1. AR Modelleme

Bir çok ayrık zamanlı sistemlerde, veri olarak yalnızca çıkış değerlerinin yardımıyla sistemin modellenmesi gerekir. Bu tür sistemler özbağımlı olarak modellenebilir. Sadece kutuplara sahip olan AR modeli;

$$y(n) = -a_1y(n-1) - a_2y(n-2) - \dots - a_py(n-p) + e(n) = -\sum_{k=1}^p a_k y(n-k) + e[n] \quad (3)$$

şeklindedir. Denklem 3’de $y(n)$ çıkış dizisini, $e(n)$ gürültü dizisini, $a(k)$ ise AR parametrelerini belirtmektedir. AR modellerde, sistem parametrelerinin ayarlanması, sistemden elde edilen çıkış işaretinin eski değerlerini, bazı katsayılarla çarparak çıkışın istenilen özellikte olması işlemidir [171].

3.7.2. MA Modelleme

MA model yapısı kullanılarak yapılan modellemede veri olarak yalnızca giriş işaretleri değerleri kullanılır. Sadece sıfırlara sahip olan bu yapı denklem 4'deki;

$$y(n) = b_0 x(n) + b_1 x(n-1) + \dots + b_q x(n-q) + e(n) = \sum_{k=1}^q b_k x(n-k) + e[n] \quad (4)$$

şekildedir. Burada $y(n)$ çıkış dizisini, $x(n)$ giriş dizisini ve b_k ise MA parametrelerini belirtir. MA modellerde, sistem parametrelerinin ayarlanması, sisteme uygulanan giriş işaretinin o andaki ve geçmiş değerlerini bazı katsayılarla çarparak çıkışın istenilen özellikte olması işlemidir.

3.7.3. ARMA Modelleme

AR model yapısı sadece kutuplara sahip olan sistemlerin matematik modelinin oluşturulmasında, MA model yapısı ise sadece sıfırlara sahip olan sistemlerin matematik modelini oluşturmakta kullanılmaktadır. Çoğu fiziksel sistemin hem kutuplara hem de sıfırlara sahip olduğu gerçeği göz önüne alınırsa bu tekniklerin yeterli olamayacağı açıktır. Bu yüzden kutup ve sıfırlara sahip sistemlerin matematik modellenmesi için ARMA modelleme yöntemleri geliştirilmiştir. Genel olarak bu modellerde, giriş dizişi $x(n)$ ile, çıkış dizişi ise $y(n)$ ile ifade edilir. Bu diziler arasında:

$$y(n) = -\sum_{k=1}^p a_k y(n-k) + \sum_{k=1}^q b_k x(n-k) \quad (5)$$

Şeklinde doğrusal fark denklemi yazılabilir, p , AR model derecesini, q ise MA model derecesini belirtmektedir[171].

3.8. Sistem Modelleme İçin Kullanılan Yöntem

Sistemlerin modellenmesi için kullanılan en klasik algoritma LMS(Least Mean Square) yöntemidir [166]. En küçük kareler yöntemi kontrol, iletişim ve jeofizik işaret işleme gibi farklı uygulamalarda yaygın olarak kullanılır. Özyineli(recursive) ve adaptif süzgeçleme yeni deneysel kanıtların var olduğu, bilinmeyen süzgeç modelleri hakkında her zaman daha çok bilgi veren özel bir tasarımı kullanır[167,168].

3.8.1. LMS Algoritması

Sistem tanımlama algoritmaları; sistem dinamikleri hakkında yeterli bilgiyi veren bilinmeyen bir işletme modelinin, bir dizi parametrelerinin tahmini ile ilgilenir. Doğrusal sistem parametreleme; uygulamaların geniş bir alanıyla sistem modellemenin önemli bir sınıfıdır. Doğrusal model sınıfları arasında en yaygını FIR (Finite Impuls Response-Sonlu Darbe Cevaplı) yapılı olanıdır. Bu sınıflama ya fiziksel sistem modellemedeki esastır yada kestirimi işi basitleştirmek için kabul edilir ve gerçek zaman uygulamalarında hesaplama yükünü azaltmak için kullanılır. Statik ve dinamik FIR modellerinin her ikisi de geçmişi göz önünde bulundurur ve algoritmaların büyük bir çoğunluğu model parametrelerinde verimlilik kestirimi için önerilmiştir [171]. LMS yönteminde parametreler her iterasyonda hatayı en aza indirecek şekilde değişmektedir.

$$A_{k+1} = A_k + M_k + \phi_k e_k$$

şeklindeki ifade edilir. Burada;

A_k : k zamanındaki tahmini parametre vektörü

M_k : algoritma kazancı

ϕ_k : çıkışın önceki değerleri

e_k : modelleme hatası

olarak adlandırılır.

3.8.2. RMS Algoritması

Bu yöntemde, adaptif kazanç , kovaryans matrisi, P yardımıyla her iterasyon için ayarlanır ve aşağıdaki şekilde ifade edilir;

$$A_{k+1} = A_k + \frac{P_{k-1} \phi_k}{1 + \phi_k^T P_{k-1} \phi_k} \left[(t) \phi_k^T A_k \right] \quad (6)$$

Burada P_k ve $P(0)$ değerleri,

$$P_k = P_{k-1} - \frac{P_{k-1} \phi_k \phi_k^T P_{k-1}}{I + \phi_k^T P_{k-1} \phi_k} \quad (7)$$

$$P(0) = I$$

dir. Burada I birim matrisidir. Çoğunlukla RLS yöntemi LMS yöntemine göre daha hızlı yakınsar. Fakat başlangıç değerleri ve yuvarlatma hataları açısından LMS den daha hassastır[172].

3.9. FIR Modeli

Sistem modellemedeki esas kabul edilen FIR kestirimi daha kolay ifade edebilmek ve gerçek zaman uygulamalarında hesaplama yükünü azaltmak için kullanılır. FIR modellerinin her ikisi de geçmiş göz önünde bulundurur ve algoritmaların büyük bir çoğunluğu model parametrelerinde verimlilik kestirimi için önerilmiştir

FIR süzgeçlerin IIR süzgece göre birtakım avantajları vardır:

1. Her zaman kararlıdır,
2. Her zaman gerçekleştirilebilir,
3. Kesin-Doğrusal faz elde edilmek için her zaman kullanılabilir.

Üçüncü avantaj FIR süzgeci, gecikme gürültüsüz, fakat sabit gecikmeli uygulamalarda vazgeçilmez kılar. FIR süzgeç modeli;

$$y(n) = \sum_{j=1}^n h_j x(k-j) + e(k) = h^T x(k) + e(k) \quad (8)$$

şeklinde ifade edilir ve $e(k)$ çıkışa ilave edilen gürültü, $y(n)$ çıkışı,

$$h = [h_1 h_2 \dots h_n]^T \quad (9)$$

FIR merkez değerleri,

$$x(k) = [x(k-1), x(k-2), \dots, x(k-n)]^T \quad (10)$$

giriş vektörünü ifade eder. Bu özelliklerinden yararlanarak FIR modelin aynı MA model gibi giriş değerlerini kullandığı görülmektedir[173].

3.10. Kas Sinyalinin Modellenmesi

Gerçek hayatta Gaussian model ile tanımlanamayacak sinyallere ve gürültülere sıkça rastlanır. Bunlara örnek olarak; endüstriyel mühendislik alanında geçici güç kesilmeleri ve telefon hatlarındaki rastlantısal kesilmeler, biyomedikal alanda ise EKG sinyaline karışan kas gürültüsü verilebilir.

EMG sinyalleri, genellikle Merkezi Limit Teorisi temel alınarak beyaz Gaussian gürültü ile modellenmektedir. Ancak kas gürültüsü çoğu zaman dürtü şeklinde meydana geldiğinden Gaussian model yetersiz kalmaktadır. Ayrıca, Gaussian olmayan gürültülü durumlar Gaussian modellerle optimize edildiğinde performans düşmesi meydana


gelmektedir. Son yıllarda, dürtü gürültülü sinyallerin tam bir modeli olarak α -bağımlı dağılıma dayalı gürültü kabul edilmektedir. Bu sebeple kas gürültüsünü α -bağımlı dağılım ile modellemek gerekmektedir.

3.10.1. α -Bağımlı Gürültü

Son yıllarda, dürtü gürültüsünü giderme işlemlerinde, uygun bir model olarak gösterilen α -bağımlı yayılım temelli sinyal işleme yöntemleri üzerinde kayda değer bir ilgi vardır. İstatistiksel bir model olarak α bağımlı yayılımın kullanımı iki özelliğinden dolayı teorikte doğrulanmaktadır. Bunların ilki, sabitlik özelliğidir; böylece iki bağımsız aynı katsayıya sahip sabit rastgele değişkenin toplamının aynı karakteristik katsayıyla sabitlenmesi sağlanabilmektedir. İkincisi ise, genelleştirilmiş merkezi limit teoremidir; eğer sonsuz sayıdaki bağımsız ve aynı şekilde dağıtılmış rastgele değişkenler yayılımda bir araya gelirse, sınırlandırılmış olan yayılım α -bağımlı olmaktadır. Bu yüzden, α -bağımlı rasgele değişkenler Gaussian değişkenlerde olduğu gibi çok sayıda bağımsız yardımcı faktörün etkisi olarak fiziksel ortamlarda ortaya çıkabilmektedir . α -bağımlı yayılımın karakteristik fonksiyon denklem 11’de verilmektedir.

$$\varphi(t) = \exp(j\mu t - \gamma|t|^\alpha) \quad (11)$$

Burada α , ($0 < \alpha < 2$) yayılımın en önemli parametresi olan karakteristik katsayısıdır çünkü α yayılım kanallarının ağırlığını kontrol etmektedir. Sabit rastgele bir değer gözlemlendiğinde α değeri büyüdükçe, merkezden uzak olan rastlantısal değerleri gözlemleme ihtimalide o oranda azalmaktadır. Ayrıca ($0 < \alpha < 2$) için, α bağımlı rastgele değişkenlerin sonsuz değişeni bulunmaktadır. Şekil.3.3 ‘de gösterildiği gibi $\alpha=1$ olduğu durumlarda Cauchy dağılım özelliği gözlemlenirken , $\alpha=2$ durumunda ise Gaussian dağılım gözlemlenmektedir [1].



Şekil 3.3. α -Bağımlı Yayılımın Grafiği.

Denklemdaki, μ gerçek değerli lokasyon parametresi, γ yayılım dispersiyonudur ($\gamma > 0$, lokasyon parametresine ait yoğunluğun yayılımını belirler).

3.11. Doğrusal Olmayan Sistem Modelleme

Gerçek hayatta karşılaşılan birçok sistem doğrusal olmayan davranışlara sahiptir. Bu tür sistemlerin kimliklendirilmesinde doğrusal modelleme yöntemleri yetersiz kalmakta ve doğrusal olmayan modelleme yöntemlerinin kullanılması gerekmektedir [20-21]. Doğrusal olmayan modellemede, sistemin giriş-çıkış ilişkisi, diferansiyel denklemler, üstel ve logaritmik fonksiyonlar gibi doğrusal olmayan matematiksel ifadelerle sağlanır.

Biyomedikal sahada EMG gibi ani değişen sinyallere uygulanabilen güçlü doğrusal olmayan süzgeçler için esnek bir teori ihtiyacı, biyolojik görüntü işleme sahalarında da ortaya çıkmıştır. Önemli araştırma çabaları, özellikle görüntü işleme alanlarında, ani gürültülere karşı güçlü ve dirençli olan doğrusal süzgeçlere uygun alternatifler bulmaya odaklanmıştır[44]. Bunların arasında, ağırlıklandırılmış Myriad ve Median süzgeç yaklaşımları son yıllarda, α -bağımlı gürültü ortamları için güçlü süzgeç yapıları olarak kullanılmaktadır. Bu süzgeç yapıları haberleşme, işaret ve görüntü işleme alanlarına başarıyla uygulanmıştır [75].

Günümüzde Median süzgeç yapıları, ticari ürünlerin görüntü işleme uygulamalarında kullanılması gün geçtikçe artmaktadır. Bunların başka alanlarda kullanılmasını engelleyen en önemli eksiklik, çıkışların giriş penceresindeki örneklemelerden biriyle sınırlandırılmış olmasıdır. Bu seçici özellik görüntü işleme alanlarında arzu edilen bir özellik olmasına rağmen, diğer bir çok pratik uygulama sahalarında kabul edilemeyecek kayıplara neden olmaktadır. Örneğin; Median, Gaussian çevrelerde lokasyon değerlendiricisi olarak kullanıldığında, ortalama örnekleme %40'a yakın kayıplar verdiği bilinmektedir.

Median temelli metodların pratik problemlerde kullanılamaması gerçek hayattaki gürültü işlemlere olan uygunsuzluğu sebebinden kaynaklandığı tartışılabilmektedir. Pratikte görülen birçok gürültü çan tipindeki yoğunluk fonksiyonlarına benzetilirken, Laplacian model, bunu genellikle daha suni yapan sivri bir yoğunluğa benzetir[44].

Doğrusal süzgeçler kullanıldığında hem gürültü hem de EKG' nin yüksek frekans bileşenleri atılmış olduğundan EKG' nin bulanıklaşmasına neden olmaktadır. Bu özelliklerinden dolayı Median model, sinyal işleme alanında pek kullanılmamıştır. Bu eksiklik Myriad süzgeç ile giderilmeye çalışılmıştır. Yukarıda verilen sınırlamalar doğrultusunda, Myriad süzgeç ailesi, çan şeklindeki dürtü yayılımları için yüksek istatistik yararı sağlayan süzgeçlemeler olarak önerilmiştir ki bu giderek daha da popüler olan α -bağımlı gibi doğal olayların pratikteki sonucu olarak görülebilmektedir.

Bu çalışmada, EKG sinyaline doğal olarak bozucu etkide bulunan kas gürültüsü (EMG) ile α -bağımlı yayılım ile modellenen yapay EMG işareti, doğrusal olmayan ağırlıklandırılmış Myriad ve Median süzgeçler ile doğrusal FIR süzgeç kullanılarak bastırılmış ve başarımları karşılaştırılmıştır. Süzgeç performanlarını artırmak için birçok adaptif öğrenme algoritması denenmiştir.

3.11.1. Ağırlıklandırılmış Myriad Süzgeç

İstatistiksel işaret işleme teorisi, işlemlerin temelini karakterize etmek için Gaussian model varsayımını kabul etmektedir. Gaussian varsayımı, bir çok fiziksel öngörü için mantıklı bir model olduğundan bu kabul Merkezi Limit teoremi kullanarak doğrulanmıştır. Dahası, bu model altındaki optimal süzgeçler doğrusal olduğundan

analitik olarak işlenebilmektedir. Fakat yinede Gaussian model ile çok iyi tanımlanamayan birçok sinyal mevcuttur. Örneğin; doğadaki gürültülerin birçoğu dürtü şeklinde meydana gelmektedir[91].

Myriad süzgeç yapısı son yıllarda, dürtü gürültülü ortamlar (özellikle α -bağımlı gürültü) için güçlü bir doğrusal olmayan süzgeç yapısı olarak kullanılmaktadır. Bu süzgeç yapısı haberleşme, işaret ve görüntü işleme alanlarına başarıyla uygulanmıştır. Bunun sebebi ise kenar koruma ve aykırı değeri reddetme özelliklerine sahip olmasıdır.

Ağırlıklandırılmış Myriad süzgeç (Weighted Myriad Filter –WMyF), α bağımlı yayılımların özel bir durumu olan Cauchy yayılımlara dayanmaktadır. Bu ağır kuyruklu yayılımlar Genelleştirilmiş Merkezi Limit teoremine dayandırılmış ve bu yayılımların dürtü gürültü işlemlerine uygunluğu da kanıtlanmıştır[174,175]. α -bağımlı yayılımlar $0 < \alpha < 2$ oranıyla sınırlandırılmış bir katsayıya sahiptir; daha küçük bir α daha ağır kuyruklu bir yayılım demektir. $\alpha=1$ ve $\alpha=2$ katsayı değerleri sırasıyla Cauchy ve Gaussian yayılımları doğurur. Aslında; bunlar kapalı formulu açıklamalar olduğunda sadece simetrik α -bağımlı yayılımları ifade eder. α bağımlı gürültü $\Phi(\omega) \propto e^{-\gamma|\omega|^\alpha}$ şeklinde bir karakteristik fonksiyona sahiptir ve buradaki γ dispersiyon parametresi ve α karakteristik değişkenini ifade eder[76].

3.11.1.1. Temel Myriad

Temel Mean ve Median yayılımları maksimum benzerlik (Maximum Likelihood -ML) yaklaşımından türetilmiştir. Özellikle temel Mean , Gaussian yayılımının bir sonucu iken temel Median ise Laplacian yayılımının sonucu olarak ortaya çıkmıştır. Median' a ait geri bildirimlerden biriside şudur ; fiziksel olgular için Laplacian yayılımın iyi bir model olmadığıdır. Fakat Cauchy yayılım, Gaussian ve Laplacian'a göre daha ağır kuyruklara sahiptir ve pratikte oluşan ani gürültülü durumları incelemede daha iyi bir model olarak kabul edilmektedir[174]. Temel Myriad, Cauchy yayılım lokasyonunun ML yaklaşımı olarak tanımlanır. $[x_1, x_2, \dots, x_N]$ şeklinde bir veri dizisi içeren ,doğrusallık faktörü K olan Cauchy yayılım şu şekilde ifade edilir :

$$f(x, \beta) = \left(\frac{K}{\pi} \right) \frac{1}{K^2 + \left(x - \beta \right)^2} \quad (12)$$

Burada β ; yayılımın lokasyon parametresidir. $\hat{\beta}_K$ değeri likeli-hood fonksiyonu ile maksimize edilir:

$$L(x_1, x_2, \dots, x_N; \beta) = \prod_{i=1}^N f(x_i, \beta) \quad (13)$$

Bu eşitlik, $K > 0$ durumu varsayılarak minimize edilir ;

$$G_K(\beta) = \prod_{i=1}^N [K^2 + \epsilon_i - \beta^2] \quad (14)$$

Genel olarak temel Myriad ;

$$\hat{\beta}_K(x_1, x_2, \dots, x_N) = \arg \min_{\beta} G_K(\beta) \quad (15)$$

$$\hat{\beta}_K = \text{myriad}(K; x_1, x_2, \dots, x_N) = \arg \min_{\beta} \prod_{i=1}^N [K^2 + \epsilon_i - \beta^2] = \arg \min_{\beta} \sum_{i=1}^N \log [K^2 + \epsilon_i - \beta^2] \quad (16)$$

şeklinde bir amaç (cost) fonksiyonuna sahiptir[91]. Oluşacak olan myriad değeri, fonksiyonu minimum yapan β değeridir. Burada N , süzgeç uzunluğu, x_i giriş verilerinden alınan örnek veri değerleri, K ise doğrusallık faktörüdür. Burada K önemli bir faktördür, örneğin $\{3, 10, 1, -1, 6\}$ şeklindeki bir veri setinin $K=20, 2$ ve 0.2 değerleri için oluşacak myriad değerleri $\beta_{20} = 1.8$, $\beta_2 = 0.1$ ve $\beta_{0.2} = 1$ olmaktadır. İlginç bir gerçekte, K arttıkça, veriler daha kesin hale gelmektedir.

3.11.1.2. Ağırlıklandırılmış Myriad

Ağırlıklandırılmış Myriad süzgeç yapısı, bir önceki kısımda bahsedilen Myriad süzgeç yapısında yer alan giriş örneklerinin pozitif ağırlıklandırılması ile daha genel hale getirilmiş halidir. Bir dizi gözlem $\{x_i\}_{i=1}^N$ ve bir dizi süzgeç ağırlığı $\{w_i\}_{i=1}^N$ düşünelim. Gözlem vektörünü şu şekilde tanımlanır[91]; $x = [x_1, x_2, \dots, x_N]^T$, ağırlık vektörü ise ; $w = [w_1, w_2, \dots, w_N]^T$ şeklinde tanımlanır. Daha sonra $K > 0$ kabul edilerek, ağırlıklandırılmış Myriad süzgeç çıkışı şu şekilde ifade edilir;

$$\hat{\beta}_K(w, x) = \text{myriad}(K; w_1 o x_1, w_2 o x_2, \dots, w_N o x_N) = \arg \min_{\beta} G_K(\beta, w, x) \quad (17)$$

Burada


$$G_K(\beta, w, x) = \prod_{i=1}^N [K^2 + \epsilon_i - \beta^2] \quad (18)$$

Burada $(w_i \circ x_i)$ ağırlıklandırma konvolusyon işlemini belirtmektedir. İçerik açık olduğu zaman, $\hat{\beta}_K(w, x)$, $\hat{\beta}_K$ ya da sadece $\hat{\beta}$ olarak yazılmaktadır. Aynı şekilde, $G_K(\beta, w, x)$, $G_K(\beta)$ olarak ya da $G(\beta)$ olarak yazılmaktadır. ML lokasyon yaklaşımın, ağırlıklandırılmış Myriad süzgeçlere ait formülde ağırlıkları negatif olmayan sınırlaması ile kısıtladığını belirtmek gerekir. Fakat ağırlıklandırılmış Myriad süzgeç (17) ve (18)'daki ifadeleri kullanarak negatif ağırlıklarla birlikte tanımlanabilmektedir. Fakat böyle bir durum süzgeçlerin potansiyel sabitsizliği şeklinde sonuçlanabilmektedir[91].

Genel olarak ağırlıklandırılmış Myriad süzgeç;

$$\beta_K = \text{myriad}(K; w_1 \circ x_1, w_2 \circ x_2, \dots, w_N \circ x_N) = \arg \min \sum_{i=1}^N \log [K^2 + w_i (\epsilon_i - \beta^2)] \quad (19)$$

şeklinde bir amaç fonksiyonuna sahiptir ve Şekil 3.4'de tipik Myriad fonksiyonu gösterilmektedir. Ağırlıklandırılmış Myriad süzgeç yapısı daha çok adaptif yapıda kullanılır [74]. Yani ağırlık değerlerinin bulunabilmesi için adaptasyon algoritmalarına ihtiyaç duyar.



Şekil 3.4. Tipik Myriad Fonksiyon.

3.11.1.3. Adaptif Ağırlıklandırılmış Myriad Süzgeç Algoritması

Burada benzetim çalışmalarında kullanılan ağırlıklandırılmış Myriad süzgeç (WMyF) yapısı için [75] no'lu referanstaki Kalluri ve Arce tarafından geliştirilmiş olan adaptif algoritmalarından bahsedilecektir. Süzgeç parametrelerinin optimizasyonu için daha önceki bölümde de bahsedildiği gibi sistem çıkışı ile istenilen çıkış arasındaki farkın

minimize edilmesi gerekmektedir. Giriş örnekleri $x=[x_1, x_2, \dots, x_N]^T$, ağırlık vektörü $w=[w_1, w_2, \dots, w_N]^T$ ve doğrusallık faktörü K ile birlikte WMyF yapısının çıkışı $y=y_K(w,x)$ olarak gösterilmektedir. İstenilen çıkış ile süzgeç çıkışı arasındaki hata $e=y-d$ şeklindedir. Hata optimizasyonu için ortalama mutlak hata (Mean Absolute Error - MAE) ve MSE (Mean Square Error) kriterleri kullanılabilir. MAE kriteri göz önüne alındığında $J_1(w,K)=E\{|e|\}=E\{|y_K(w,x)-d|\}$ ve MSE kriteri göz önüne alındığında $J_2(w,K)=E\{e^2\}=E\{|y_K(w,x)-d|^2\}$ şeklinde olur. Parametre optimizasyonu için bu hata fonksiyonlarının çıkışın ağırlığa göre türevi alınmalıdır. Bu durumda

$$\frac{dJ_1(w,K)}{dw_i} = \frac{d}{dw_i} E\{|y_K(w,x)-d|\} = E\left\{\text{sgn}(y-d) \frac{dy}{dw_i}\right\} \quad (20)$$

ve

$$\frac{dJ_2(w,K)}{dw_i} = 2E\left\{(y-d) \frac{dy}{dw_i}\right\} \quad (21)$$

şeklinde elde edilir.

Optimal süzgeç parametrelerinin bulunabilmesi için literatürde sıkça kullanılan en dik iniş (*steepest descent*) metodu [80]

$$w_i(n+1) = w_i(n) - \mu \frac{dJ}{dw_i}(n) \quad (22)$$

şeklindedir. Burada $dJ_1(w,K)/dw_i$ kullanılırsa

$$w_i(n+1) = w_i(n) - \mu \frac{dJ_1}{dw_i}(n) = P\{w_i(n) - \mu \text{sgn}[e(n)] \frac{dy}{dw_i}(n)\} \quad (23)$$

bulunur, burada

$$P[u] = \begin{cases} u, & u > 0 \\ 0, & u \leq 0 \end{cases} \quad (24)$$

şeklindedir. Denklem (23)'de görüldüğü gibi dy/dw_i (ağırlıklandırılmış myriad süzgeç çıkışının parametre değerine göre türevi) değerine ihtiyaç duyulmaktadır. Bu durumda

$$\frac{dy}{dw_i} = \frac{\left\{ \frac{-(y-x_i)}{\left[1 + \frac{w_i}{K^2}(y-x_i)^2\right]^2} \right\}}{K^2 \cdot \left\{ \sum_{j=1}^N \frac{w_j}{K^2} \cdot \frac{1 - \frac{w_j}{K^2}(y-x_j)^2}{\left[1 + \frac{w_j}{K^2}(y-x_j)^2\right]^2} \right\}} \quad (25)$$

şeklinde elde edilir. Böylelikle

$$w_i(n+1) = P \left[w_i(n) + \mu \operatorname{sgn}[e(n)] \frac{\left\{ \frac{(y-x_i)}{\left[1 + \frac{w_i}{K^2}(y-x_i)^2\right]^2} \right\}(n)}{K^2 \cdot \left\{ a + \sum_{j=1}^N \frac{w_j}{K^2} \cdot \frac{1 - \frac{w_j}{K^2}(y-x_j)^2}{\left[1 + \frac{w_j}{K^2}(y-x_j)^2\right]^2} \right\}(n)} \right] \quad (26)$$

olur. Burada a katsayısı kararlılık katsayısıdır. Algoritmanın payda kısmında bulunan fonksiyon çok küçük değerlerde olacağından, algoritma daha sade şekliyle

$$w_i(n+1) = P \left[w_i(n) + \mu \operatorname{sgn}[e(n)] \left\{ \frac{(y-x_i)}{\left[1 + \frac{w_i}{K^2}(y-x_i)^2\right]^2} \right\}(n) \right] \quad (27)$$

elde edilir [75].

3.11.2. Ağırlıklandırılmış Median Süzgeç

100 yıl önce daha az kesin regresyon içeriği ile Ağırlıklandırılmış Median Smoother (Weighted Median Smoother-WMS)'lar Edgemore tarafından ortaya konulmuştur[176]. Son 20 yıl içerisinde WMS 'lar, sinyal işleme araştırmalarında önemli hale gelmiştir[82,83]. Bu yapıların sinyal uygulama literatüründe genelde süzgeç olarak

bilinmesine rağmen, bu yapılar WMS olarak da adlandırılmaktadır. Son birkaç yıldır, WMS temelindeki teori hızla geliştirilmiş ve günümüzde görüntü işleme uygulamalarında da sıkça kullanılmaya başlanmıştır. Görüntü uygulamalarında median smoothersların başarısı kendine özgü iki özelliğe dayanır; kenar koruma ve ani gürültülerin güç bastırımı ki bu özellikler geleneksel doğrusal süzgeçlerde bulunmamaktadır. WMS ile doğrusal FIR arasında birçok benzerlik bulunmaktadır. Ayrıca bunlar son derece sınırlı ve doğrusal FIR süzgeçlerden daha az güce sahiptirler[79].

Mühendislik uygulamalarının büyük bir çoğunluğu “band geçiren” ya da “yüksek geçiren” frekans süzgeçleme özelliğine ihtiyaç duyar. Ters konvolusyon, kestirim ve sistem tanımlama “band geçiren” ya da “yüksek geçiren” özelliğinin çok önemli olduğu uygulamalara örnektir. Doğrusal FIR eşitleyicileri sadece pozitif süzgeç ağırlıklarını kabul ederler.

Doğrusal olmayan WMS ‘ler ilk tasarlandıklarında sadece pozitif ağırlıklandırmalar ile çalışabilirken son zamanlardaki gelişmeler ([79] no’lu referansta bahsedilen) median yapısının pozitif ve negatif ağırlıklandırmalar ile süzgeçleme yeteneğine sahip olmasını sağlamıştır. Bu çalışmada Ağırlıklandırılmış Median süzgeç ağırlıklarının eğitimi esnasında Yinbo Li, Gonzalo R. Arce tarafından geliştirilen [178] no’lu referanstaki adaptif öğrenme algoritması kullanılmıştır.

Örnek 1 ;

Pencere boyutu 5 , $W=[1, -2, 3, -2, 1]$ simetrik ağırlık vektörüne sahip ve giriş verisi $X(n)=[2, -6, 9, 1, 12]$, olan WM süzgeç çıkışı aşağıdaki şekilde bulunmaktadır ;

$$\begin{aligned}
 Y(n) &= \text{MEDIAN}[1 \diamond 2, -2 \diamond -6, 3 \diamond 9, -2 \diamond 1, 1 \diamond 12] \\
 &= \text{MEDIAN}[1 \diamond 2, 2 \diamond 6, 3 \diamond 9, 2 \diamond -1, 1 \diamond 12] \\
 &= \text{MEDIAN}[2, 6, 6, 9, 9, -1, -1, 12] \\
 &= \text{MEDIAN}[-1, -1, 2, 6, 6, 9, 9, 12] \\
 &= 6
 \end{aligned}$$

Median ağırlıklarda negatif değerler bulunduğunda bu ağırlıkların matematiksel işaretleri ile ağırlıklara karşılık gelen giriş verileri çarpılır ve yeni giriş veri dizisi oluşturulur . Mevcuttaki negatif değerli ağırlıkların mutlak değerleri alınarak pozitif

değerli ağırlıklar elde edilir. Daha sonra ağırlık değerleri adetinde giriş verileri tekrarlanarak yeni dizi oluşturulur ve dizideki veriler küçükten büyüğe doğru sıralanır. Eğer dizideki veri sayısı tek ise dizinin tam ortanca değeri (altı çizili olan) veri dizinin medianı olur. Buda median süzgeç çıkışını ifade eder.

Örnek 2;

$W = (1, -2, 2, -2, 1)$ tam sayı ağırlıklarına sahip, pencere boyutu 5 olan ve giriş örnek verisi $X(n) = [5, 5, 5, 5, 5]$ pozitif ağırlıklara sahip dizi için WM süzgeç çıkışı aşağıdaki şekilde bulunur;

$$\begin{aligned} Y(n) &= \text{MEDIAN}[1 \diamond 5, -2 \diamond 5, 2 \diamond 5, -2 \diamond 5, 1 \diamond 5] \\ &= \text{MEDIAN}[1 \diamond 5, 2 \diamond -5, 2 \diamond 5, 2 \diamond -5, 1 \diamond 5] \\ &= \text{MEDIAN}[5, -5, -5, 5, 5, -5, -5, 5] \\ &= \text{MEDIAN}[-5, -5, -5, \underline{-5}, \underline{5}, 5, 5, 5] \\ &= 0, \end{aligned}$$

Median ağırlıklarda negatif değerler bulunduğunda bu ağırlıkların matematiksel işaretleri ile ağırlıklara karşılık gelen giriş verileri çarpılır ve yeni giriş veri dizisi oluşturulur. Mevcuttaki negatif değerli ağırlıkların mutlak değerleri alınarak pozitif değerli ağırlıklar elde edilir. Daha sonra ağırlık değerleri adetinde giriş verileri tekrarlanarak yeni dizi oluşturulur ve dizideki veriler küçükten büyüğe doğru sıralanır. Eğer dizideki veri sayısı çift ise dizideki verilerin ortanca iki değerinin (altı çizili olan) ortalaması veri dizisinin medianı olur. Bu değer Median süzgeç çıkışını ifade eder[179].

Ağırlıkların tam sayı olmaması durumunda ağırlıklandırılmış süzgeç çıkışı aşağıdaki aşamalarla hesaplanır:

1. Eşik değer hesaplanır $T_0 = \frac{1}{2} \sum_{i=1}^N |w_i|$
2. Ağırlık katsayılarına ait işaretler hesaplanır ve her bir ağırlığa karşılık gelen giriş verisi ile çarpıldıktan minimum değerden başlayıp maksimum değere kadar sıralanır ; $\text{sgn}(W_i)X_i$.
3. Daha sonra giriş verilerine karşılık gelen ağırlık katsayılarının mutlak değerleri alındıktan sonra 2. aşamada yeniden hesaplanarak sıralanan giriş veri sıralaması

baz alınarak sıralanır ve soldan başlayarak en sağa kadar ki bütün ağırlıklar toplanır benzer şekilde bir sağa kayarak bütün ağırlık değerleri elde edilir.

4. Median çıkışı; eşik değerinden büyük olan ilk ağırlığa karşılık gelen giriş verisine eşittir. Band ve yüksek geçiren süzgeç karakteristiği için çıkış; eşik değerinden büyük birinci ve ikinci ağırlığa karşılık gelen giriş verilerinin ortalamasına eşittir.

Örnek 3;

Pencere boyutu 5 , gerçek ağırlık değerleri (W_1, W_2, W_3, W_4, W_5) = (0.1,0.2, 0.3, -0.2, 0.1), gerçek giriş verileri $[X_1, X_2, X_3, X_4, X_5] = [-2, 2, -1, 3, 6]$ sahip olan WMS çıkışı aşağıdaki şekilde hesaplanır ;

Eşik değeri hesaplanır ; $T_0 = \frac{1}{2} \sum_{i=1}^5 |W_i| = 0.45$ daha sonra sırasıyla diğer işlemler yapılır;

Gerçek giriş verileri	-2, 2, -1, 3, 6
Gerçek ağırlıklar	0.1, 0.2, 0.3, -0.2, 0.1
Yenilenen giriş verileri	-3, -2, -1, 2, 6
İlişkili ağırlık değerleri	0.2, 0.1, 0.3, 0.2, 0.1
Ağırlık toplamaları	0.9, 0.7, <u>0.6</u> , 0.3, 0.1

Süzgeç çıkışı ; eşik değerinden büyük olan altı çizili ilk ağırlığa yani 0.6'ya karşılık gelen giriş verisi olan -1'e eşittir. Band ve yüksek geçiren süzgeç çıkışı ise ; 0.45' den büyük olan ilk iki ağırlık yani 0.6 ve 0.7 ' ye karşılık gelen giriş verileri -1 ve -2 nin ortalaması olan -1,5'e eşittir[179].

3.11.2.1. Ağırlıklandırılmış Median Süzgeç Algoritması:

Adaptif doğrusal ve adaptif Median süzgeçler, Gaussian ve Laplacian istatistikleri temelindeki lokasyonun ML yaklaşımından doğmaktadır.Birbirinden bağımsız tek değişkenli giriş verisi $\{X_i\}$ nin her birinin bir Gaussian yayılıma farklı bir varyans σ_i^2 ile uyduğunu düşünelim .Lokasyonun ML yaklaşımına ait amaç fonksiyonu aşağıdadır ;

$$G_2(\mu) = \sum_{i=1}^N \frac{1}{\sigma_i^2} (X_i - \mu)^2 \quad (28)$$

ve ,

$$\mu = \frac{\sum_{i=1}^N W_i X_i}{\sum_{i=1}^N W_i} \quad (29)$$

yazılabilir burada $w_i = \sigma_i^{-2} > 0$ dir. 31'nolu ifade denklemi $Y = \sum_{i=1}^N W_i X_i$ olan bir

FIR süzgecin normalize edilmiş halini göstermektedir.

Lokasyonun yeni cost fonksiyonu ;

$$G_1(\mu) = \sum_{i=1}^N \frac{1}{\sigma_i^2} |X_i - \mu| \quad (30)$$

şeklinde ifade edilir. Negatif ağırlıklara sahip ağırlıklandırılmış Median süzgeç ;

$$Y = MED(|W_i| \circ \text{sgn}(W_i) X_i) \Big|_{i=1}^N \quad (31)$$

$\text{Sgn}(x) = 1$, $X > 0$ iken

$= -1$, $X < 0$ iken

$= 0$, $X = 0$ iken

şeklinde ifade edilir .Tez çalışmasında kullandığımız LMA (Least Mean Absolute Error) algoritmasını aşağıdaki gibi kullanmalıyız;

$$W_i(n+1) = W_i(n) + \mu_v \text{sgn}(W_i(n))(D(n) - Y(n)).\text{sgn}(\text{sgn}(W_i(n))X_i(n) - Y(n)) \quad (32)$$

Burada $Y(n)$; çıkış değerini, $D(n)$; istenilen değeri, W_i ; ağırlık değerlerini göstermektedir [178].

3.12. Spektral Analiz

Periyodik sayısal bir işaret Fourier serileri ile temsil edilir ve bu işaret kendisinin Fourier katsayılarından yeniden elde edilir. Fourier dönüşümü ile işaret , farklı frekanslardaki sinüzoidal sinyallerin toplamı olarak ifade edilir. Sonlu uzunlukta olan bir sayısal işaretin Hızlı Fourier Dönüşümünü (HFD) almak için bu işaret 64,128,256 gibi örnekler içeren çerçevelere ayrılır. Her bir çerçevenin frekans spektrumu hesaplanırken öncelikle pencereleme işlemi yapılır. Pencereleme işleminin amacı

gerçekte olmayan frekans bileşeninin spektrumda ortaya çıkmasını önlemektir. Pencereleme işleminden sonra sayısal işarete sıfır ekleme (zero padding) işlemi yapılır. Sıfır ekleme işlemi, spektrumda okunabilirliği artırmaktadır .

Mühendislik uygulamaları açısından bir zorlamanın Fourier dönüşümü alınabilmesi için aşağıdaki şartı sağlaması gerekmektedir .

$$\int_{-\infty}^{\infty} x(t) dt \neq 0 \quad (33)$$

Bu eşitlik klasik teoremin sadece $t \rightarrow \infty$ sifira giden fonksiyonlar için kullanılabileceğini anlatır. Eğer zorlama bu şartı sağlıyor ise fonksiyonun Fourier dönüşümü;

$$X(W) = 1/2 \int_{-\infty}^{\infty} x(t) e^{-j\omega t} dt \quad (34)$$

şeklindedir ve bu zorlamaya sistemin cevabı

$$Y(w) = H(w)X(w) \quad (35)$$

şeklindedir. Sonucun ters dönüşümü alınarak sistemin zaman bölgesindeki cevabı aşağıdaki şekilde bulunur,

$$X(w) = \int_{-\infty}^{\infty} H(w) \left\{ 1/2 \int_{-\infty}^{\infty} x(t) e^{-j\omega t} dt \right\} e^{j\omega t} dw \quad (36)$$

Doğrusal sistemlerde aynı mantıkla güç spektral yoğunluğu tek giriş ve tek çıkış için

$$S_y(w) = |H(w)|^2 S_x(w) \quad (37)$$

ve çok giriş-tek çıkış için

$$S_y(w) = \sum_{r=1}^N |H_r(w)|^2 S_{x_r}(w) \quad (38)$$

şeklindedir[180,181].


3.13. Güç Spektral Yoğunluğunun Hesaplanması

Gelişigüzel ayırık sinyallerin güç spektral yoğunluklarının hesaplanması için yapılan çalışmalar yaklaşık 200 yıl önce Schuster' ın güneş ışığı miktarı üzerine yaptığı çalışmalarla başlamıştır. Gelişigüzel sinyallerin Fourier analizi, kovaryans ile güç spektrumu arasında ilişki kuran Wiener- Khintchine teoreminin bulunmasıyla yeni bir döneme girmiştir. Son olarak bir ayırık Fourier dönüşümü (AFD) algoritması olan hızlı

Fourier dönüşümlerinin (HFD) keşfi ve dijital bilgisayarların gelişmesiyle parametrik olmayan klasik yaklaşımın temelleri atılmıştır.

Bu sinyallerin spektral analizinde modern (parametrik) ve klasik (parametrik olmayan) şeklinde iki yaklaşım kullanılmaktadır. Parametrik veya modern yaklaşım, incelenen sürecin tam olarak veya yaklaşık olarak seçilen bir model ile ifade edilebileceği temeline dayanır. Parametrik spektra hesaplama yaklaşımı (1) modelin seçilmesi, (2) verilerden ve kovaryans gecikmelerinden model parametrelerinin hesaplanması ve (3) hesaplanan model kullanılarak spektral yoğunluğun hesaplanması olarak üç aşamadan oluşmaktadır. Model tabanlı bu metodun en önemli avantajı veriler pencereden geçirilmediği için yüksek frekans çözünürlüğüne ulaşılabilmesidir. Bu yaklaşımda öncelikle uygun model hesaplanıp buradan GSY(Güç Spektrum Yoğunluğu)'na geçildiği için direkt olmayan bir yapıdadır [182].

Klasik spektral analiz yaklaşımı direkt ve direkt olmayan şeklinde iki katagoriye ayrılmaktadır . Şekil 3.5 'ten de görülebileceği gibi direkt metod işlenmemiş verileri frekans bölgesine dönüştürmek ve sonucu oluşturmak şeklinde çalışmaktadır. Dolaylı metodta ise öncelikle kovaryans işlemi hesaplanmakta ve daha sonra bu frekans bölgesine dönüştürülmektedir. Yani dolaylı metod Wiener-Khintchine teoreminin bir uygulamasıdır [181,182].



Şekil 3.5. Klasik (Parametrik olmayan) Spektral Hesap


Gelişigüzel $x(t)$ süreci için otokorelasyon fonksiyonu, $x(t)x(t+\tau)$ çarpımının ortalamasıdır. Süreç durağan olduğu sürece bu değer zamandan bağımsızdır ve sadece zaman gecikmesi τ 'ya bağlıdır. Buna göre

$$E[x(t)x(t + \tau)] = f(t) = R_x(t) \quad (39)$$

buradan spektral yoğunluk,

$$S_x(\omega) = AFD[R_x(\tau)] \quad (40)$$

şeklindedir [180,181]. Bu teknik gürültülü spektral hesaplamalar vermeye meyillidir, fakat otokorelasyon genellikle gecikme penceresi olarak adlandırılan bir pencere fonksiyonu, W , ile çarpılarak daha düzgün sonuçlar elde edilebilir. Pencere temel olarak spektral kaçakları azaltır ve spektral yoğunluk hesabını geliştirir. Bu yöntemin blok diyagramı Şekil 3.6' da verilmiştir.



Şekil 3.6. Korelasyon Metodu Blok Diyagramı

Bu blok diyagramı aşağıdaki şekilde özetlenebilir;

1. $x(t)$ 'nin AFD'nün hesaplanması, yani $X(\omega)$,
2. $X(\omega)$ 'nin konjügesiyle çarpılarak $|X(\omega)|^2$ nin elde edilmesi,
3. TAFD ile kovaryansın elde edilmesi,
4. Kovaryansın $W(\tau)$ gecikme penceresiyle çarpılması,
5. Pencereden geçirilmiş kovaryansın AFD ile GSY'nun hesaplanması,

Direkt metod olarak adlandırılan periodogramın istatistikî özellikleri korelasyon metoduyla aynıdır. Periodogram istatistikçiler tarafından gürültülü veri kayıtlarındaki periyodik hareketleri tespit etmek için oluşturulmuş bir methodur. Bu geliştirilmiş spektral hesap yöntemi

$$P_x = 1/N [X(\omega)]^2 = 1/N \sum_{k=-(N-1)}^{N-1} R_x(\tau) e^{j\tau\omega} \quad (41)$$

şeklinde tanımlanmıştır. Periodogram metodu istatistiki ortalama ve pencereyle düzgünleştirme yöntemleriyle daha da geliştirilebilir. Bu geliştirilmiş metod Welch Metodu olarak adlandırılır.

Welch Metodunun uygulanması için takibi gerekli basamaklar aşağıda sıralanmıştır ve Şekil 3.7' de Welch Metodunun blok diyagramı verilmiştir.

1. Eldeki veriler, $\{x(t)\}$, $t=1, \dots, N$ herbiri L uzunluğunda K parçaya bölünür, yani;

$$K = N / L$$

$$x_i(t) = x(t + L(i - 1)), i = 1, \dots, K, t = 0, \dots, L - 1 \quad (42)$$

2. $x_i(t)W_i(t)$ elde etmek için veriler pencereden geçirilir.
3. AFD kullanılarak K adet periodogram hesaplanır,

$$P(w, i) = 1/U |AFT[x_i(t)W_i(t)]|^2, i = 1, \dots, K \quad (43)$$

Burada,


$$U = 1/L \sum_{t=0}^{L-1} W^2(t) \quad (44)$$

olarak ifade edilir.

4. Aşağıdaki formül kullanılarak spektrum hesaplanır.

$$S_x(w) = 1/K \sum_{i=1}^K P(w, i) \quad (45)$$

Bu hesaplanan spektrumun varyansı $1/K$ ile ve çözünürlük hatası K/N ile orantılıdır.




Şekil 3.7. Welch Metodu Blok Diyagramı

4.BÖLÜM

BENZETİM ÇALIŞMALARI

Bu çalışmada EKG sinyaline karışan kas gürültüsü (EMG), doğrusal olmayan adaptif ağırlıklandırılmış Myriad süzgeç, ağırlıklandırılmış Median süzgeç ve doğrusal adaptif FIR süzgeç kullanılarak bastırılmış ve süzgeç başarımları Matlab 6.5 kullanılarak karşılaştırılmıştır. Bu maksatla EKG işaretine gerçek zamanlı olarak kaydedilen EMG işareti ve α -bağımlı yayılım ile modellenen yapay EMG işareti ayrı ayrı eklenmiş ve bu durumlardaki süzgeç performansları incelenmiştir. Yapılan benzetim çalışmalarında, EKG sinyalinden kas gürültüsünün adaptif süzgeç yapısı kullanılarak arındırılmasına yönelik işleme ait blok şema Şekil 4.1’de verilmektedir.



Şekil 4.1. Adaptif Süzgeç Yapısı


Benzetim çalışmalarında kullanılan EKG ve EMG sinyalleri literatürde referans olarak gösterilen Physionet veri bankasında bulunan MIT-BIH Polysomnographic kayıtlar içerisinde seçilen (slp32, slp37, slp41, slp45, slp48) kayıtlar kullanılmıştır. Uyku bozukluklarının tanısı için “altın standart” yöntem olan “polisomnografi” , uyku sırasında, nörofizyolojik, kardiyorespiratuar, diğer fizyolojik ve fiziksel parametrelerin belli bir periyod, genellikle gece boyunca, eş zamanlı ve devamlı olarak kaydedilmesi şeklinde tanımlanmaktadır. Bu yöntemle uyku evreleri ve birçok fizyolojik parametre ayrıntılı olarak izlenmekte ve çeşitli organ sistemlerinin fonksiyonu, uyku ve uyanıklık sırasındaki etkileşimleri konusunda bilgi sağlanmaktadır.

MIT-BIH Polisomnografik veri bankasında, uyku esnasındaki çoklu fizyolojik sinyallerin toplu kayıtları bulunmaktadır. Sinyaller, kronik uyku apnesi sendromunu değerlendirmek ve genellikle bu konudaki engelleri azaltmak için uygulanan sürekli pozitif hava baskılarının etkilerini test etmek için gözlemlenmektedir.

Bu veritabanında, 16 deneğin hepsi erkek, 32 ile 56 yaş arasında, 89 ile 152 kilo arasındadır. Slp01a ve Slp01b kayıtları bir deneğin polisomnogramının sekmeleridir ki bunlar yaklaşık bir saatlik aralıklarla yapılmıştır. Slp02a ve Slp02b kayıtları 10 dakikalık boşluklara bölünmüş diğer deneklerin polysomnogram’larıdır. Geriye kalan 14 kaydın hepsi farklı deneklerindir.


Bütün kayıtlar; ECG sinyalleri, yayılan kan basıncı sinyalleri, EEG sinyali ve solunum verilerini içermektedir. Bazılarında ise ilave olarak, EOG, EMG (Çene bölgesinden alınan) , kalbe ait ses sinyali ve kulak memesi oksimetre sinyalini içermektedir[183].

Uygulamalarda giriş verisi olarak kullanılan EKG ve EMG sinyallerinin toplam kayıt süresi 1 dk olup örnekleme frekansları 250Hz ve rastgele örnek alma süreleri 0.004 sn’dir. Bu sinyallerin grafiksel olarak gösterimi Şekil 4.2’de verilmektedir. Her iki sinyal 15000’er adet örnek veriden oluşmakta ve 12 bitlik analog dijital çevirici çözünürlüğüne sahiptir.




Şekil 4.2. Benzetim çalışmalarında kullanılan EKG ve EMG sinyalleri.

Benzetim çalışmalarında ilk olarak gerçek zamanlı olarak kaydedilen EMG sinyalinin α -bağımlı gürültü modeli [184] no'lu referansta geliştirilen metot temel alınarak oluşturulmuştur. EMG işaretinin $\alpha=1.5$ ve $\alpha=0.5$ olarak seçilen α -bağımlı gürültü modelleri sırasıyla Şekil 4.3 (a) ve (b)'de görülmektedir. α değeri sıfıra yaklaştıkça sinyal daha keskin dürtülere sahip olmaktadır. Şekil 4.4 (a) ve (b)'de ise bu modellere ait Güç Spektrum Yoğunlukları (GSY) görülmektedir.





(a) $\alpha=1.5$




(b) $\alpha=0.5$


Şekil 4.3. EMG işaretinin α -bağımlı gürültü modelleri.

(a) $\alpha=1.5$ (b) $\alpha=0.5$ Şekil 4.4. EMG işaretinin α -bağımlı Gürültü modellerine ait GSY 'ları

Yapay EMG sinyalleri ile yapılan testlerde EMG sinyalinin modellenmesinde α -bağımlı modelin başarımının Gauss modeline göre daha başarılı olduğu Şekil 4.4 ve Şekil 4.5 'te gösterilmektedir. Ayrıca α değeri sıfıra yaklaştıkça EMG sinyaline olan benzerliği daha da artmaktadır. Şekil 4.5 'de ise gerçek zamanlı olarak kayıt edilen EMG sinyali ve Gauss sinyallerine ait Güç Spektrum yoğunlukları gösterilmektedir. EMG sinyali ile Gauss sinyalinin frekans sahaları birbirine yakın fakat frekans karakteristikleri farklılık göstermektedir.




(a) Gerçek EMG Sinyali



(b) Gauss Sinyali


Şekil 4.5. Gerçek EMG Sinyali ve Gauss Sinyaline ait GSY' ları

Benzetimlerde kullanılan EKG işareti olarak Şekil 4.2.'deki 15000 örnek verinin ilk 500 örnek verisi istenilen işaret olarak kullanılmış ve bu işaret Şekil 4.6'da verilmiştir.




Şekil 4.6. İstenilen EKG işareti.

Şekil 4.6 'da verilen EKG sinyaline Şekil 4.3 (a) ve (b) de verilen yapay EMG gürültüleri eklenmiştir. Eklenen gürültüler sonucu oluşan bozuk EKG işaretleri sırasıyla Şekil 4.7 (a) ve (b)' de verilmiştir.



(a)




(b)


Şekil 4.7. Yapay EMG işareti eklenen EKG işaretleri.

Şekil 4.1 'de verilen blok yapı göz önüne alınarak gürültülü EKG işareti adaptif Myriad süzgeç , Median süzgeç ve FIR süzgeçten geçirilerek gürültüden arındırılması sağlanmıştır. Adaptif Myriad süzgeç optimizasyonunda öğrenme algoritması olarak [75] no'lu referansta Kalluri ve Arce tarafından geliştirilen algoritma, adaptif Median süzgeç algoritması olarak [178] Yinbo Li 'nin tasarladığı algoritma ve FIR süzgeç


optimizasyonunda ise LMAD algoritması kullanılmıştır [185]. Şekil 4.7 (a) 'da ki gürültülü EKG işaretinin ($\alpha=1.5$) adaptif Myriad süzgeç ,Median süzgeç ve FIR süzgeçten geçirildikten sonra oluşan gürültüden arındırılmış durumu sırasıyla Şekil 4.8. (a), (b) ve (c) 'de verilmiştir. Elde edilen çıkışları, gürültüsüz EKG sinyali ile karşılaştırdığımızda, FIR süzgeç çıkışındaki sinyalin, gürültüden tam olarak arındırılmadığı ve sinyale ait P,Q,S,T bileşenlerinin net olarak anlaşılamadığı görülmektedir. Ayrıca Median süzgeç çıkışı incelendiğinde, FIR süzgeç çıkışına göre nispeten daha başarılı gürültü süzme yapmasına rağmen, R bileşeninin genliğinde bozulmalar olduğu tespit edilmiştir. Myriad süzgeç çıkışındaki sinyalin, P,Q,R,S,T bileşenleri gürültüsüz EKG sinyali bileşenlerine daha yakın değerler olduğu tespit edilmiştir.



(a) Ağırlıklandırılmış Myriad süzgeç çıkışı.




(b) FIR süzgeç çıkışı.




(c) Ağırlıklandırılmış Median süzgeç çıkışı.

Şekil 4.8. Yapay gürültülü ($\alpha=1.5$) EKG 'ye ait süzgeç çıkışları.

Çıkışların Güç Spektrum yoğunlukları (GSY) ise Şekil 4.9 'da gösterilmektedir. Gürültüsüz EKG sinyali ile filtre çıkışlarının aynı frekans sahası ve aynı frekans özelliklerine sahip olduğunu anlamak için GSY 'ları incelenmiştir. Myriad ve FIR süzgeç çıkışları ile gürültüsüz EKG sinyalinin frekans sahasları yaklaşık 32 Hz civarındadır yani hemen hemen aynı frekans sahası içinde bulunmaktadır. Ancak 10 ile 30 Hz arasındaki frekans değerlerinde FIR süzgece ait frekans karakteristiğinin Myriad süzgeç cevabına göre daha başarısız olduğu tespit edilmiştir. Bu yüzden gürültüsüz EKG sinyalinin frekans karakteristiğine en yakın davranışı Myriad süzgecin sergilediği sonucuna varılmıştır. Ayrıca Median süzgecin frekans sahasının yaklaşık 26 Hz olması ve frekans karakteristiğinin farklılığı sebebiyle gürültüsüz EKG sinyalinin özelliklerine yakın davranışlar sergileyememiştir.



(a)



(b) Şekil 4.9 (a) 'nın Ayrıntılı Hali.


Şekil 4.9. ($\alpha=1.5$) iken Süzgeç Çıkışlarının GSY'ları.

Sistemde, istenilen işaret olan gürültüsüz EKG sinyali ile filtre çıkışlarında elde edilen gürültüden arındırılmış sinyaller karşılaştırılarak, hata karakteristiği ,MSE (Mean Square Error) yöntemiyle hesaplanmıştır. $\alpha =1,5$ iken , Tablo 4.1 'de gösterildiği üzere bütün SNR (Sinyal / Gürültü) değerlerinde Ağırlıklandırılmış Myriad süzgeç çıkışlarında elde edilen hata değerleri istenilen yani (MSE= 0) sifıra daha yakın sonuçlar vermektedir.


Tablo 4.1. $\alpha =1,5$ iken MSE değerleri.

α	SNR (dB)	Mean Square Error (MSE)		
		WMyriad Süzgeç	WMedian Süzgeç	FIR Süzgeç
1,5	+ 25dB	0,000505	0,0113	0,002
1,5	+ 20dB	0,0015	0,0154	0,0039
1,5	+ 15dB	0,0041	0,0160	0,0072
1,5	+ 10dB	0,0151	0,0171	0,0162
1,5	+ 5dB	0,0213	0,0233	0,0291
1,5	+ 0dB	0,0246	0,0271	0,0446


Aynı zamanda Şekil 4.7 (b)' deki gürültülü EKG işaretinin ($\alpha=0.5$) süzgeçlerden geçirildikten sonraki durumu ise sırasıyla Şekil 4.10 (a),(b) ve (c) 'de gösterilmiştir. FIR süzgeç çıkışındaki sinyalin, hala yoğun olarak dürtülü gürültü bileşenleri içerdiği ve bu yüzden P ve T bileşenlerinin net olarak anlaşılamamaktadır. Median süzgeç çıkışı incelendiğinde, FIR süzgeç çıkışına göre daha başarılı gürültü süzme başarımı olmasına rağmen, R bileşeninin genliğinde bozulmalar meydana getirdiği tespit edilmiştir. Myriad süzgeç çıkışındaki sinyalde azda olsa dürtü bileşenleri bulunmasına rağmen bu durum P,Q,R,S,T bileşenlerinin anlaşılması için problem teşkil etmemektedir. Ayrıca gürültüsüz EKG sinyal bileşenlerine en yakın değerler Myriad süzgeç çıkışında elde edilmiştir.



(a) Ağırlıklandırılmış Myriad süzgeç çıkışı.



(b) FIR süzgeç çıkışı.




(c) Ağırlıklandırılmış Median süzgeç çıkışı


Şekil 4.10. Yapay gürültülü ($\alpha=0.5$) EKG' ye ait süzgeç çıkışları.

Şekil 4.11 'de gürültülü EKG işaretinin ($\alpha=0.5$) süzgeçlerden geçirildikten sonra elde edilen çıkışlara ait Güç Spektrum yoğunlukları gösterilmektedir. Myriad ve FIR süzgeç

çıkışları ile gürültüsüz EKG sinyalinin frekans sahalarının yaklaşık 33 Hz olmasına karşın, gürültüsüz EKG sinyalinin frekans karakteristiğine en yakın davranışı Myriad süzgeç sergilemektedir. Ayrıca Median süzgecin frekans sahasının yaklaşık 26 Hz 'den olması ve frekans karakteristiğinin farklı olması sebebiyle gürültüsüz EKG sinyalinin özelliklerine benzerlik göstermemektedir.



(a)



(c) Şekil 4.11 (a) 'nın Ayrıntılı Hali.


Şekil 4.11. Yapay gürültülü ($\alpha=0.5$) EKG' ye ait süzgeç çıkışlarının GSY 'ları.

$\alpha = 0,5$ iken, Tablo 4.2 'de gösterildiği gibi bütün SNR (Sinyal/Gürültü) değerlerinde Ağırlıklandırılmış Myriad süzgeç çıkışlarında elde edilen hata değerlerinin en uygun sonuçları verdiği anlaşılmaktadır. Ayrıca bu sonuçları, $\alpha = 1,5$ olduğu zaman ki sonuçlarla karşılaştırdığımızda bunların ideal değerlere (MSE = 0) daha yakın oldukları tespit edilmiştir.

Tablo 4.2. $\alpha = 0,5$ iken MSE değerleri.

α	SNR (dB)	Mean Square Error (MSE)		
		WMyriad Süzgeç	WMedian Süzgeç	FIR Süzgeç
0,5	+ 25dB	0,0004	0,015	0,0019
0,5	+ 20dB	0,001	0,0151	0,0036
0,5	+ 15dB	0,0014	0,0156	0,007
0,5	+ 10dB	0,0025	0,0159	0,0102
0,5	+ 5dB	0,0109	0,0167	0,0203
0,5	+ 0dB	0,0171	0,0174	0,0453


Yapılan bu çalışmaların yanı sıra, süzgeçlerin gerçek zamanlı olarak kaydedilen EMG ile bozulan EKG işaretinin gürültüden arındırılmasındaki başarımları da incelenmiştir. Bu maksatla Şekil 4.2 'deki 15000 örnek EMG verisinin ilk 500 verisi gürültü olarak kullanılmış ve Şekil 4.12 (a) 'da verilmiştir. Ayrıca, gerçek zamanlı olarak kaydedilen EMG gürültüsünün eklenmesi sonucu oluşan gürültülü EKG işareti de Şekil 4.12 (b) 'de verilmiştir.




(a) Gerçek zamanlı olarak kaydedilen EMG işareti. (b) Gürültülü EKG işareti.

Şekil 4.12. Gerçek EMG sinyali ve EKG'ye eklenmiş hali.


Şekil 4.12 (b) 'deki gerçek gürültü ile bozulmuş EKG işareti sırasıyla adaptif Myriad süzgeç, Median süzgeç ve FIR süzgeçten geçirilmiştir. Süzgeç çıkışlarında elde edilen gürültüsüz EKG işaretleri Şekil 4.13 (a),(b),(c) 'de gösterilmiştir. FIR süzgeç çıkışındaki sinyalin, hala EMG sinyal bileşenleri içermesi sebebiyle P,Q,S,T bileşenleri ayrıntılı olarak tanımlanamamaktadır. Median süzgeç çıkışında P,Q,S,T bileşenlerinin daha anlaşılır olmasına rağmen, genliklerinde azalmaların olması ve R bileşeninde kısmen bastırılmasından dolayı işarete bozulmalar meydana gelmiştir.



(a) Ağırlıklandırılmış Myriad süzgeç çıkışı.



(b) FIR süzgeç çıkışı.




(c) Ağırlıklandırılmış Median süzgeç çıkışı.


Şekil 4.13. Gerçek EMG gürültülü EKG' ye ait süzgeç çıkışları.

Şekil 4.12 (b) 'deki gerçek gürültü ile bozulmuş EKG işaretinin süzgeç başarımları sonucunda Şekil 4.13 'de elde edilen çıkışlara ait Güç Spektrum yoğunlukları Şekil 4.14' de gösterilmektedir.

Myriad ve FIR süzgeç çıkışları ile gürültüsüz EKG sinyalinin frekans sahalarının yaklaşık 37 Hz olmasına rağmen Myriad süzgeç çıkışı, FIR 'a göre EKG sinyalinin frekans karakteristiğine daha çok benzemektedir. Diğer taraftan Median süzgecin frekans sahasının yaklaşık 27 Hz olması ve frekans karakteristiğinin gürültüsüz EKG sinyalinin özelliklerinden uzak olması nedeniyle benzerlikler göstermemektedir



(a)



(b) Şekil 4.14 (a) 'nın Ayrıntılı Hali.

Şekil 4.14. Gerçek EMG Gürültülü EKG Sinyaline ait Süzgeç Çıkışlarının GSY'ları.

Gerçek EMG sinyalleri ile yapılan testlerde Tablo 4.3 'de de gösterildiği üzere bütün SNR değerlerinde hata karakteristiği yönünden Ağırlıklandırılmış Myriad süzgeç , FIR süzgeç ve Ağırlıklandırılmış Median süzgece göre daha iyi sonuçlar vermektedir.

Tablo 4.3. Gerçek EMG sinyali için MSE değerleri.

Snr (dB)	Mean Square Error (MSE)		
	Wmyriad Süzgeç	Wmedian Süzgeç	FIR Süzgeç
+ 25dB	0,00056	0,0153	0,0018
+ 20dB	0,0012	0,0157	0,0034
+ 15dB	0,0026	0,0166	0,006
+ 10dB	0,0052	0,0184	0,0082
+ 5dB	0,0148	0,0228	0,0151
+ 0dB	0,0305	0,0341	0,0326

Yapılan çalışmalarda süzgeçleme başarımlarının tespiti amacıyla MSE ve GSY hesaplamalarının yanısıra EKG sinyal bileşenlerinin voltaj ve süre olarak analizleride yapılmıştır. Bu amaçla farklı hastalardan alınan EKG sinyalleri içeren kayıtlar sisteme giriş verisi olarak uygulandığında çıkışlarda Tompkins algoritması [133] ile elde edilen sinyalin bileşen değerleri hesaplanmaktadır.

Tablo 4.1, Tablo 4.2, Tablo 4.3 'de görüldüğü üzere α değeri arttıkça, alınan sonuçlardaki hata başarımlarının azaldığı tespit edilmiştir. +0 ile +25 dB arasında bütün SNR (Sinyal/Gürültü) değerlerindeki filtre çıkışlarına ait MSE değerleri incelendiğinde Myriad süzgeç yapısı sonuçlarının sıfıra daha yakın hata değerleri veren model olduğu görülmektedir. Ayrıca EKG bileşen analizi için yapılan testlerde ise α değeri arttıkça, EKG bileşenlerinin ideal değerlerden [145] uzaklaştığı görülmektedir.

MIT-BIH veri bankasından alınan (slp32, slp37, slp41, slp45, slp48) EKG kayıtlarına, α değeri 0.5, 1.0, 1.5 seçilerek oluşturulan yapay gürültüler ilave edilmiş ve bunlar sisteme giriş verisi olarak uygulanmıştır. Bunlara karşılık süzgeç çıkışlarından alınan sinyallere ait EKG bileşenlerini, genlik (mV) ve süre (sn) cinsinden incelenmiştir. Tablo 4.4, Tablo 4.5, Tablo 4.6 'da görüldüğü üzere bütün süzgeç çıkışlarındaki EKG bileşen değerlerinin, α değeri arttıkça ideal değerlerden uzaklaştığı tespit edilmiştir.

Ayrıca Yüzüncü yıl üniversitesinin EKG analizi için yaptığı araştırma [145] ve [186] sonuçları temel alınarak, süzgeç çıkışları kendi aralarında karşılaştırılmıştır. Sonuçlarda Myriad süzgeç yapısının Median ve FIR süzgeç yapılarına göre daha iyi başarımlar sergilediği tespit edilmiştir. Sonuçlara göre, lineer bir yapı olmasına rağmen FIR süzgeç yapısı, Myriad süzgeç yapısından sonra en iyi sonuçları veren süzgeçtir.

Tablo 4.4. Myriad Süzgeç Çıkışlarındaki EKG Bileşen Değerleri.

MIT-BIH Kayıt Tipi	Giriş Datası	MYRIAD SÜZGEÇ ÇIKIŞI										
		P1 (mV)	P2 (mV)	P_P Süre (sn)	R1 (mV)	R2 (mV)	R_R Süre (sn)	T1 (mV)	T2 (mV)	T_T Süre (sn)	QRS (mV)	QRS Süre(sn)
	Slp32 + Noise (@=0.5)	0,218	0,221	0,816	2,678	2,976	0,82	0,345	0,381	0,8240	0,960	0,08470
	Slp32 + Noise (@=1)	0,216	0,217	0,811	2,669	2,971	0,77	0,348	0,378	0,8236	0,952	0,08468
	Slp32 + Noise (@=1.5)	0,212	0,215	0,802	2,661	2,963	0,79	0,342	0,372	0,8233	0,948	0,08462
	Slp37 + Noise (@=0.5)	0,217	0,219	0,8	2,564	2,856	0,812	0,321	0,364	0,802	0,965	0,0843
	Slp37 + Noise (@=1)	0,215	0,216	0,798	2,551	2,844	0,811	0,318	0,352	0,793	0,952	0,08323
	Slp37 + Noise (@=1.5)	0,211	0,213	0,793	2,537	2,832	0,805	0,301	0,345	0,797	0,943	0,083
	Slp41 + Noise (@=0.5)	0,231	0,203	0,81	2,789	3,171	0,767	0,371	0,394	0,804	0,941	0,0798
	Slp41 + Noise (@=1)	0,224	0,201	0,805	2,768	3,165	0,762	0,366	0,387	0,801	0,933	0,0796
	Slp41 + Noise (@=1.5)	0,221	0,205	0,809	2,756	3,143	0,756	0,345	0,379	0,793	0,927	0,0795
	Slp45 + Noise (@=0.5)	0,212	0,215	0,798	2,545	2,744	0,801	0,345	0,366	0,797	0,966	0,0836
	Slp45 + Noise (@=1)	0,21	0,212	0,801	2,501	2,732	0,8	0,321	0,357	0,784	0,953	0,0827
	Slp45 + Noise (@=1.5)	0,199	0,201	0,799	2,489	2,702	0,798	0,312	0,351	0,760	0,944	0,0823
	Slp48 + Noise (@=0.5)	0,202	0,207	0,8	2,571	2,632	0,802	0,311	0,337	0,794	0,963	0,0817
	Slp48 + Noise (@=1)	0,2	0,202	0,798	2,562	2,625	0,798	0,309	0,332	0,792	0,956	0,0813
	Slp48 + Noise (@=1.5)	0,198	0,199	0,796	2,56	2,615	0,792	0,302	0,329	0,79	0,946	0,0811

Tablo 4.5. MedianSüzgeç Çıkışlarındaki EKG Bileşen Değerleri.

MIT-BIH Kayıt Tipi	Giriş Datası	MEDIAN SÜZGEÇ ÇIKIŞI										
		P1 (mV)	P2 (mV)	P_P Süre (sn)	R1 (mV)	R2 (mV)	R_R Süre (sn)	T1 (mV)	T2 (mV)	T_T Süre (sn)	QRS (mV)	QRS Süre(sn)
MIT-BIH Kayıt Tipi	Slp32 + Noise (@=0.5)	0,163	0,169	0,801	2,178	2,196	0,79	0,221	0,231	0,8030	0,662	0,0620
	Slp32 + Noise (@=1)	0,154	0,163	0,794	2,15	2,188	0,786	0,215	0,224	0,783	0,660	0,0612
	Slp32 + Noise (@=1.5)	0,158	0,161	0,797	2,123	2,171	0,782	0,21	0,211	0,776	0,651	0,0603
MIT-BIH Kayıt Tipi	Slp37 + Noise (@=0.5)	0,178	0,172	0,799	2,181	2,178	0,8	0,271	0,291	0,778	0,683	0,0615
	Slp37 + Noise (@=1)	0,176	0,167	0,789	2,087	2,166	0,793	0,267	0,272	0,772	0,68	0,0609
	Slp37 + Noise (@=1.5)	0,165	0,161	0,8	2,066	2,152	0,787	0,251	0,281	0,769	0,677	0,0606
MIT-BIH Kayıt Tipi	Slp41 + Noise (@=0.5)	0,162	0,168	0,793	2,121	2,197	0,792	0,255	0,261	0,789	0,675	0,0638
	Slp41 + Noise (@=1)	0,16	0,164	0,791	2,119	2,191	0,788	0,244	0,253	0,8	0,672	0,0624
	Slp41 + Noise (@=1.5)	0,158	0,16	0,795	2,11	2,18	0,785	0,24	0,251	0,795	0,667	0,063
MIT-BIH Kayıt Tipi	Slp45 + Noise (@=0.5)	0,168	0,171	0,798	2,103	2,141	0,797	0,231	0,238	0,787	0,643	0,0603
	Slp45 + Noise (@=1)	0,166	0,167	0,793	2,101	2,132	0,793	0,224	0,234	0,782	0,641	0,0595
	Slp45 + Noise (@=1.5)	0,161	0,162	0,791	2,098	2,125	0,789	0,221	0,231	0,78	0,635	0,0602
MIT-BIH Kayıt Tipi	Slp48 + Noise (@=0.5)	0,148	0,15	0,755	2,2	2,217	0,721	0,211	0,232	0,703	0,631	0,0635
	Slp48 + Noise (@=1)	0,144	0,147	0,751	2,16	2,201	0,716	0,202	0,226	0,695	0,624	0,0626
	Slp48 + Noise (@=1.5)	0,141	0,143	0,748	2,11	2,198	0,708	0,196	0,215	0,691	0,621	0,0614

Tablo 4.6. FIR Süzgeç Çıktılarındaki EKG Bileşen Değerleri.

MIT-BIH Kayıt Tipi	Giriş Datası	FIR SÜZGEÇ ÇIKIŞI										
		P1 (mV)	P2 (mV)	P_P Süre (sn)	R1 (mV)	R2 (mV)	R_R Süre (sn)	T1 (mV)	T2 (mV)	T_T Süre (sn)	QRS (mV)	QRS Süre(sn)
MIT-BIH Kayıt Tipi	Slp32 + Noise (@=0.5)	0,182	0,187	0,81	2,194	2,204	0,801	0,263	0,27	0,81	0,721	0,0722
	Slp32 + Noise (@=1)	0,179	0,174	0,807	2,188	2,199	0,8	0,254	0,262	0,8056	0,701	0,0717
	Slp32 + Noise (@=1.5)	0,175	0,169	0,801	2,178	2,196	0,79	0,221	0,231	0,8030	0,662	0,071
MIT-BIH Kayıt Tipi	Slp37 + Noise (@=0.5)	0,189	0,184	0,789	2,217	2,232	0,791	0,297	0,301	0,797	0,763	0,0714
	Slp37 + Noise (@=1)	0,188	0,183	0,782	2,201	2,211	0,794	0,291	0,296	0,782	0,759	0,0712
	Slp37 + Noise (@=1.5)	0,185	0,178	0,802	2,198	2,203	0,804	0,288	0,291	0,794	0,742	0,0705
MIT-BIH Kayıt Tipi	Slp41 + Noise (@=0.5)	0,177	0,183	0,799	2,236	2,343	0,786	0,275	0,289	0,795	0,747	0,0703
	Slp41 + Noise (@=1)	0,173	0,18	0,802	2,229	2,302	0,8065	0,271	0,278	0,792	0,741	0,0701
	Slp41 + Noise (@=1.5)	0,171	0,178	0,801	2,221	2,297	0,802	0,265	0,271	0,789	0,735	0,0698
MIT-BIH Kayıt Tipi	Slp45 + Noise (@=0.5)	0,172	0,188	0,791	2,349	2,402	0,788	0,282	0,281	0,763	0,764	0,0723
	Slp45 + Noise (@=1)	0,17	0,183	0,795	2,301	2,386	0,783	0,279	0,273	0,761	0,761	0,0711
	Slp45 + Noise (@=1.5)	0,169	0,181	0,788	2,293	2,341	0,777	0,271	0,268	0,76	0,756	0,0704
MIT-BIH Kayıt Tipi	Slp48 + Noise (@=0.5)	0,169	0,171	0,793	2,236	2,265	0,794	0,269	0,276	0,757	0,746	0,0701
	Slp48 + Noise (@=1)	0,163	0,168	0,792	2,231	2,256	0,785	0,258	0,261	0,732	0,737	0,0699
	Slp48 + Noise (@=1.5)	0,161	0,162	0,795	2,215	2,247	0,771	0,247	0,245	0,724	0,731	0,0695

5.BÖLÜM

SONUÇLAR

Bu tez çalışmasında, EKG sinyaline karışan kas gürültüsünün (EMG), doğrusal olmayan adaptif Myriad süzgeç , adaptif Median süzgeç ve doğrusal adaptif FIR süzgeç kullanılarak bastırılması amaçlanmıştır. Bu maksatla EKG işaretine hem gerçek zamanlı olarak kaydedilen EMG işareti hem de α -sabitli gürültü ile modellenen yapay EMG işareti ayrı ayrı eklenmiş ve bu durumlardaki süzgeç performansları incelenmiştir. Yapılan benzetim çalışmalarına göre, farklı α değerleri ile oluşturulan yapay kas gürültülerin ve gerçek zamanlı kas gürültüsünün EKG işaretinden arındırılmasında Myriad, Median ve FIR süzgeç yapıları gözlemlenmiştir.

Yapay EMG sinyalleri ile yapılan testlerde EMG sinyalinin modellenmesinde α -bağımlı modelin başarımının, Gauss modeline göre daha başarılı olduğu gözlemlenmiştir. Ayrıca α değeri sıfıra yaklaştıkça EMG sinyaline olan yakınlığı daha da artmaktadır. Bu sonuç, işaretlere ait GSY grafikleri ile daha detaylı olarak görülmektedir.

MIT-BIH veri bankasından alınan (slp32, slp37, slp41, slp45, slp48) EKG kayıtlarına, α değeri 0.5, 1.0, 1.5 seçilerek oluşturulan yapay gürültüler ilave edilmiş ve bunlar sisteme giriş veri olarak uygulanmıştır. Bunlara karşılık süzgeç çıkışlarından alınan sinyallere ait EKG bileşenlerini, genlik (mV) ve süre (sn) cinsinden incelenmiştir. Sonuçlarda görüldüğü üzere bütün süzgeç çıkışlarındaki EKG bileşen değerlerinin, α değeri arttıkça ideal değerlerden uzaklaştığı tespit edilmiştir.

Genel olarak deęerlendirildięinde Myriad süzgeçlerin her türlü α -baęımlı gürültülü durumda giriş işaretiinden gürültü işaretinin ayıklanması işleminde dięer süzgeçlere göre daha başarılı oldukları tespit edilmiştir. Yüzüncü yıl üniversitesinin EKG analizi için yaptığı araştırma sonuçları temel alınarak, süzgeç çıkışları MSE , GSY ve EKG bileşen deęerlerine göre kendi aralarında karşılaştırıldığında, Myriad süzgeç yapısının Median ve FIR süzgeç yapılarına göre daha iyi başarımlar sağladığı ortaya çıkmaktadır. Ayrıca sonuçlar, lineer bir yapı olmasına rağmen FIR süzgeç yapısı, Myriad süzgeç yapısından sonra en iyi sonuçları veren süzgeç yapısı olarak öne çıkmaktadır.

Bu tez araştırması, adaptif Myriad süzgeç performansının farklı öğrenme algoritmalar yardımıyla, artırılmasına yönelik çalışmalarla devam etmektedir.

KAYNAKLAR

1. Pander, T., P., A Suppression of an Impulsive Noise in ECG Signal Processing, Proceedings of the 26th Annual International Conference of the IEEE EMBS, San Francisco, CA, USA, 2004.
2. Kalluri, S., Nonlinear Adaptive Algorithms For Robust Signal Processing and Communications In Impulsive Environments, Doktora Tezi, University Of Delaware, 1998.
3. Zorlu, H., Özer, Ş., Bulanık Sinir Ağı Tabanlı Esnek Anahtarmalı Karma Süzgeç, ELECO 2006, Elektrik - Bilgisayar, 244-247,2006.
4. Tepe, C., Sezgin H., EKG Sinyallerinde Gürültü Gidermede Ayrık Dalgacık Dönüşümünde Farklı Ana Dalgacıkların ve Ayrıştırma Seviyelerinin Karşılaştırılması, Ulusal Kongre-2007.
5. Gonzalez, J., G., Arce G., R., Optimality of the Myriad Filter in Practical Impulsive-Noise Environments, IEEE Transactions on Signal Processing, 49, 2, 2001.
6. Kalluri, S., Arce, G.R., Adaptive Weighted Myriad Filter Algorithms For Robust Signal Processing In α -Stable Noise Environments, IEEE Trans. on Signal Processing, 46, 322-334, 1998.
7. Tönderstrom, S., System Identification, Prentice-Hall, 1989.
8. Lim, Y.C., Parker, S.R., On The Identification Of Systems From Data Measurements Using ARMA Lattice Models, IEEE Trans. Assp, 4, 824-827, 1986.
9. Gauss, K. F., Theory of the Motion of Heavenly Bodies, Dover, 1963.
10. Zadeh, L.A., From Circuit Theory to System Theory, Proc IRE, 50, 856-865, 1962.
11. Özer, Ş., Taşpınar, N., Güney, K., ARMA Modeli ile Ayrık Zamanlı Lineer Sistemlerin Modellenmesi, Bilkent Üni. Elektrik-Elektronik ve Bilgisayar Mühendisliği Konferansı Bildiri kitabı, 195-198, 1991.
12. Özer, Ş., Sağiroğlu, Ş., Kaplan, A., Performance Analysis of Algorithms on Linear ARMA Models, Proc. Of the Int. Symposium Computer and Information Science XVI, 445-451, 2001.
13. Graupe, D., Cline, WK., Functional Separation of EMG Signals via ARMA Identification. IEEE Trans. Syst. Man Cybern ;5, 252-259, 1975.

14. Sherif, Mh., Stochastic Model of Myoelectric Signals for Movement Pattern Recognition in Upper Limb Prostheses, Ph.D. thesis, School of Engineering and Applied Sciences, University of California at Los Angeles, 1980.
15. Doerschuk, PC., Gustafson, W., Upper Extremity Limb Function Discrimination Using EMG Signal Analysis, IEEE Trans. Biomed. Eng.; 30,18-38, 1983.
16. Zhou, Y., Chellappa, R., Bekey, G., Estimation of Intramuscular EMG Signals From Surface EMG Signal Analysis, IEEE International Conference on Acoustics, Speech, and Signal Processing; 11,1805-1808, 1986.
17. Hefftner, G., Zucchini, W., Jaros, G., The Electromyogram (EMG) as a Control Signal For Functional Neuro-muscular Stimulation Part 1: Autoregressive Modeling as a Means of EMG Signature Discrimination, IEEE Trans. Biomed. Eng. 35,230-237, 1988.
18. Bernatos, L., Crago, P., Chizeck, H., A Discrete-time Model of Alectricity Stimulated Muscle, IEEE Trans. Biomed. Eng. 33,829-838,1986.
19. Tohru, K., Investigation of Parametric Analysis of Dynamic EMG Signals by a Muscle-structured Stimulation Study, IEEE Trans. Biomed. Eng. 39,280-288,1992.
20. Widrow, B., Stearns, D., Adaptive Signal Processing, Prentice Hall, 1985.
21. Rauf, F., Nonlinear Adaptive Filtering : A Unified Approach, Ph.D. Thesis, Boston University, Boston, 1993.
22. Zhang, P., Song Y., Discrete Frequency-domain Modeling and Measuring of Mildly Nonlinear of Volterra Transfer Functions with a Set of Special Sinusoid Signals, IEEE Pacific Rim Conference on Communications, Computers and Signal Processing ,1989 .
23. Ning, T., Shiming, A. N., A Comparison of Linear and Nonlinear Modelling of The Hippocampal EEG, Biomedical Engineers Proceedings of the 16th Annual International Conference of the IEEE 1,221 - 222, 1994.
24. Stathaki, .T., Blind Volterra Signal Modelling, IEEE ICASSP-96 International Conference ,3,1601 - 1604, 1996.
25. Xu, Y., L., Zhiang, Y., T., Identification of EMG-Force System Using the Second-Order Volterra Model ,Engineering in Medicine and Biology Society, Proceedings of the 18th Annual International Conference of the IEEE 2, 569 - 570, 1996.
26. Stathaki, T., Two Dimensional Blind Volterra Signal Modelling for Texture Feature Extraction Using Nonlinear Constrained Optimisation ,Signals, Systems & Computers, 1998. Conference Record of the Thirty-Second Asilomar Conference , 2,979 – 983, 1998.

27. Bardakjan, B., L., Karlson, P., and Courville, A., A Parallel Nonlinear-Linear Nueronal Model , Engineering in Medicine and Biology, 21st Annual Conf.,1, 397 , 1999.
28. Hirafuji, Tanaka K., Hagan, S., Lotka-Volterra Machine for a General Model of Complex Biological Systems, Computer Aided Control System Design, Proceedings of the 1999 IEEE International Symposium 2,516 – 521, 1999.
29. Jo, J., A., ark. , Detection Of Autonomic Abnormality In Obstructive Sleep Apnea Using A Nonlinear Model Of Heart-Rate Variablility, Engineering in Medicine and Biology, 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society] EMBS/BMES Conference, 2, 1554- 1555, 2002.
30. Aoki, Y., ark., An Optimal Term Selection Scheme for The Volterra System Model Applied To The Analysis Of Heart Rate Fluctuations, Engineering in Medicine and Biology, 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society] EMBS/BMES Conference, 1, 220- 221, 2002.
31. Georgios, D., ark., Nonlinear Modeling of the Dynamic Effects of Arterial Pressure and CO2 Variations on Cerebral Blood Flow in Healthy Humans, IEEE Transaction on Biomedical Engineering, 51,11,2004.
32. Mohler, R., R., Tang, Z., On Biliner Time-Series Modelling and Estimation, Decision and Control , Proceedings of the 27th IEEE Conference 2, 953-954 , 1988.
33. David, J., C., ark., Application of Linear and Nonlinear Time Series Modeling to Heart Rate Dynamics Analysis, Biomedical Engineering, IEEE Transactions 42,24-26, 1995 .
34. Ito, K., ark., Compliance control of an EMG-controlled prosthetic forearm usingultrasonic motors , Intelligent Robots and Systems '94. 'Advanced Robotic Systems and the Real World', IROS '94. Proceedings of the IEEE/RSJ/GI International Conference 3,1816-1823 , 1994.
35. Hazarika, N., Sergejew, T., A., Nonlinear Considerations in EEG Signal Classification Signal Processing, IEEE Transactions 45,33-35, 1995.
36. Isernia, T., Pascazio, V., Pierri, R., Tomographic Imaging Via Non Linear Estimation: A Bilinear Approach Geoscience and Remote Sensing, IEEE Transactions on vol:35, 1997.
37. Ledzewicz, U., Schattler, H., Analysis of a Class of Optimal Control Problems Arising in Cancer Chemotherapy” Int. J. Appl. Math. Comput. Sci., 13, 357–368,2003.

38. Ledzewicz, U. Schattler, H. "Optimal Control for a Bilinear Model with Recruiting Agent in Cancer Chemotherapy" Decision and Control, 2003. Proceedings. 42nd IEEE Conference 3, 2762- 2767, 2003
39. Jain, S., Deshpande, G., Parametric Modeling of Brain Signals, Biotechnology and Bioinformatics, Proceedings. Technology for Life: North Carolina Symposium 4,85–91, 2004.
40. Fangzhi, G., ark., Application of Bilinear Quadrilateral Modeling to EM Scattering Problems, Microwave Conference Proceedings, APMC 2005. Asia-Pacific Conference Proceedings 2,3,2005.
41. Dyrholm, M., Parra, L.C., Smooth Bilinear Classification of EEG, Engineering in Medicine and Biology Society, EMBS '06. 28th Annual International Conference of the IEEE 14,4249 – 4252, 2006.
42. Christini, D.J., ark., Time Series Modeling of Heart Rate Dynamics, Biomedical Engineering IEEE Transactions on 42 ,134-136, 1995.
43. Jain, S., Deshpande, G., Parametric Modeling of Brain Signals Biotechnology and Bioinformatics, Proceedings. Technology for Life: North Carolina Symposium 3,85 – 91, 2004.
44. Gonzalez, J.G., Arce, G.R., Optimality of the Myriad Filter in Practical Impulsive-Noise Environments, IEEE Transactions on Signal Processing, 49,2,2001.
45. Khurram, M. U., Fast Learning Nonlinear Adaptive Filtering Structures, Ph.D. Thesis, University Of Boston, 1994.
46. Koh, T., Powers, E. J., Scnd Order Volterra Filtering and Its Application to nonlinear system identification, IEEE Trans. on ASSP, 33, 1445-1455, 1985.
47. Mathews, V.J., A Fast Recursive Least Squares Adaptive Nonlinear Filter, Proceedings Of 21st Asimolar Conference on Systems, Signals and Computers, Pacific Grove, California,1987.
48. Haykin, S., Adaptive Fitler Theory, Prentice-Hall, 1986.
49. Thakor , N.V., Zhu , Y.S., Applications of adaptive filtering to ECG analysis : Noise cancellation and arrhythmia detection, IEEE Trans.Biomedical Engineering, 38,785-794,1991.
50. Hamilton , P.S., A Comparison of Adaptive and Nonadaptive Filters for Reduction of Power Line Interference in the ECG , IEEE Trans. Biomedical Engineering,43,105-109, 1996.

51. Velasco, M., B., Weng , B., Barner K.E., A New ECG Tests, in Proc. 2006 Computers in Cardiology conference, Valencia, Spain, 3, 917-920, 2006.
52. Wu, Y. F., Rangayyan, R.M., An Unbiased Linear Artificial Neural Network with Normalized Adaptive Coefficients for Filter in Noisy ECG Signals, in Proc. 20th Canadian Conf. Electrical and Computer Eng., Canada, 2007.
53. Olmos , S., and Laguna, P., Steady-state MSE Convergence of LMS adaptive Filters with Deterministic Reference Inputs with Applications to Biomedical Signals, IEEE Trans. Sign. Proces., 48, 2229-2241, 2000.
54. Olmos , S., and Laguna, P., Symmo, L., Block, LMS Adaptive Filter with Deterministic Reference Inputs for Event-related Signals, Proceedings of the 23rd Annual EMBS International Conference, 23, 1828-1831, 2001.
55. Haykin , S., Adaptive Filter Theory. New Jersey: Prentice-Hall, 1996.
56. Kepski , R., Cytowski , J., Buchner , T., Adaptive Filtering in Dynamically Changing High Resolution ECG, International Conference on Information, Communications and Signal Processing ICICS '97 Singapore, 1997.
57. MejiaGarcia, Ark., Adaptive Cancellation of The ECG Interference in External Electroenterogram, Proceedings of the 25 Annual International Conference of the IEEE EMBS Cancun, Mexico September 25, 17-21, 2003.
58. Yelderman, M., ECG Enhancement by Adaptive Cancellation of Electrosurgical Interference, IEEE Tran. on Biomedical Engineering, 30, 7, 1983.
59. Cyrill , D., McNames, J., Aboy , M., Adaptive Comb Filter for Quasi-Periodic Physiologic Signals, Proceedings of the 25th Annual International Conference of the IEEE EMBS Cancun, Mexico September 25, 17-21, 2003.
60. Weiting, Y., Runjing Z., An Improved Self-Adaptive Filter Based on LMS Algorithm for Filtering 50Hz Interference in ECG Signals The Eighth International Conference on Electronic Measurement and Instruments ICEMI , 2007.
61. Philips, W., Adaptive Noise Removal from Biomedical signal Using Warped Polynomials", IEEE Tran. On Biomedical Eng., 43, 5, 1996.
62. Jiyin, Z., Jianpo, Li., Application of Variable step LMS Algorithm Based on Iterative Time in ECG Signal, Abstraction Bioinformatics and Biomedical Engineering, ICBBE 2008, The 2nd International Conference , 2, 2266-2269, 2008.
63. Widrow B., Adaptive Noise Cancelling Principle and Applications , Proceeding of the IEEE , 63, 1692-1716, 1975.

64. Raoof, K., Gumery, P. Y., Levy, P., Filtering of Nonstationary Electromyographic Signals of Respiratory Muscles, *Innovation et Technologie et Medicine*, 13, 77-89, 1992
65. Valtino X. A., Tompkins, W. J., Nguyen, T. Q., Comparing Stress ECG Enhancement Algorithms, *IEEE Engineering In Medicine and Biology* ,2, 739-751 , 1996
66. Lee, A. G., Y. D., Chung , W. Y., ECG Signal Denoising with Signal Averaging and Filtering Algorithm, *IEEE Third 2008 International Conference on Convergence and Hybrid Information Technology*, 2008
67. Yacoub, S., Gumery, P., Raoof, K., A Novel Signal Processing Method For Multi-Electrode Surface Electromyography , *IEEE* vol. 2, pp. 1336-1337 , 1994
68. Östlund, N., Wiklund, U., Yu, J., Karlsson, J.S., Adaptive Spatio-Temporal Filtration of Bioelectrical Signal, *IEEE Engineering in Medicine and Biology 27th Annual Conference* , 2005
69. Alty, S., Man W. D., Moxham, J., Lee, K. C., Denoising of Diaphragmatic Electromyogram Signals for Respiratory Control and Diagnostic Purpose, *IEEE 30th Annual International EMBS Conference Vancouver*, 30, 20-24, 2008
70. Chang, F.C., Chang, C.K., Chi, K.Y., Lin, Y.D., Evaluation Measures for Adaptive PLI Filters in ECG Signal Processing , *Computers in Cardiology* ,34, 529–532, 2007
71. Jane, R., Laguna, P., Caminal, P., Adaptive Baseline Wander Removal in The ECG; Comparative Analysis with Cubic Spline Technique, *Computers in Cardiology*, 143-146, 1992.
72. Kim, H.D., Min, C.H., Kim, T.S., Adaptable Noise Reduction of ECG Signals for Feature Extraction, *Lecture Notes in Computer Science*, 3973,586-591, 2006
73. Marque, C., Bisch, C., Dantas, R., Elayoubi, Brosse, V., Perot, C., Adaptive Filtering for ECG Rejection from Surface EMG Recordings, *Journal of Electromyography and Kinesiology*,15, 310-315, 2005
74. Zhang, N., Investigation of Fault-Tolerant Adaptive Filtering for Noisy ECG Signals, in *Proceedings of the 2007 IEEE Symposium on Computational Intelligence in Image and Signal Processing*, 177-182, 2007
75. Kalluri, S., Arce, G.R., Adaptive Weighted Myriad Filter Algorithms For Robust Signal Processing In α -Stable Noise Environments, *IEEE Trans. on Signal Processing*, 46, 322-334, 1998.

76. Pitas , L., Venetsanopoulos, A., Order Statistic in Digital Image Processing , Proc.IEEE 80,14-17,1992.
77. Kalluri, S., Arce, G.R.,Fast Algorithms for Weighted Myriad Computation by Fixed-Point search, IEEE Trans. Signal Processing ,48,159-171,2000.
78. Kalluri, S., Arce, G.R.,Robust Frequency Selective Filtering Using Weighted Myriad Filters Admitting Real valued weights, IEEE Trans.Signal Processing, 49,2721-2733,2001.
79. Arce, G.R., A General Weighted Median Filter Structure Admitting Negative Neights, IEEE Trans.Signal Processing,46,3195-3205,1998.
80. Shmulevich , Arce ,G.R., Spectral Design of Weighted Median filters Admitting Negative Weights, IEEE Trans.Signal Processing,8, 313-316,2001.
81. Arce ,G.R. and Parades, J.L., Recursive Weighted Median Filters Admitting Negative Weights and Their Optimization, IEEE Trans.Signal Processing,48,768-779,2000.
82. Yin , L., Yang ,R., Gabbouj ,M., Weighted Median Filters: A Tutorial “,IEEE Trans. Circuit System2 ,43,122-124,1996.
83. Brownrigg , D., The Eighted Median Filter, Commun. Assoc.Computer, 807-818,1984.
84. Ko ,S.J., Lee , S.J. ,,Center Weighted Median Filters and Their Applications to Image Enhancement, IEEE Trans. Circuit Sys. ,15,984-993,1991.
85. Sun, T., Neuvo, Y., Detail-preserving Median Based Filters in Image Processing,Pattern Recognit.Lett ,15,341-347,1994 .
86. Florencio, D., Schafer, R., Decision-based median fitler using local signal statistics, in Proc.Spie Int. Symp. Visual Communications Image Processing, 1994.
87. Arce, G.R.,Nonlinear Signal Processing: A Statistical Approach,NewYork,2005.
88. Hassouni ,M.E, Cherifi, H., Spatio Temporal Weighted Myriad Filter for Alpha Stable Noise Removal in Video Squences “ in ICSES04 Int. Conf.Signals and Electronic Syst. Poznan,2004.
89. Ganguli ,R., Surender ,V.P., Adaptive Myriad Filter For Improved Gas Turbine Condition Monitoring Using Transient Data ,ASME Turbo Expo 2004,Vienna ,2004.
90. Hamza ,A., Krim, H., Image Denoising : A Nonlinear Robust Statistical Approach, IEEE Trans. Signal Process. ,49,3045 -3054, 2001.
91. Kalluri ,S., Arce, G.R., Adaptive Weighted Myriad Filter Optimization for Robust Signal Processing, in Proc. 1996 CISS, Princeton, NJ, 1996.

92. PANDER, T., An Application of Robust Filters in ECG Signal Processing , Journal of Medical Informatics Technologies ,10,1642-6037, 2006
93. PANDER, T., Application of Weighted Myriad Filters to Suppress Impulsive Noise., in Biomedical Signals Task Quarterly ,8, 199–216, 2004
94. PANDER, T.,The Class of M-filters in the Application of ECG Signal Processing, Biocybernetics and Biomedical Engineering, 26, 3–13, 2006
95. Raphisak, P., Schuckers, S.C., Jongh, A., An Algorithm for EMG Noise Dedection in Large ECG Data , Computers in Cardiology, 369- 372, 2004
96. Chen, Y., Duan, H., A QRS Complex Detection Algorithm Based on Mathematical Morphology and Envelope, in Proceedings of the 27th IEEE Annual Conference on Engineering in Medicine and Biology, 4654-4657, 2005
97. Sun, P., Wu, Q., Weindling, A.M., Finkelstein, A., Ibrahim, K., An Improved Morphological Approach to Background Normalization of ECG Signals, IEEE Transactions on Biomedical Engineering, 50, 117-121, 2003
98. Guglielminotti, P., Merletti ,R., Effect of Electrode Location on Surface Myoelectric Signal Variables: a Simulation Study, 9th Int. Congress of ISEK; Florence, Italy, 1992.
99. Laterza, F., Olmo, G., Analysis of EMG Signals by Means of The Matched Wavelet Transform. Electronics Letters; 33,357-359, 1997.
100. Pattichis, C.S., Pattichis, M.S., Time-scale Analysis of Motor Unit Action Potentials, IEEE Trans Biomed Eng; 46,1320-1329, 1999.
101. Mallat ,S., A Wavelet Tour of Signal Processing, Academic Press, 1999
102. Nibhanupudi ,S., Signal Denoising Using Wavelets, Ph.D. dissertation, University of Cincinnati, 2003.
103. Chmelka ,L. Kozumplik ,J., Wavelet-based Wiener Filter for Electrocardiogram Signal Denoising,. Computers in Cardiology, 32, 771-774, 2005.
104. Agante, P.M., de Sá , J.P.M., ECG Noise Filtering Using Wavelets with Soft-thresholding Methods,. Computers in Cardiology, 26, 535-538, 1999.
105. Xu , L., Zhang , D., Wang ,K., .Wavelet-based Cascaded Adaptive Filter for Removing Baseline Drift impulse Waveforms, IEEE Trans. Biomed. Eng., 53, 1973-1975, 2005.
106. Ye ,W., Yungfeng, W.,Yachao Z., Ruifan L. ,A Wavelet Method for the noise Redution in Electrocardiographic Signals, Proceedings of the 2007 International Conferenceon Wavelet Analysis and Pattern Recognition,China, 2007.

107. Elena, MM., Quero, JM., Borrego, I., An optimal Technique for ECG Noise Reduction in Real Time Application ,Computer in Cardiology ,33,225-228, 2006.
- 108.Eloumi, A., Lachiri, Z., Denoising Ecg Contaminated with Emg Components Cased on Pitch Synchronous Wavelet Analysis, In Proceedings of the IEEE International Conference on Industrial Technology, 3, 1660–1663, 2004
- 109.Shantha, R., Kumari, S., Thilagamanimala, A.,Sadasivam, V., ECG Signal Interferences Removal Using Wavelet Based CSTD Technique, International Conference on Computational Intelligence and Multimedia Applications ,1, 530-534, 2007.
- 110.Taelman, J., Huffel, S. V., Wavelet Independent Component Analysis to Remove Electrocardiography Contamination in Surface Electromyography, 29th Annual International Conference of the IEEE Publication, 29, 682-685, 2007
- 111.Conforto, S., Pignatelli, S., Optimal Rejection of Movement Artefacts form Myoeletric Signals by Means of A Wavelet Filtering Procedure. Journal of Electrophysiology and Kinesiology, 9, 47-57 , 1999
- 112.Zhou, P., Kuiken, T. A., Elimination of ECG Artifacts from Myoelectric Control Signals Developed by Targeted Muscle Reinnervation”, Physiol. Meas., 27, 1311–1327, 2006.
- 113.Singh, B.N., Tiwari, A.K., Optimal Selection of Wavelet Basis Function Applied to ECG Signal Denoising , Digital Signal Processing, 16, 275-287, 2006
- 114.Zhang, J., Shou, G., Dai, G., Denoising of ECG Signals Based on Wavelet Transform, Journal of Northwestern Polytechnical University, 23, 11-14, 2005
- 115.Zhang, D., Wavelet Approach for ECG Baseline Wander Correction and Noise Reduction , Annual International Conference of the IEEE Engineering in Medicine and Biology Proceedings , 1212-1215 , 2005
- 116.Bazhyna, A., Gotchev, A., Christov, I., Noninvasive His-Bundle Electrocardiogram Toward Beat-to-Beat Electromyogram Noise Removal, Computers in Cardiology ,30 ,545-548 , 2003
- 117.Nikolaev, N., Nikolov, Z., Gotchev, A., Wavelet Domain Wiener Filtering for ECG Denoising Using Improved Signal Estimate. Proceedings of Int. Conf. Acoustics, Speech and Simal Processing, 2210-2213, 2000
- 118.Nikolaev, N., Gotchev, A., ECG Simal Denoisine Usine Wavelet Domain Wiener Filtering, PGeedings of the European Signal Processing Conf EUSIPCO, 5, 51-55, 2000

- 119.Nikolaev, N., Nikolov, Z., Gotchev, A., Egiazarian, K., Wavelet Domain Wiener Filtering for ECG Denoising Using Improved Signal Estimate, IEEE International Conference on Acoustics, Speech, and Signal Processing, 6 , 3578–3581, 2000
- 120.Ghael, S.P., Sayeed, A.M., Baraniuk, R.G., Improved Wavelet Denoising via Empirical Wiener Filtering , In Proc. of SPIE, 3169 , 389–399, 1997
- 121.Lee, T.W., Girolami, M., Sejnowski, T.J., Independent Component Analysis Using an Extended Algorithm for Mixed Subgaussian and Supergaussian Sources, Neural Computation ,11, 417-441, 2003
122. Djuwari, D., Kuamr, D.K., Ragupathy, S.C., Polus, B., Multi-Step Independent Component Analysis for Removing Cardiac Artefacts from Back SEMG Signals, Anziis , 35- 40, 2003
- 123.Joseph, N.F., Hu, Y., Luk, K.D.K., ICA-Based ECG Removal from Surface Electromyography and Its Effect on Low Back Pain Assessment, Proceedings of the 3rd International IEEE EMBS Conference on Neural Engineering, 2007
- 124.Cao, Y., Chen, C., Hu, Y., Application of Independent Component Analysis to ECG Cancellation in Surface Electromyography Measurement, Journal Biomedical Engineering, 22, 686–689, 2005.
- 125.Zhang, Z., Enomoto, T., Horiata, S., ICA Using Wavelet Transform and its Application to Biological Signals , Proceedings of the 2008 International Conference on Wavelet Analysis and Pattern Recognition, Hong Kong, 2008
- 126.Zhang, J., and Morris, A.J., Fuzzy Neural Network for Nonlinear System Modelling. IEEE Proceedings, Control Theory Applications, 42, 551-561, 1995.
- 127.Del Boca, A., Park, D.C., Myoelectric Signal Recognition Using Fuzzy Clustering and Artificial Neural Networks in Real Time, IEEE International Conference on Neural Networks and IEEE World Congress on Computational Intelligence, 5,3098-3103, 1994.
- 128.Vijila, C.K.S., Kumar, C.E.S., Cancellation of ECG in Electromyogram Using Back Propagation Network, International Conference on Advances in Recent Technologies in Communication and Computing , 2009
- 129.Kumar, D.K., Polus, B., Relationship of Magnitude of Electromyogram of the Lumbar Muscles to Static Posture Ragupathy, Proceedings of the 26th Annual International Conference of the IEEE EMBS ,26,7803-7807, 2004

130. Azzerboni, B., Carpentieri, M., Foresta, F.L., Morabito, F.C., Neural-ICA and Wavelet Transform for Artifacts Removal in EMG, in Proc. Of the IEEE International Joint Conference on Neural Networks, 4, 3223–3228, 2004
131. Zhou, P., Lock, B., Kuiken, T.A., Real Time ECG Artifact Removal for Myoelectric Prosthesis Control, Physiological Measurement., 28, 397– 413, 2007.
132. Rhou , B., Sawan, M., Desilets, T., Real-time Filtering Technique to Remove ECG Interference from Recorded Esophageal EMG , IEEE BioCAS , 2008.
133. Pan, J., Tompkins, W.L., A Real-Time QRS Detection Algorithm, in IEEE Biomedical Engineering , 32, 230–236, 1985
134. Callaghan, Frank J., Automatic Function in Cardiac Pacing: Optimization of Device and Patient Therapy, IEEE Engineering in Medicine and Biology, 28-31, 1990.
135. Smith, B., An Externally Powered, Multichannel , Implementable Stimulator-Telemeter for Control of Paralyzed Muscle, IEEE Transaction On Biomedical Engineering, 45, 463-475, 1998.
136. Arabi, K., Sawan, M.A., Electronic Design of a Multichannel Programmable Implant for Neuromuscular Electrical Stimulation, IEEE Transactions On Rehabilitation Engineering, 7 , 204-214, 1999.
137. Kaczmarek, K.A., A 16-Channel 8-Parameter Waveform Electrotactile Stimulation System , IEEE Transactions On Biomedical Engineering, 38, 933-942, 1991.
138. Jane, R., Caminal, P., Laguna ,P., Alignment Methods for Averaging of High-Resolution Cardiac Signals : a Comparative Study of Performance, IEEE Transactions on Biomedical Engineering, 38 , 571-579, 1991.
139. Cobbold, R. S. C., Transducers for Biomedical Measurements: Principles and Applications, John Wiley & Sons, Inc., New York, 1974.
140. Welkowitz, W., Biomedical Instruments, Theory and Design, Academic Press, New York, 1976.
141. Webster, J. G. (Ed.) , Medical Instrumentation, Application and Design, Houghton Mifflin Company, Boston, 1978.
142. Chan, U.F., Chan, W.W., Pun, S.H., Vai, M., Mak P.U., Flexible Implementation of Front-end Bioelectric Signal Amplifier Using FPAA for Telemedicine System, Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society, 3721-3724, 2007.
143. Korürek, M., Tıp Elektroniğinde Tasarım İlkeleri, İstanbul, İTÜ Yayınları, 1996.

- 144.Saxena , S.C., Kumar , V., Hamde , S.T., Feature Extraction from ECG Signals Using Wavelet Transforms for Disease Diagnostics,International Journal of Systems Science, 33, 1073-1085, 2002.
- 145.Bulduk, B., Kılıçalp, D., Sigara İçen Erkeklerde Arteriyal Kan Basıncı, Kalp Atım Sayısı ve EKG Değerlerindeki Değişikliklerin Belirlenmesi , Yüzüncü Yıl Üniversitesi, Sağlık Bilimleri Dergisi, Cilt 9, Sayı 2, Sayfa 68-74, 2006
- 146.Kemaloğlu, S., Kalp Seslerinin EKG İşareti ile Eş Zamanlı Alınması ve Bilgisayarla Analizi , Erciyes Üni.Yüksek Lisans Tezi ,2001
- 147.Kara , S., EKG İşaretlerinin Algılanması ve Bilgisayar ile Görüntülenmesi, Erciyes Üni. Yüksek Lisan Tezi, 1991.
- 148.Reaz , M. B. I., Hussain , M. S., Mohd-Yasin ,F., Techniques of EMG Signal Analysis: Detection, Processing, Classification and Applications Biol. Proced. Online 8, 11-35,2006
- 149.Shahid, S., Higher Order Statistics Techniques Applied to EMG Signal Analysis and Characterization, Ph.D. thesis, University of Limerick; Ireland, 2004.
- 150.Nikias, CL., Raghuveer, MR., Bispectrum Estimation: A digital Signal Processing Framework, IEEE Proceedings on Communications and Radar; 75,869-891, 1987.
- 151.Basmajian. JV., de Luca, CJ., Muscles Alive -The Functions Revealed by Electromyography, The Williams & Wilkins Company; Baltimore, 1985.
- 152.Rodriguez, I., Malanda, A., Gila, L., et al., Filter design for cancellation of baseline – fluctuation in needle EMG recordings, Comput. Meth. and Prog. in Biomed., 81, 79-93, 2006.
- 153.Okkesim ,Ş., Ortodontik Anormallikler Bulunan Hastalarda Kullanılan “Pre Ortodontik Trainer” Apareninin Çene ve Ağız Çevresindeki Kaslara Olan Etkisini Emg Kayıtlarıyla Değerlendirilmesi, Erciyes Üniversitesi Yüksek Lisans Tez ,2006.
- 154.Gabor, D., Theory of Communication, J. Inst. Elect. Eng. 93,429-457, 1946.
- 155.Ismail, AR., Asfour, SS., Continuous Wavelet Transform Application to EMG Signals During Human Gait, Thirty-Second Asilomar Conference on Signals, Systems & Computers; 1,325-329, 1998.
- 156.Cheron, G., Draye, JP., Bourgeois, M., A Dynamic Neural Network Identification of Electromyography and Trajectory Relationship During Complex Movements, IEEE Trans Biomed Eng; 43,552- 558, 1996.

157. Belouchrani, A., Abed Meraim, K., Amin, MG., Joint-Antidiagonalization for Blind Source Separation, *Procedures in ICASSP*, 2789- 2792, 2001.
158. Farina, D., Fevotte, C., Doncarli, C., Merletti, R., Blind Separation of Linear Instantaneous Mixtures of Nonstationary Surface Myoelectric Signals, *IEEE Trans. Biomed. Eng.*, 51,1555-1567, 2004.
159. Giannakis, GB., Tsatsanis, MK., HOS or SOS for parametric modeling Procedures, *IEEE Int. Conf. Acoustics Speech Signal Process*, 5,3097-3100, 1991.
160. Yana, K., Mizuta, H., Kajiyama, R., Surface Electromyogram Recruitment Analysis Using Higher Order Spectrum, *IEEE 17th Annual Conference on Engineering in Medicine and Biology Society*, 2,1345-1346, 1995.
161. Nikias, CL., Petropulu, AP., *Higher-Spectral Analysis: A Nonlinear Signal Processing Framework*, Prentice Hall; New Jersey, 1993.
162. Nikias, CL., Mendel, JM., *Signal Processing with Higher-Order Spectra*, *IEEE Signal Processing Magazine*, 10,10-37, 1993.
163. Kaplanis, PA., Pattichis, CS., Hadjileontiadis, LJ., Bispectral Analysis of Surface EMG. *10th Mediterranean Electrotechnical Conference*, 2,770-773, 2000.
164. Zorlu, H., Doğrusal Olmayan Sistemlerin Yapay Sinir Ağları Kullanılarak Modellenmesi, Yüksek Lisans Tezi, Erciyes Üniversitesi, Kayseri, 2004.
165. Lee, J., Mathews, V.J., A Stability Condition For Certain Bilinear Systems, *IEEE Trans. on Signal Processing*, 42, 1871-1873, 1994.
166. Takagi, T., Fuzzy Identification of Systems and It's Application to Modelling and Control, *IEEE Transactions, SMC*, 15, 116-132, 1985.
167. Kaplan, A., Nümerik Tabu Arama Algoritması, Doktora Tezi, Erciyes Üni., Kayseri, 2000.
168. Candy, J.V., *Signal Processing: The model-based Approach*, Mc Graw Hill, 1986.
169. Cioffi, J., Kailath, T., Fast Recursive Least Squares Transversal Filters for Adaptive Processing, *IEEE Trans. Acoust., Speech, Signal Processing*, 34, 304- 307 ,1984.
170. Honig, H.L., Messerschmitt, D.G., *Adaptive Filters Structures, Algorithms and Applications*, Kluwer Academic Publishers, Berlin, 1995.
171. Ljung, L., *System Identification: Theory For The User*, Englewood Cliffs, NJ., Rentice Hall, 1987.
172. Goodwin, K., *Adaptive Filtering , Prediction and Control* , Prentice-Hall, 1990

173. Kim, P.S., Kwon, W.H., Forgetting least squares estimation FIR filters without noise covariance information, SICE 2000. Proceedings of the 39th SICE Annual Conference. International Session Papers,1-6, 2000
174. Shao ,M., Nikias , C.L., Signal Processing with Fractional Lower Order Moments: Stable Processes and Their Applications Proceedings of the IEEE,81,33-37,1993.
- 175.Zolotarev ,V., One Dimensional Stable Distributions , Providence R.I.American Mathematical Society,1986.
- 176.Edgeworth , F.Y., A new Method of Reducing Observations Relating to Several Quantities, Phil. Mag. (Fifth Series), 24, 45-48, 1887.
- 177.Lee , K.D., Lee , Y. H., Threshold boolean filters, IEEE Trans. Signal Processing, 42,32-37,1994.
- 178.Li.Y, Arce, G.,A., Fellow, Weighted Median Filters for Multichannel Signals ,IEEE Trans. on Signal Processing, 54, 12-15, 2006.
- 179.Arce , G. R., Nonlinear Signal Processing A Statistical Approach, Book, 2005.
- 180.Bendat, J.S., Piersol, A.G., Random Data Analysis And Measurement Procedures, John Wiley Sons, Inc., USA, 1986
- 181.Newland, D.E., An Introduction To Random Vibrations, Spectral , Wavelet Analysis, Longman, UK, 1997.
- 182.Candy, J.V., Signal Processing: The Modern Approach, McGraw-HillBook Co., USA, 1988.
- 183.[www.physionet.org / Database.](http://www.physionet.org/)
- 184.P.G. Georgiou, P. Tsakalides, Ch. Kyriakakis, Alpha-stable modeling of noise and robust time-delay estimation in the presence of impulsive noise, IEEE Trans. On Multimedia, 1,291-301,1999.
- 185.Galin, L., Messer, H., Robust Processing of Heavy Tails Signals-comparison of Approaches, Statistical Signal and Array Processing, Proceedings., 8th IEEE Signal Processing Workshop , 1996.
- 186.Mitra S., Mitra M. , Chaudhuri, B., Pattern defined heuristic rules and directional histogram based online ECG parameter extraction , Science Direct,Measurement 42 , 150-156, 2009.

ÖZGEÇMİŞ

Selçuk Mete, 1983 yılında Kayseri’ de doğdu. İlk, orta ve lise öğrenimini Kayseri’ de çeşitli okullarda tamamladı. 2001 yılında girdiği Erciyes Üniversitesi Mühendislik Fakültesi Elektronik Mühendisliği Bölümü’ nden 2006 yılında mezun olarak mühendis ünvanını kazandı. Aynı yıl Erciyes Üniversitesi Fen Bilimleri Enstitüsü Elektronik Anabilim Dalı’ nda Yüksek Lisans öğrenimine başladı. 2006 yılı sonunda itibaren yaklaşık 2,5 yıl kadar özel bir firmada Network ve Sistem Mühendisi olarak çalıştı ve 2008 yılından itibaren Kayseri Türk Telekom’un Bilişim Ağları Müdürlüğü’nde Network Mühendisi olarak görevine devam etmektedir.

Tel : 0 352 555 12 59
E-posta : selcuk.mete@turktelekom.com.tr
Adres : Türk Telekom A.Ş / KAYSERİ