

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

**ELEKTROMİYOGRAF İŞARETLERİNİN
YAPAY SİNİR AĞLARI İLE İNCELENMESİ**

Elektrik-Elektronik Mühendisi Mustafa ÖZSERT

**FBE Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Elektronik Programında
Hazırlanan**

YÜKSEK LİSANS TEZİ

Tez Danışmanı: Prof. Dr. Tülay YILDIRIM

İSTANBUL, 2007

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	IV
KISALTMA LİSTESİ	V
ŞEKİL LİSTESİ	VI
ÇİZELGE LİSTESİ	VIII
ÖNSÖZ	X
ÖZET	XI
ABSTRACT	XII
1. GİRİŞ.....	1
1.1 Çalışmanın Amacı	1
2. ELEKTROMİYOGRAM (EMG) İŞARETİ.....	3
2.1 EMG işareti literatürü	3
2.2 EMG işaretlerinin temel kavramları	4
2.2.1 Kasların Yapısı	4
2.2.2 Motor ünite	5
2.2.3 Kas kasılması	6
2.2.4 Kaslarda Servomekanizma	7
2.2.5 Kas Hareketi Sırasında Üretilen Gerilim	8
2.3 EMG işaretlerinin algılanması	8
2.3.1 EMG ölçüm düzeneği	8
2.3.1.1 Elektrotlar	9
2.3.1.2 Elektrotun Devre Modeli	11
2.3.1.3 Elektrot çeşitleri	12
2.4 Biyolojik işaretlerin ölçümü ve teşhisinde işaret işlemenin yeri	17
2.5 Biyolojik işaretlerin sınıflandırılması	18
2.6 EMG işaretlerinin analizi.....	19
2.6.1 Modelleme	19
2.6.2 Zaman Domeni Analizi.....	20
2.6.3 Frekans Domeni Analizi	21
2.7 EMG işaretlerinin uygulama alanları.....	22
3. EMG İŞARETİNİN KAYIT TEKNİĞİ ve MODELLENMESİ	23
3.1 Biceps kası görevleri ve EMG işaretinin kayıt teknikleri.....	26
3.2 Frontalis kası görevleri ve EMG işaretinin kayıt teknikleri	28
3.3 Abductor Pollicis Brevis kası görevleri ve EMG işaretinin kayıt teknikleri	30
3.4 EMG İşaretlerinin Parametrik Modellenmesi.....	32

3.4.1	Durağan Süreçler ve Modeller.....	32
3.4.2	Ayrık – Zaman Stokastik Süreçlerin Kısmi Karakterizasyonu.....	33
3.4.3	Korelasyon Matrisi	34
3.5	Stokastik Modeller.....	38
3.5.1	Öz bağımlı (Autoregressive) Modeller	39
3.5.1.1	Analiz metodu.....	40
3.5.1.2	Sentez modeli.....	41
3.5.2	Hareketli Ortalama (Moving Average) Modeller	42
3.5.3	Öz Bağımlı Hareketli Ortalama (Autoregressive-Moving Average) Modeller	43
3.5.4	Wold Ayrıştırması	44
3.5.5	Öz Bağımlı Sürecin Korelasyon Fonksiyonu	46
3.5.6	Öz Bağımlı Modellerin Karakterizasyonu.....	46
3.5.7	Yule-Walker Denklemleri	47
3.6	Kaydedilen EMG İşaretlerinin Öz Bağımlı Metot İle Modellenmesi.....	47
3.6.1	Biceps Kasının Öz Bağımlı Model ile Parametrik Modellenmesi.....	48
3.6.2	Frontalis Kasının Öz Bağımlı Model ile Parametrik Modellenmesi	50
3.6.3	Abductor Pollicis Brevis Kasının Öz Bağımlı Model ile Parametrik Modellenmesi	53
4.	YAPAY SİNİR AĞLARININ GENEL TANIMI	57
4.1	Yapay Sinir Ağlarının Genel Özellikleri	58
4.2	Uygulamada Kullanılan Yapay Sinir Ağları.....	60
4.2.1	Çok katmanlı algılayıcı ağları (Multi-layer Perceptron)	60
4.2.1.1	Çok katmanlı ağların yapısı	61
4.2.1.2	Çok katmanlı ağlarda öğrenme.....	62
4.2.2	Radyal Temelli Fonksiyon Ağları	66
4.2.2.1	Ağ Topolojisi	67
4.2.2.2	Radyal Temelli Fonksiyon Ağlarının Eğitilmesi	68
4.2.2.3	Radyal Temelli Fonksiyon Ağları Öğrenme Algoritmaları.....	69
4.2.3	Olasılıksal Yapay Sinir Ağları.....	69
4.2.4	Genelleştirilmiş Regresyon Yapay Sinir Ağları	71
4.3	Çapraz Geçerlilik Metodu ile Eğitim ve Test Verisinin Oluşturulması.....	73
4.4	Uygulamada kullanılan YSA'ların topolojisi	74
5.	SONUÇLAR ve ÖNERİLER	76
5.1	SONUÇLAR.....	76
5.1.1	İleri Beslemeli Geri Yayımlı Yapay Sinir Ağları Test Sonuçları	76
5.1.2	Radyal Temelli Fonksiyon Ağları İçin Test Sonuçları.....	79
5.1.3	Genelleştirilmiş Regresyon Ağları İçin Test Sonuçları	82
5.1.4	Olasılıksal Yapay Sinir Ağları İçin Test Sonuçları	85
5.1.5	Alıcı Çalışma Karakteristikleri Analizi	87
5.1.5.1	Bire karşı tüm karşılaştırması (one-versus-all).....	88
5.2	ÖNERİLER	91
	KAYNAKLAR.....	92
	ÖZGEÇMİŞ.....	94

SİMGE LİSTESİ

x_o	İşaretin ortalama değeri
x_{rms}	İşaretin efektif değeri
σ_v^2	Gürültü varyansı
$r_{mm}(k)$	Otokorelasyon fonksiyonu
$\mathbf{R}$	Korelasyon matrisi
a_M	Öz bağımlı model katsayıları
b_K	Hareketli ortalama modeli katsayıları
w	Yapay sinir ağı ağırlıkları
β_j	Ara katmanda bulunan j. elemana ait eşik değeri elemanı ağırlığı
E_m	m. işlem elemanı için oluşan hata
α	Öğrenme oranı
η	Momentum katsayısı
r	Euclidean uzaklığı
D	Hamming uzaklığı
σ	Yumuşatma parametresi

KISALTMA LİSTESİ

A1	Çapraz Geçerlilik işlemi sonrası oluşan birinci alt küme
A2	Çapraz Geçerlilik işlemi sonrası oluşan ikinci alt küme
A3	Çapraz Geçerlilik işlemi sonrası oluşan üçüncü alt küme
A4	Çapraz Geçerlilik işlemi sonrası oluşan dördüncü alt küme
A5	Çapraz Geçerlilik işlemi sonrası oluşan beşinci alt küme
AÇK	Alıcı Çalışma Karakteristikleri
APB	Abductor Pollicis Brevis kası
ATP	Adenozin Trifosfat
Bİ	Biceps kası
ÇKA	Çok Katmanlı Ağ
FR	Frontalis kası
GRYSA	Genelleştirilmiş Regresyon Ağları
HO	Hareketli Ortalama
MU	Motor Ünite
ÖB	Öz Bağımlı
ÖBHO	Öz Bağımlı Hareketli Ortalama
PSD	Güç Spektral Yoğunluğu
RTFA	Radyal Temelli Fonksiyon Ağları
SENIAM	Surface EMG for Noninvasive Assesment of Muscles
YSA	Yapay Sinir Ağı

ŞEKİL LİSTESİ

Şekil 2.1 Kaslarda servomekanizma.....	7
Şekil 2.2 Klinik EMG düzeni basitleştirilmiş blok diyagramı.....	9
Şekil 2.3 Elektrod-elektrolit arayüzü ve akım (Yazgan ve Korürek ,1996)	9
Şekil 2.4 Elektrodun eşdeğer devre modeli (Yazgan ve Korürek ,1996)	11
Şekil 2.5 Bir elektrodun Ag-Agcl referans elektrodu ile arasındaki empedansın genliğinin frekansla değişimi (Yazgan ve Korürek ,1996)	11
Şekil 2.6 a) Elektrod-elektrolit ve kuvvetlendiriciden oluşan sistem b) Sistemin basitleştirilmiş elektriksel eşdeğer modeli (Yazgan ve Korürek ,1996)	12
Şekil 2.7 Yüzey elektrodları : a) Metal plaka b) Vakum pompalı c) Gezici tipten d) Tümüyle atılabilir e) Bükülebilir f) Kuru elektrodlar (Yazgan ve Korürek ,1996).....	13
Şekil 2.8 Dahili elektrodlar : a) İğne elektrod b) Tel elektrod c) Tel halka elektrod (Yazgan ve Korürek ,1996).....	15
Şekil 2.9 Mikroelektrodlar:a)Cam muhafazalıb)Cam göbekli(Yazgan ve Korürek ,1996).....	16
Şekil 2.10 Mikropipet Elektrod (Yazgan ve Korürek ,1996).....	16
Şekil 2.11 Mikroelektrod İle Gerçekleştirilen Ölçüm Düzeninin Basitleştirilmiş Modeli (Yazgan ve Korürek ,1996).....	17
Şekil 3.1: EMG sinyalinin frekans spektrumu.....	24
Şekil 3.2: Farklı bölgedeki elektrodların sinyal üzerine etkisi	25
Şekil 3.3 Uygulamada kullanılan yüzeyel elektrotlar.....	25
Şekil 3.4 Biceps kası (Upper Extremity Muscle Atlas Michael L. Richardson, M.D.).....	26
Şekil 3.5 Biceps kası için elektrot yerleşimi.....	27
Şekil 3.6 Biceps kası için EMG ölçüm düzeneği.....	27
Şekil 3.7 Ölçüm aşamalarının sonucunda elde edilen Biceps kasına ait EMG işareti.....	28
Şekil 3.8'de Frontalis kası	28
Şekil 3.9 Frontalis kası için elektrot yerleşimi.....	29
Şekil 3.10 Frontalis kası için EMG ölçüm düzeneği	29
Şekil 3.11 Ölçüm aşamalarının sonucunda elde edilen Frontalis kasına ait EMG işareti	30
Şekil 3.12 APB kasının yeri(Upper Extremity Muscle Atlas Michael L. Richardson, M.D.).	30
Şekil 3.13 APB kası için elektrot yerleşimi ve ölçüm düzeneği.....	31
Şekil 3.14 Ölçüm aşamalarının sonucunda elde edilen Frontalis kasına ait EMG işareti	31
Şekil 3.15 Rasgele süreç tarafından oluşturulan ayırık zaman stokastik süreç blok diyagramı	38
Şekil 3.16 Lineer filtre yapısı	39

Şekil 3.17 Süreç analizörü	41
Şekil 3.18 Süreç üretici	42
Şekil 3.19. Hareketli Ortalama Modeli (süreç üretici)	43
Şekil 3.20 (M,K) derecelerinde ÖBHO (süreç üretici) modeli	44
Şekil 3.21 . Genel doğrusal süreç oluşturulması için tüm sıfır filtreye dayanan model	45
Şekil 3.23 Birinci denekten alınan Biceps kasına ait EMG işareti	48
Şekil 3.24. Biceps kasına ait EMG işaretinin 5. dereceden öz bağımlı model katsayıları...	49
Şekil 3.25. Biceps kasına ait EMG işaretinin 10. dereceden öz bağımlı model katsayıları.	49
Şekil 3.26 Biceps kasına ait EMG işaretinin 20. dereceden öz bağımlı model katsayıları..	50
Şekil 3.27 Birinci denekten alınan Frontalis kasına ait EMG işareti	51
Şekil 3.28. Frontalis kasına ait EMG işaretinin 5. dereceden öz bağımlı model katsayıları	51
Şekil 3.29 Frontalis kasına ait EMG işaretinin 10. dereceden öz bağımlı model katsayıları	52
Şekil 2.31. Birinci denekten alınan Abductor Pollicis Brevis kasına ait EMG işareti	53
Şekil 3.32 Abductor Pollicis Brevis kasına ait EMG işaretinin 5. dereceden öz bağımlı model katsayıları	54
Şekil 3.33 Frontalis kasına ait EMG işaretinin 10. dereceden öz bağımlı model katsayıları	55
Şekil 3.34 Abductor Pollicis Brevis kasına ait EMG işaretinin 20. dereceden öz bağımlı model katsayıları	56
Şekil 4.1 Bir yapay sinir ağı örneği	57
Şekil 4.2 Çok katmanlı ağ yapısı	61
Şekil 4.3 ÇKA’larda öğrenme	62
Şekil 4.4 Olasılıksal yapay sinir ağının yapısı.....	71
Şekil 4.5 Genelleştirilmiş regresyon yapay sinir ağının yapısı.....	72
Şekil 4.6. Çapraz geçerlilik metodu ile veri kümesinin alt kümelerine ayrılması	73

ÇİZELGE LİSTESİ

Çizelge 4.1. XOR problemi	60
Çizelge 4.2 Çeşitli radyal temelli fonksiyonlar.....	68
Çizelge 4.3 Çapraz geçerlilik sonucu oluşan eğitime ve test kümeleri.....	74
Çizelge 5.1 $lr=0,5$ için ileri beslemeli geri yayımlı ağ test sonuçları.....	77
Çizelge 5.2 $lr=0,75$ için ileri beslemeli geri yayımlı ağ test sonuçları.....	77
Çizelge 5.3 $lr=0,8$ için ileri beslemeli geri yayımlı ağ test sonuçları.....	78
Çizelge 5.4 $lr=0,85$ için ileri beslemeli geri yayımlı ağ test sonuçları.....	78
Çizelge 5.5 $lr=0,9$ için ileri beslemeli geri yayımlı ağ test sonuçları.....	79
Çizelge 5.6 Çeşitli lr değerleri için ileri beslemeli geri yayımlı ağ test sonuçları	79
Çizelge 5.7 Test1 verisi için farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları	80
Çizelge 5.8 Test 2 verisi için farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları	80
Çizelge 5.9 Test 3 verisi için farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları	81
Çizelge 5.10 Test 4 verisi için farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları	81
Çizelge 5.11 Test 5 verisi için farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları	82
Çizelge 5.12 Farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları.....	82
Çizelge 5.13 Test 1 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları	83
Çizelge 5.14 Test 2 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları	83
Çizelge 5.15 Test 3 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları	83
Çizelge 5.16 Test 4 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları	84
Çizelge 5.17 Test 5 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları	84
Çizelge 5.18 Farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları.....	85
Çizelge 5.19 Test 1 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları	85

Çizelge 5.20	Test 2 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları	86
Çizelge 5.21	Test 3 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları	86
Çizelge 5.22	Test 4 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları	86
Çizelge 5.23	Test 5 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları	87
Çizelge 5.24	Farklı sp değerlerinde olasılıksal yapay sinir ağı test sonuçları.....	87
Çizelge 5.25	Hata Matrisi (confusion matrix).....	88
Çizelge 5.26	İleri beslemeli geri yayımlı YSA için test 4 Hata Matrisi.....	89
Çizelge 5.27	Radyal temelli fonksiyon ağı için test 4 Hata Matrisi.....	89
Çizelge 5.28	Biceps'e karşı Frontalis ve Abductor Pollicis Brevis'e ait değerler	90
Çizelge 5.29	Frontalis'e karşı Biceps ve Abductor Pollicis Brevis'e ait değerler	90
Çizelge 5.30	Abductor Pollicis Brevis'e karşı Biceps ve Frontalis'e ait değerler	90

ÖNSÖZ

Tez çalışmamda emeğini ve bilgisini daima yanımda hissettiğim tez danışmanım, Prof.Dr. Tülay Yıldırım hocama sonsuz teşekkürlerimi sunuyorum, ayrıca İstanbul Üniversitesi Tıp Fakültesi Nöroloji Anabilim Dalından Doç.Dr. Mehmet Barış Baslo'ya ve EMG laboratuvarı çalışanlarına teşekkür ediyorum.

Her zaman yanımda ve desteklerini bir an bile olsun eksik etmeyen aileme şükranlarımı ve sevgilerimi sunuyorum.

ÖZET

Elektromiyogram (EMG) işaretleri kasların kasılması sonucu ortaya çıkan biyopotansiyel işaretlerdir. Bu işaretler zamanın bir fonksiyonudur. EMG işareti sinir sistemi tarafından kontrol edilen ve kasların anatomik ve fiziksel durumlarına bağlı olan karmaşık bir işarettir. EMG işaretlerinin iyi bir şekilde tanımlanması için kullanılan metotlar biyomedikal mühendislik alanında çok güncel bir araştırma konusudur. EMG analizin en çok kullanım yeri klinik teşhis ve biyomedikal uygulamalardır. Bu çalışmada nörojen ve miyojen tutulumlarının teşhisinin alt yapısını hazırlamak üzere Biceps (kol kası), Frontalis (kaş kası) ve Abductor Pollicis Brevis (el kası) EMG işaretleri alınmıştır. Bu kaslar günümüzde doktorların bu tutulumları belirleyebilmek için kullandıkları kas gruplarıdır. Biceps kasından kaydedilen EMG işareti, Frontalis kasının işareti gibi sınıflanırsa inceleme altındaki kasın miyojen tutulumu olduğu; Abductor Pollicis Brevis kası gibi sınıflanırsa da nörojen tutulumu olduğu kestirilecektir. Kas gruplarının ayrımının yapılabilmesi iki adımda gerçekleşmektedir. Birinci adım, kas gruplarının modellenmesidir. Bu modelleme Öz Bağlanımlı modeller aracılığıyla yapılmıştır. İkinci adım ise modellenen bu kas gruplarının sınıflandırılmasıdır. Sınıflama aşaması için İleri Beslemeli Geri Yayılımlı Ağlar, Radyal Temelli Fonksiyon Ağları, Olasılıksal Yapay Sinir Ağları ve Genel Regresyon Yapay Sinir Ağları kullanılmıştır. Üç kas grubunun sınıflamasında Radyal Temelli Fonksiyon Ağları % 91,111, İleri Beslemeli Geri Yayılımlı Ağ ise % 90,444 başarı oranı göstermiştir.

Anahtar Kelimeler: Elektromiyografi, Öz bağlanımlı modeller, Yapay Sinir Ağları, Alıcı Çalışma Karakteristikleri

ABSTRACT

Electromyogram (EMG) signals are biopotential signals which appear as a result of muscle contraction. These signals are a function of time and controlled by central nervous system. EMG signals are dependent on anatomic and physical conditions of muscles. Methods which are used to define EMG signals are current research topics in biomedical engineering field. Most usage area of EMG signals are clinical diagnosis and biomedical applications. In this work; EMG signals were recorded from Biceps, Frontalis, and Abductor Pollicis Brevis to lay the foundation of myogen and neurogen ecliptic. Clinicians are using these groups of muscles too for diagnosis of these ecliptics. If the EMG signal recorded from Biceps is similar to Frontalis muscle EMG signal then the muscle named as myogen ecliptic and if the recorded EMG signal is similar to Abductor Pollicis Brevis muscle then it named as neurogen ecliptic. The classification of these groups has two steps. The first step is the modeling of EMG signals. Auto-regressive models used for modeling the EMG signals. After this modeling stage EMG signals were classified by neural networks. For classification operation Feed Forward Neural Networks, Radial Basis Function Neural Networks, Probabilistic Neural Networks and Generalized Regression Neural Networks were used. After several experiments Radial Basis Function Neural Networks has % 91,111 accuracy rates and Feed Forward Neural Networks has % 90,444 accuracy rates for classifying of these muscle groups

Keywords: Electromyogram, Auto-Regressive models, Neural Networks, Receiver Operating Characteristics

1. GİRİŞ

Elektromiyogram (EMG), kasın kasılması sonucu ortaya çıkan biyopotansiyel işaretlerdir. Elektromiyografi ise, kasların kasılmasını sağlayan elektriksel aktivitenin izlendiği ve yorumlandığı bir kas incelemesidir ve uygulama olarak birçok alana hitap etmektedir. Birkaç örnek vermek gerekirse sinir cerrahisinde, kaza cerrahisinde, nevraljide ve ortopedide elektromiyografi günümüzün değerli bir diyagnostik metodunu oluşturmaktadır. Doktorlarda da bunun aracılığıyla metabolizma hastalıklarında kas ve sinirlerin uyarılma bozukluklarını görebilir. Aynı zamanda doktor, bu yöntemi merkezi sinir sisteminin motor sinir hastalıklarında tanısal olarak kullanmaktadır ve bu metotla periferik sinir ve kasların hastalıklı durumunu kliniksel belirtiler ortaya çıkmadan önce kanıtlayabilir. Bu ölçümlerin doğru olması ve tam değerlendirilmesi için teknik bakımdan çok karmaşık cihazlar gerekmektedir.

EMG direkt inceleme yöntemlerinin yerini tutmasa da bu yöntemlere yol göstermekte, birçok hastalıkta ise direkt yöntemlere gerek kalmaksızın klinisyene tanı koymada yardımcı olarak tedavinin yolunu açmaktadır.

1.1 Çalışmanın Amacı

Motor ünite potansiyelinin süre ve genlik değerleri hastalık modellerinde değişmektedir. Sinir-kas sistemini etkileyen hastalıklar; motor ünite “nörojen” veya “miyojen” tutulumuna sebep verirler. Nörojen tutulumunda, kas lifleri uyarılmalarını kaybetmektedirler. Bu kayıp ile birlikte, sağ kalan sinir hücreleri, uyarılmasını kaybetmiş kas liflerini yeniden uyararak kas gücü kaybını kompanse etmeye çalışırlar. Bu mekanizma ile motor üniteler zimmetlerine yeni kas lifleri kattıkları için ürettikleri motor ünite potansiyelleri de daha uzun süreli ve yüksek genlikli olur. Bu özellik EMG işaretinin daha yüksek genlikli olmasını ve seyrelmiş olmasını doğurur. Oysa miyojen tutulum kayıp kas liflerinin ortadan kalkması şeklindedir. Bu mekanizma, motor ünite başına düşen kas lifi sayısını azaltacağından kaydedilen motor ünite potansiyellerinin süresi kısalmış ve genlikleri düşer. Başka bir deyişle; nörojenik tutulumda EMG işareti el kasından kaydedilene; miyojen tutulumda ise yüz kasından kaydedilene benzemektedir.

Miyojen ve nörojen tutulumlarının belirlenebilmesi için bu tutulumların tanısında kullanılan üç kas grubuna ait EMG işaretleri alınmıştır. Bu kas grupları Biceps (kol), Frontalis (yüz), Abductor Pollicis Brevis (el) kaslarıdır. Alınan bu işaretler parametrik modelleme yöntemleri ile modellenmiş ve elde edilen değerler ile yapay sinir ağları metotları ile sınıflama yapılmıştır. Modellemede kullanılan parametrik modelleme metodu Öz bağımlı

modellerdir.

1975 yılında Graupe ve Cline (Graupe D, Cline W.K.,1975); ilk defa EMG işaretlerinin gösteriminde öz bağımlı yürüyen ortalama metodunu kullanmıştır. 1983 yılında Doerschuk vd. (Doerschuk PC, Gustafson W., 1983) EMG sinyalleri ile protes kontrolü için öz bağımlı modeli kullanmıştır. 1986 yılında Zhou vd. (Zhou Y, Chellappa R, Bekey G., 1986) yüzey EMG'lerini bir öz bağımlı model olarak göstermiştir. 1988 yılında Hefftner (Hefftner G, Zucchini W, Jaros G., 1988) EMG işaretlerini yüksek hesaplama hızından dolayı öz bağımlı bir modelle göstermiştir. Öz bağımlı modeller birkaç katsayıyla (öz bağımlı model katsayıları) EMG işaretini tam anlamıyla ifade etmeyi sağlar. Öz bağımlı model katsayıları başarılı bir şekilde işaretin güç spektrumunu kestirebilirler.

Bu çalışma EMG sinyali ile kayıt kası ilişkisinin kurulması; nörojen tutulumunu, miyojen tutulumundan ayırt etmek için bir temel oluşturacaktır. Kol kasından kaydedilen EMG işareti, yüz kasının işareti gibi sınıflanırsa inceleme altındaki kasın miyojen tutulumu olduğu; el kası gibi sınıflanırsa da nörojen tutulumu olduğu kestirilecektir.

2. ELEKTROMİYOGRAM (EMG) İŞARETİ

Elektromiyogram (EMG) işaretler; kasların kasılması ile meydana gelen elektrokimyasal olaylar sonucu ortaya çıkan biyopotansiyel işaretlerdir. İki tip kas hareketi vardır. Bunlar istemli ve istem dışı kas hareketleridir. Beyinde oluşan aksiyon potansiyellerinin sinirlerle kasa iletilmesi sonucu istemli kas hareketleri oluşur. EMG işaretlerinin vücuttan elde edilmesi için iki tip yöntem vardır. Bu yöntemler işaretleri alırken kullanılan elektrotlara göre sınıflandırılır.

Birinci yöntem; iğne elektrotlar vasıtasıyla alınan işaretlerdir ki bu yönteme iğne elektromiyografisi denir. İkinci yöntem ise yüzeysel elektrotlar ile alınan yüzeysel EMG'dir. Her iki yöntemde de alınan işaretlerin kuvvetlendirilmesinde diferansiyel kuvvetlendiriciler kullanılır. İşaretlerin analizi ise frekans veya zaman domeninde yapılabilir.

2.1 EMG işareti literatürü

H.Piper EMG işaretleri ile ilgili çalışan ilk araştırmacı sayılmaktadır. Bu çalışmaları 1912 yılında Almanya da bir galvanometre ile yapmıştır (Piper, H, 1912). 1924 yılında Gasser ve Erlanger benzer bir çalışmayı osiloskop ile yapmıştır (Gasser, H.S. ve Erlanger, J, 1924). 4 yıl sonra Proebster bu işaretlerin kaslar tarafından üretildiğini bulmuş ve klinik EMG alanını açmıştır (Proebster, R., 1928). Günümüzde de EMG çalışmaları için kullanılan eş-merkezli iğne elektrodu yöntemini 1929 yılında Adrian ve Bronk geliştirmiştir (Adrian,E.D. ve Bronk D.W., 1929). Devam eden yıllarda motor ünite aksiyon potensiyeli ile ilgili nicel analiz ve metotların (MUAP) geliştiricileri sayılan Kugelberg, Petersen, Buchtal, Guld, Gydikov, Kosarov, Pinelli, Rosenfalck ve Stalberg vakum tüpü yükselticileri ve daha sonra katı hal devrelerini kullandılar (solid state circuits). Denny-Brown 1949 yılında “EMG işaretlerinin gösterimi ” belirledi (Gydikov, A., Kostov, K., Kossev, Kosarov, D., 1984). Uchizono kurbağa sartoris kasındaki işaretlerin yayılımını tanımlamıştır (Uchizono, 1953). Willison 1964 yılında EMG işaretlerinin Genlik analizini yapmıştır (Willison, R.G., 1964). 1962 yılında J.V. Basmajian tarafından yazılan “Muscles Alive ” kitabı bir mihenk taşıdır. 1979 yılında De Luca tarafından yazılan ve bu konuda bir ilk olan EMG içerik bilgisi ve açılması ile ilgili makalesi EMG işaretlerinin fizyolojisi ve matematiksel metotlarını birleştiren bir klasik sayılmaktadır (De Luca, C.J., 1979).

Bilgisayarların kullanımı sayesinde bu işaretlerin simülasyonu ve modellerin gelişmesi daha da kolaylaşmıştır. 1970'ler ve 1980'lerde birçok araştırma grubu bu konuyla ilgilenmiş ve

birçok yayın yayınlamışlardır. Modelleme alanında Dimitrova ve Lindstrom başı çekmişlerdir (Dimitrova, N., 1974; Lindstrom, L., Magnusson, R., 1977). Bu modeller EMG işaretinin içerdiği bilgilerinin anlaşılması ve işaretin biyofiziğinin anlaşılmasında çok başarılı olmuştur. EMG işaretlerinin geçmiş ve doğal bir alanı da protez kontrolüdür. Myoelectric kontrol olarak adlandırılan bu saha il olarak 1940’larda (Reiter, R., 1948) başlamış ve 1960,1970,1980’lerde hızlı bir gelişme kaydetmiştir. Örüntü tanıma temelli EMG kontrolörler günümüzde güncel ve gelişen bir alandır (Englehart, K., Hudgins, B., Parker, P.A.,2001; Kyberd, P.,Evans,Winkel, S., 1998).

1965 yılında J.V. Basmajian, S. Carlsöö, B. Johnson, M. MacConaill, J. Pauly ve L. Scheving’in yaptıkları toplantıda Uluslar arası Elektormiyografi ve Kinesoloji topluluğunu (International Society of Electromyography and Kinesiology (ISEK))kurmayı kararlaştırdılar ve 1966 yılında kurdular. Bu topluluğun çalışma alanları arasında gelişen EMG alanı ile ilgili toplantılar, konferanslar ve sempozyumlar organize etmek bulunmaktadır.

İğne EMG teknikleri bölgesel ve iğnenin batırıldığı küçük bir alanla ilgili olan içerik bilgilerini verir. Yüzeyel EMG yöntemleri EMG işaretleri ile ilgili daha geniş ve genel bilgiler vermektedir.

Yüzeyel EMG ölçümlerinde bazı kayıplar olmaktadır ve ölçümlerin standart bir şekilde yapılması için bazı standartlar belirlenmiştir. 1995 yılında bir grup araştırmacının önderliğinde ve Avrupa Birliğinin katkılarıyla elektrot, elektrot yerleşimi ve işaret işleme tekniklerinin belirlendiği Kasların Noninvasive fikirleri için Yüzeyel EMG (Surface EMG for noninvasive Assesment of Muscles (SENIAM) projesi hazırlanmış ve 1996 yılında yürürlüğe girmiştir. SENIAM’ın amacı; bu konularda çalışan laboratuarların kabul edilebilir bir seviyeye getirmektir.

2.2 EMG işaretlerinin temel kavramları

2.2.1 Kasların Yapısı

İskelet kasları fiber denilen ince uzun hücrelerden meydana gelmiştir. Uzunlukları 1–50 mm ve çapları 10–100 µm arasındadır. Dış yüzeyleri sakrolenma denilen bir kılıf ile örtülmüştür. Bu lifler, kıkırdak dokuya bağlıdırlar. Kasın kasılması, liflerin kısalıp şişmesi ile olur. Kaslara besin, kan damarlarıyla, uyarı ise sinirlerle götürülür. Kasın kasılması anında bir seri kimyasal reaksiyon olur. Bu reaksiyonlar için gerekli aktomiyosin proteini, kandaki hemoglobine

benzer biçimde oksijen depolayan myoglobin, enerji tasarrufu için gerekli fosfatlar ve yakıt olarak gylcogen şeklinde kasta bulunur.

Çizgili Kaslar

İstemli hareketi sağlayan iskelet kaslarıdır. Mikroskop altında yapılan incelemelerde açık renkli ve koyu renkli bandlar gözlenmiştir. Koyu banda A, açık banda I bandı denir. A bandının ortasında açık H bandı ve I bandının ortasında koyu Z bandı vardır. Z bandları arasındaki bölge kasılma anında daralır. A bandı sabit kalır, H ve I bandları ise daralır. Kasın proteinin actomyosinin myosin bileşeni A'da bulunur. Actin ise Z bandında başlayıp H bandında biter.

Düz Kaslar

Bu kaslar, istemsiz hareket kasları olup sindirim sistemi, idrar yolları ve kan damarları etrafında bulunurlar. Lifleri kısıdır. Otonom sinir sisteminin sempatik ve parasempatik kontrolleri altındadır.

Kalp Kasları:

Bu kaslar çok gelişmiş istemsiz kaslardır. Kalın ve kısa liflerden meydana gelen çok yoğun bir ağ gibidir. Sinirsel uyarı olmadan kasılabilirler. Sinirsel uyarı, kasılma zamanını etkiler.

Yukarıda bahsedilen kas tiplerinin temel birimi motor ünitelerdir.

2.2.2 Motor ünite

İnsan motor sistemi; iç ve dış istekler ile sınırlama durumlarının çok geniş farklılıklarıyla baş etmek zorundadır. Bu farklılıklar; dışarıya uygulanacak kuvvetin güçlü ve hassas bir şekilde ayarlanması, dik duruş ve birçok el kol hareketlerini içermektedir. Birçok motor sistemin özel kontrol öğelerini anlatmak çok zor olacağından burada güç ve hareket kontrolünde büyük pay sahibi olan iskelet motor sistemi kontrolünün temel prensipleri anlatılacaktır.

Merkezi Sinir Sistemi hiyerarşik bir yapıda örgütlenmiştir. Motor programlama; premotor korteks, ek motor alanı ve korteksin ilişkili olduğu diğer bölgelerde bulunur.

Bu alanlardan gelen girişler birincil motor korteksine düşer ve burada bulunan çeşitli nöronları harekete geçirir. Birincil motor korteksinin çıkışları beyin sapı ve omurilikte

bulunan iç nöronlar ve motonöronlar üzerinde kuvvetli bir tesiri bulunmaktadır.

Motor üniteler (MU) omurilikte bir α -motonöron ve kas lifinden oluşmaktadır. α -motonöronlar gelen bütün girişlerin ve reflekslerin son toplanma noktasıdır. MU'ların sayısı kastan kasa değişmektedir. Mesela küçük bir el kasındaki MU'ların sayısı 100 ile 1000 arasında değişmektedir. Bu sayı kol ve bacak kaslarındaki kaslarda daha da fazladır. Aynı zamanda MU'ların sayısı güç üretme kapasitesine göre de değişiklik oluşturmaktadır.

Yapılan ilk çalışmalar fizyolojik özelliklerine göre 3 tip MU olduğunu göstermiştir. Bunlar:

- S veya I tipi Motor Ünite(Slow): Yavaş seğirir, oksidatif enzimler içerir, en yavaş kasılma ve seğirme gerilmesi veya en küçük kuvvetle yorulmaya karşı koyan birimlerdir.
- FR veya II-a Tipi Motor Ünite (Fast, Rezistant): Hızlı seğirir, oksidatif ve glikolitik enzimler içerir, daha hızlı kasılma zamanları ve daha geniş kuvvetlerle yorulmaya karşı koyan birimlerdir.
- FF veya II-b Tipi Motor Ünite (Fast, Fatigable) : Hızlı seğirir, glikolitik enzimler içerir, en hızlı kasılmalar ve en geniş kuvvetlerle kolayca yorulabilir.

2.2.3 Kas kasılması

Kasların kasılması için kas lifinin uyarılması gerekir. Kasların kasılması iki biçimde olur. Kas boyunun sabit kalıp sadece şişmesi şeklindeki kasılmaya statik (izometrik) kasılma denir. İkinci kasılma şekli ise kas boyunun hem kısalması hem de kasılması şeklinde olan dinamik (izotonik) kasılma biçimidir. Kasın uyarılmasından sonra önce kasılma sonra da gevşeme olur. Kasa gelen uyardıdan sonra kas hemen aktif hale geçmez. Aktif hale geçmek için belli bir süre geçmelidir. Bu süreye gecikme zamanı (latency period) denir.


Kimyasal olarak kasın kasılması kısaca şöyle özetlenebilir: Kas aktif duruma geçtiğinde glikojen depoları boşaltılır, oksijen kullanımı ile karbondioksit meydana çıkar. Kas glikojeni pruvik aside parçalanırken yüksek enerjili ATP (adenin trifosfat) moleküllerinde depolu enerji açığa çıkar. Pruvik asidin tekrar oksitlenmesi ile sitrik asit çevriminde CO₂ ve H₂O ile yeni ATP molekülleri oluşur. Oksijen yetersizliği durumunda ise pruvik asitten anaerobik reaksiyonla laktik asit üretilir ve yeni enerji açığa çıkar.

Egzersizden sonra artmış olarak devam eden solunum ile sağlanan fazla oksijen alımı, oksijen açığını kapatır. Laktik asidin beşte biri oksitlenerek CO₂ ve su ile enerji açığa çıkar ve bu enerji ile laktik asidin geri kalan kısmı glikojene dönüşür. Kasın aktif olduğu zaman üretilen enerjinin bir kısmı mekanik enerjiye, bir kısmı da ısı enerjisine dönüşür. Kasın enerji verimi en fazla % 25'dir. Yani enerjinin en az dörtte üçü ısı enerjisi olarak kaybolur. Motor sinirlerin kas lifine ulaştığı noktaya motor uç plakları adı verilir. Motor sinirinden motor uç plakalarına bilgi geldiğinde acetylcholine salgılanarak kas uyarılır. Bazı düzgün kaslar ise kimyasal haber ileticisi olarak noradrenaline kullanırlar.

Kalp kasları, enerjilerini glikozdan değil yağdan sağlar. Böylece kandaki glikoz oranından etkilenmezler. Düz kaslar kontrol ettikleri organı bir ağ gibi sarar. Onların daralıp kasılmaları ile organda hareket meydana gelir. Buna peristaltik hareket denir. Vücudun hareketsiz olduğu anlarda bazı kaslar, izometrik olarak gergin olup, yerçekimine karşı koyarlar.

2.2.4 Kaslarda Servomekanizma

Kas hareketini kontrol eden sinir sisteminin oldukça basitleştirilmiş blok şeması aşağıdaki şekildedir.



Şekil 2.1 Kaslarda servomekanizma

Sistem, bir servomekanizma kontrol sistemidir. Bir duyu alıcısı, bir hız veya konum işareti üretir. Bu işaret duyu siniri ile beyne iletilir. Beyin hafızadaki bilgi ile gelen bilgiyi karşılaştırarak bir hata (kontrol) işareti üretir. Bu işaret motor siniri ile kasa gönderilerek onun hareketi kontrol edilir.

Bu servo sisteminin çalışması basit bir örnekle açıklanabilir. Bir insan parmağını soğuk bir cisme değdirdiği zaman, parmaktaki duyu alıcıları sıcaklığı algılar ve beyne gönderir. Beyin bu işaretin soğuktan geldiğini anlar ve motor siniri ile kası harekete geçirmesi gerekmez.

Şayet parmak sıcak bir cismin üzerine konmuşsa, beyin duyu sinirleri ile gelen bilgiden parmağın sıcak bir cisim üzerinde olduğunu anlar. Eğer cisim çok sıcak ise motor sinirleri ile kol kaslarına gerekli bilgiyi gönderip parmağın sıcak cismin üzerinden çekilmesini sağlar. Duyu alıcılarının sıcak cismi hissetmeleri ile parmağın kaldırılması arasında birkaç yüz ms'lik bir zaman gecikmesi vardır. Bu gecikme daha ziyade şahsın o sıcak cisme gösterdiği ilgi ile de ilgilidir. Şimdi, parmağın çok sıcak bir cisim üzerine değdirildiğini düşünelim. Bir refleks cevap ile parmak, 150 ms civarında bir sürede cismin üzerinden kaldırılır.

2.2.5 Kas Hareketi Sırasında Üretilen Gerilim

Bir duyu alıcısı uyarıldığında, duyu sinir lifi boyunca yürüyen bir depolarizasyon dalgasını (aksiyon potansiyelini) oluşturur. Bu darbe dizisi beyine ulaşır. Buna cevap olarak beyin de, motor uç plakalarının depolarizasyonuna neden olan uyarıyı, motor sinirleri boyunca propagasyon yapan aksiyon potansiyelleri şeklinde kasa gönderir. Motor uç plakalarının depolarizasyonu kas lifi içindeki hücreleri depolarize eder ve lifler kasılır.


Kaslarla ve sinirlerle uğraşırken, mikro elektrodlarla hücre potansiyellerinin ölçümü pek nadir yapılır. Genel olarak bir motor ünitesi gibi az sayıdaki hücrelerin net potansiyel değişiminin ölçümü iğne elektrodlarla, birçok motor ünitesinin oluşturduğu toplam potansiyelinin ölçümü ise yüzey elektrodları ile yapılır. Eğer bir mikro elektrod hücrenin içine batırılarak ölçme yapılırsa hücrenin tüm faaliyetinin 1 ms'den daha az olduğu görülür. Eğer, iğne elektrodlar bir hücrenin yakınına yerleştirilirse çevredeki hücrelerden gelen değişimleri de algırlar. Aynı motor ünitesine bağlı kas lifleri, motor uç plakalarına gelen sinir dalları ile hemen hemen aynı zamanda uyarıldığı halde, hücrelerin depolarize durumda kalış sürelerindeki farklılıklar ve ayrıca kas liflerine gelen sinir dallarının uzunluk farklılıklarından dolayı (bazı kas liflerine uyarı diğerlerinden biraz daha önce ulaşmış olur) bir motor ünitesindeki değişim süreci 2 ila 5 ms arasındadır. Bu asenkron durum, kas hareketinin düzgünlüğüne katkıda bulunur.

2.3 EMG işaretlerinin algılanması

2.3.1 EMG ölçüm düzeneği

EMG ölçüm düzenekleri genellikle işaretleri algılamaya yarayan elektrotlar, osiloskop, kuvvetlendirici devreler, magnetik kaydedici ve hoparlörden oluşur. Araştırma konularında bu sistem elemanlarına ek olarak çeşitli işaret işleme modülleri, spektrum analizörleri ve bilgisayarlar bulunabilir.

Uygulamada ölçüm yapılacak kasın motor ünitesi uyarılarak kas lifinde meydana gelen EMG işareti elektrotlar yardımıyla alınarak biyopotansiyel kuvvetlendiriciye oradan da görüntüleme ünitesine verilir. Şekil 2.2’de EMG ölçüm düzeneğinin blok bir şeması verilmiştir.




Şekil 2.2 Klinik EMG düzeni basitleştirilmiş blok diyagramı

2.3.1.1 Elektrotlar

Biyolojik işaretlerin vücut ile ölçme düzeni arasındaki iletişimi sağlayan ve ayrıca çeşitli amaçlar ve özellikle tedavi amacı için organlara akım gönderilmesini sağlayan elemanlara elektrod adı verilir. Elektrodlar iyon akımını elektron akımına veya tersi durumu dönüştürerek gerçekleştirirler.

Elektrodların iyon akımını elektron akımına dönüştürme işlemi, elektrodların içinde bulundukları sıvı ortamda (elektrolit içinde) ve elektroda yakın olan yüzeyde (arayüzde) gerçekleşir. Şekil 2.3’de bu dönüşüm işleminin gerçekleştiği arayüz görülmektedir. Bu arayüzün elektrod tarafında akım taşıyıcı olarak elektronlar ve elektrolit tarafında ise katyon(C^+) ve anyonlar(A^-) bulunur.



Şekil 2.3 Elektrod-elektrolit arayüzü ve akım (Yazgan ve Korürek ,1996)

Elektrolit içinde kullanılan elektrod malzemesinden katyonların bulunduğu durum da göz önüne alınarak, elektrod atomlarının elektronlarını kaybederek elektrolit içinde katyon durumuna gelmesi (oksidasyon reaksiyonu) veya tersine elektrolit içindeki elektrod malzemesinden olan katyonların, elektroddan elektron çalarak elektrod yüzeyinde birikmesi (eksiltme reaksiyonu) işlemleri ile karşılaşır. Elektroddan akım çekilmediği sürece, kimyasal birer reaksiyon durumunda olan bu iki işlem, birbirini dengeleyecek biçimde (2.1) eşitliğinde gösterildiği gibi sürüp gider(termodinamik denge).



(2.1) eşitliğinde, n ve m sırasıyla katyon ve anyonların valanslarını göstermektedir. Termodinamik dengede, elektrod-elektrolit arayüzünde pozitif yüklü C^{+} iyonları ile, elektrodun arayüze yakın olan bölgelerinde elektronlar birikir. Bu şekilde arayüzdeki yük birikimi (iyon birikimi), elektrodu çevreleyen elektrolit bölgesinin elektriksel potansiyelini, elektrolitin diğer bölgelerine göre farklı bir potansiyele getirir. Kullanılan elektrodun yapıldığı malzemeye ve kullanılan elektrolitteki iyon aktivitesine göre değişen bu potansiyel farkına “yarı hücre potansiyeli” adı verilir. Elektrodların yarı hücre potansiyellerini ölçmek kolay değildir. Çünkü elektrolitin elektroddan uzaktaki referans potansiyelde olan noktasına batırılacak referans elektrodunun da bir yarı hücre potansiyeli olacaktır ve yarı hücre potansiyeli ölçülecek elektrod ile referans elektrod arasına bağlanacak büyük iç dirençli bir voltmetre ancak bu iki elektrodun yarı hücre potansiyellerinin farkını gösterecektir. Bu soruna bir çözüm getirmek amacıyla, yarı hücre potansiyeli sıfır varsayılan hidrojen elektrodu(asit içine daldırılarak etrafında hidrojen kabarcıkları oluşturulmuş platin elektrod), referans elektrod olarak ele alınmıştır.


Yarı hücre potansiyelinin ölçülebilmesi için elektroddan hiç akım çekilmemesi gerekir. Akım çekilince reaksiyon dengesi bozulur ve ölçülen yarı hücre potansiyeli, akımın sıfır olduğu değerinden farklı olur. Bu iki potansiyel arasındaki farka gerilim aşımı denir.

Teorik olarak elektrodlar, polarize olan ve polarize olmayan elektrodlar olarak ikiye ayrılabilirler. Polarize olan elektrodalarda, elektrod-elektrolit arayüzünde akım geçişi sınırlıdır ve elektrod bir kapasite gibi davranır. Polarize olmayan elektrodalarda akım arayüzü serbestçe geçer ve bu elektrodalarda gerilim aşımı yoktur. Ag-AgCl elektrodu pratik olarak polarize olmayan elektrod sınıfına girer ve bu yüzden, bu elektrodların yarı hücre potansiyelleri

oldukça kararlıdır, yani gürültüleri çok azdır. Ayrıca bu elektrodların yapımı kolay ve ucuzdur.


2.3.1.2 Elektrotun Devre Modeli

Elektrodun elektriksel devre modeli Şekil 2.4'te gösterilmektedir. Bu modelde, C_d elektrod-elektrolit arayüzündeki yük birikiminin neden olduğu kapasiteyi, R_d ise bu kapasitenin kaçak direncini temsil etmektedir. E_d , elektrodun yarı hücre potansiyeline karşılık olan gerilim kaynağıdır. R_s ise elektrolitin direncine karşı gelir. Kullanılan elektrod Ag-AgCl elektrodu ise C_d kapasitesi oldukça küçüktür ve bu yüzden kapasitif etki oldukça azdır.



Şekil 2.4 Elektrodun eşdeğer devre modeli (Yazgan ve Korürek ,1996)


Şekil 2.5'de Ag-AgCl referans elektrodu ile birlikte kullanılan ve devre modeli çıkarılacak olan elektrodun, empedansının genliğinin frekansla değişimi gösterilmiştir. Bu değişimde, empedansın modülünün alçak frekanslardaki değeri, eşdeğer devredeki $(R_d + R_s)$ direncinin değerine ve yüksek frekanslardaki değeri ise R_s direncinin değerine karşılık gelmektedir.



Şekil 2.5 Bir elektrodun Ag-AgCl referans elektrodu ile arasındaki empedansın genliğinin frekansla değişimi (Yazgan ve Korürek ,1996)

Şekil 2.6'da elektrodların doku ile olan bağlantı durumunun elektriksel eşdeğer modelinin

çıkarılmasında yardımcı olabilecek şekil olarak, elektrolit içine daldırılmış olan elektrodların kuvvetlendirici ile olan bağlantısı ve bu bağlantının elektriksel eşdeğer modeli gösterilmiştir. Bu modelde elektrodlar, aşağıdaki şekilde elektrod eşdeğer devresi ile ve elektrolit ise daha çok rezistif karakter göstermesi nedeniyle R_u direnci ile gösterilmiştir.



Şekil 2.6 a) Elektrod-elektrolit ve kuvvetlendiriciden oluşan sistem b) Sistemin basitleştirilmiş elektriksel eşdeğer modeli (Yazgan ve Korürek ,1996)

Elektrodların deri üzerinden test edilecek veya ölçme yapılacak organa olan bağlantısında ise deri, paralel R-C elemanları ile, biyopotansiyel kaynak, bir gerilim kaynağı (e_{mp}) ve ona seri olan paralel R-C devresi ile ve elektrod-biyopotansiyel kaynak arasındaki, daha çok sıvımsı olan ortam (iletken hacim) ise bir direnç elemanı (R_u) ile modellenebilecektir.

2.3.1.3 Elektrot çeşitleri

Değişik amaçlara göre kullanılan elektrod çeşitleri aşağıdaki şekilde gruplandırılabilir:

1) Yüzey Elektrodları


- a) Metal Plaka Elektrodları
- b) Emici Düzenli (Vakum Pompalı) Elektrodlar
- c) Gezici Tipten Elektrodlar
- d) Tümüyle Atılabilir Elektrodlar
- e) Bükülebilir Elektrodlar
- f) Kuru Elektrodlar

2) Dâhili Elektrodlar

3) Mikroelektrodlar

4) Hücre Uyarmada Kullanılan Elektrodlar

- 1) Yüzey Elektrotları: Şekil 2.7’de, çeşitli yüzey elektrodları görülmektedir. Bu elektrodlar, biyolojik işaretlerin deri üzerinden algılanmasında kullanılırlar.



Şekil 2.7 Yüzey elektrodları : a) Metal plaka b) Vakum pompalı c) Gezici tipten d) Tümüyle atılabilir e) Bükülebilir f) Kuru elektrodlar (Yazgan ve Korürek ,1996)

- a) Metal Plaka Elektrodlar: Çok sık kullanılan bir elektrod türüdür ve özellikle EMG, EEG ve EKG işaretlerini algılamakta kullanılır. Deri ile temas eden metalik bir yüzeyi bulunur. Gerçekte, deri ile temas eden bir elektrolit pasta aracılığı ile olur. Metal plaka, düz veya uygulanacak yüzeyin şeklini alacak şekilde bir silindirik yüzey parçası biçimindedir ve genellikle Nikel-Gümüş alaşımından yapılmaktadır (Şekil 2.7-a). Genelde bu sınıfa giren elektrodların yüzeyleri büyük olduğundan empedansları küçüktür (2-10 Kohm).
- b) Emici Düzenli Elektrodlar: Metal plaka elektrodunun geliştirilmiş bir şekli olup herhangi bir şekilde yapışkan veya bağlama kayışı gerektirmez ve genelde göğüs üzerinden EKG işaretlerinin algılanmasında kullanılır. Bu elektrod türünde, metal elektrod bir boru şeklindedir. Bu borunun halka şeklindeki yüzlerinden biri deriye değerken diğer yüzü, deriye elektrodun tutturulmasını sağlayan ve vakum pompası


görevi gören elastik bir hazne içind kalır. Bu tür bir elektrodun deri ile temas eden yüzeyi halka şeklinde olduğundan, elektrod oldukça büyük hacimli olsa bile, empedansı büyüktür ve bu yüzden küçük giriş empedanslı kuvvetlendiricilerle kullanılması elverişli olmaz (Şekil 2.7-b).

- c) Gezici Tipten Elektrodlar: Bu tipten bir elektrodta elektrolit, metal elektrod ile birlikte hareket ettiğinden, elektrod ya da deri, yani elektrolit hareketinden ileri gelen bozucu işaretler pek oluşmamaktadır. Şekil 2.7-c’de gezici tipten bir elektrod görülmektedir. Elektrod şapka biçimindedir ve metal dik şapkanın en üst iç yüzeyine yapışık durumdadır. Elektrod kullanılacağı zaman, yalıtkan şapkanın içi elektrolit ile doldurulur ve şapka, her iki yüzü yapışkan olan elastik bir halka vasıtası ile deriye yapıştırılır. Şapka hareketli olsa bile metal elektrolite göre hareket edemeyeceğinden aralarındaki yük dağılımı bozulmaz ve daha kararlı işaretler elde edilir. Ayrıca metal, disk gümüşten(Ag) yapıp AgCl ile kaplanırsa kararlılık daha da artırılmış olur. Her iki tarafı yapışkan olan elastik halka, her hasta için yenilenir.
- d) Tümüyle Atılabilir Elektrod: Bu elektrodlar, EKG ölçümlerinde çok kullanılan ve bir kere kullanıldıktan sonra atılan elektrodlardır (Şekil 2.7-d). Elektrolit, Ag-AgCl elektrod tabanının hemen altında, elektroda yapışık durumda jel, emdirilmiş sünger olarak gerçekleştirilir.
- e) Bükülebilir Elektrodlar: Bu türden bir elektrod, düz olmayan vücut yüzeyinin şeklini alacak şekilde bükülebilmektedir. Çok kullanılanı, bir yüzü kısmen Ag telleri ile örülmüş, yapışabilir özelliğe sahip olan bir band şeklinde olanıdır (Şekil 2.7-e). Bükülebilir elektrodlar genellikle küçük çocukların EKG işaretlerini algılamada kullanılırlar.
- f) Kuru Elektrodlar: Yüzey elektrodlarının bu gruba girenleri, ara pasta malzemesi gerektirmeden, deri üzerine direkt olarak uygulanabilirler ve aradaki kuplaj kapasitiftir. Şekil 2.4’deki eşdeğer devre geçerlidir ancak, elektrod-elektrolit ilişkisi bulunmadığından, eşdeğer devrede kaynak gerilimi yoktur. Dış deri, elektrod yüzeyi ile, daha iyi iletken durumunda olan dermis arasında bir yalıtkan durumundadır ve bu yüzden bir kapasite oluşur ki dermis ile elektrod bu kapasitenin plakaları, dış deri ise dielektrik malzeme durumundadır. Üst deri iyice temizlenmeden kuru elektrod deri yüzeyine, eşdeğer devredeki kapasiteye paralel gelen direnç (R_d) de oldukça büyüktür. Bu yüzden bu tür elektrodların bağlandığı kuvvetlendiricilerin giriş dirençleri de aynı

oran da büyük (1 G Ω mertebelerinde) olmalıdır. Büyük empedanslı devrelerle çalışıldığı içindir ki gürültü problemini en aza indirmek amacıyla, daha ziyade, empedans dönüştürme işi yapan kuvvetlendiricinin ön katı, elektrodun hemen yanına monte edilir (Şekil 2.7-f). Kuru elektrodların, bazen dielektrik malzemesi de metal üzerinde oksit film oluşturularak gerçekleştirilir ki bu durumda artık hiç elektrolite gerek yoktur. Yarı iletken yapım teknolojisi ile silisyum kristal yüzeyler üzerinde çok ince ve düzgün SiO₂ yalıtkan tabakaları oluşturularak yapılan kuru elektrodlarda, kapasite 1nF civarında olup, kuvvetlendiriciler de aynı silisyum taban üzerinde gerçekleştirilebilmektedir.

- 2) Dâhili Elektrodlar: Dahili elektrodlar, biyopotansiyel işaretleri vücut içinden algılamakta kullanılırlar. Deri altına batırılan iğne şeklinde olanları bulunduğu gibi, tümüyle vücut içine gömülüp harici kuvvetlendiriciye telemetri verici düzeni ile bağlı olanları da vardır. Bu tür elektrodlarda pasta kullanılmaz, elektrolit olarak hücre sıvısı mevcuttur. Şekil 2.8’de dahili elektrodlardan, iğne,tel ve tel halka elektrodları görülmektedir.


İğne elektrodlar, paslanmaz çelikten yapılmış olup, EMG ve ameliyat gereken hastalarda EKG işaretlerinin algılanmasında kullanılırlar (Şekil 2.8). Bu elektrodlarda, yüzey elektrodlara göre daha kararlı işaretler elde edilebilmektedir, ancak bunların kullanılışı her zaman hastayı rahatsız etmektedir. Çünkü iğne çapları 0,1 mm ile 1 mm arasında değişmektedir. Tel elektrodların metal uçları kanca şeklindedir ve bu kanca sayesinde bir şırıngaya tutturularak deri altına sokulurlar ve şırınga geri çekildiğinde ise yine bu kanca yardımıyla bulundukları yere tutunurlar (Şekil 2.8-b).



Şekil 2.8 Dahili elektrodlar : a) İğne elektrod b) Tel elektrod c) Tel halka elektrod
(Yazgan ve Korürek ,1996)


Vücut içine yerleştirilen elektrodlardan biri, Şekil 2.8-c’de gösterilmiştir. Bu elektrodun ucu, vücut içinde ölçme yapılacak noktaya dikilebilmesi için halka şekline getirilmiştir.

- 3) Mikroelektrodlar: Uyarılabilen hücrelerin elektriksel davranışlarını inceleyebilmek için, hücre zarı ile bölünen hücre içi ve hücre dışı arasındaki potansiyel farkını ölçmek gerekmektedir. Bunu gerçekleştirmek için hücreyi tahrip etmeyecek ve elektriksel davranışını bozmayacak bir elektrodun hücre içine daldırılması gerekmektedir. Bu amaç için kullanılan ve uç çapları 0,05–10 μm arasında değişen ve hücre zarını delerek, mekanik olarak kararlı kalabilecek durumda olan elektrodlara mikroelektrodlar adı verilir.



Şekil 2.9 Mikroelektrodlar : a) Cam muhafazalı b) Cam göbekli (Yazgan ve Korürek ,1996)


Mekanik sağlamlık, metal cam içinde muhafaza edilerek veya bir cam silindir yüzeyini kaplayacak biçime getirilerek sağlanır.(Şekil 2.9-a ve b). Elektrodu, içine konan elektrolit içinde muhafaza eden, camdan yapılmış mikropipetler de mikroelektrod sınıfına girerler (Şekil 2.10). Mikropipet elektrodlarda, cam muhafaza şeklindeki tübün geniş olan ağzı, ortasında metal (Ag) elektrod tel bulunan yalıtkan bir tıpa ile kapatılır. Cam tübün ince ve açık olan ucunun çapı 1 μm kadardır.



Şekil 2.10 Mikropipet Elektrod (Yazgan ve Korürek ,1996)

Şekil 2.11’de mikroelektrod ile yapılan hücre içi biyopotansiyel ölçüm düzeninin basitleştirilmiş elektriksel modeli gösterilmiştir. Bu şekilde, A ucu mikroelektrodun bağlantı ucuna ve B ucu ise referans elektrodunun bağlantı ucuna karşı gelmektedir. Bu modelde, yüzeyi mikroelektrod yüzeyine göre oldukça geniş olan referans pasif model elemanları mikroelektrodun model elemanları yanında ihmal edilmiştir. Şekil 2.4’deki modele gözüken seri dirençler de bu modelde ihmal edilmiştir. Sonuçta, basitleştirilmiş modelde mikroelektrodun paralel R-C elemanları ile kablo ve elektrod kaçak kapasiteleri

kalmaktadır. Modeldeki ($E_{ma}-E_{mb}$) potansiyel kaynağı, mikroeletrod ile referans elektrod eşdeğer yarı hücre potansiyel farklarını temsil etmektedir.



Şekil 2.11 Mikroeletrod İle Gerçekleştirilen Ölçüm Düzeninin Basitleştirilmiş Modeli (Yazgan ve Korürek ,1996)

- 4) Hücre Uyarmada Kullanılan Elektrodlar: Hücre uyarmada kullanılan elektrodlar genelde, biyoelektrik potansiyellerin algılanmasında kullanılan elektrodla benzerler. Ancak bu elektrodlardan mili amper mertebesinde uyarı akımları akıtılmaktadır. Kalbin hızlı ve zayıf çalışmasını önleyici cihazlarda ve kalbin atış hızını ayarlayan cihazlarda hücre uyarması için özel elektrodlar kullanılır. Elektriksel uyarı için, dikdörtgen dalga, sinüzoidal veya dönüşü eksponansiyel olarak azalan darbeler kullanılmaktadır. Uyarı, akım veya gerilim değişimi biçiminde yapılabilir. Elektrod eşdeğer devresi Şekil 2.4'deki gibidir. Uyarı elektrodlarında kullanılan malzeme önemlidir, çünkü uyarı akımı elektrodun okside olmasına ve elektrod yakınında elektrod malzemesinden iyonların konsantrasyonunun artmasına ve dolayısıyla hücre zehirlenmesine yol açabilir. Elektrod açısından bakıldığında ise bu oksidasyon, elektrodun ömrünü azaltıcı bir etkidir. Bu yüzden uyarı elektrodu olarak soy metaller kullanmak uygun olur.

2.4 Biyolojik işaretlerin ölçümü ve teşhisinde işaret işlemenin yeri

Ölçüm ve teşhis sistemlerinde işaret işleme teknikleri ikiye ayrılmıştır. Bunlar Analog işaret işleme Sayısal işaret işleme teknikleridir. Analog işaret işleme adımları genel olarak algılama, ön kuvvetlendirme, süzme ve ön işaret işleme adımlarını kapsar. Sayısal işaret işlemede ise veri toplama, sayısal süzme, veri azaltma, amaca yönelik işaret işleme, öznelik bulma veya parametre türetme, ön sınıflama ve son sınıflama adımları bulunmaktadır. Analog işaret işleme tekniklerini incelersek;

1. Veri algılama: veri algılamada biyolojik veya fizyolojik büyüklüğü elektriksel büyüklüğe çeviren elektrotlar bulunur ve bu sayede işaretler algılanmış olur.

2. Ön Kuvvetlendirme: elektrotlardan meydana gelebilecek gürültülerin anlamlı işareti ayırmak için ön kuvvetlendirme yapılmalıdır.
3. Süzme ve ön işaret işleme: ortamdaki hareket gürültüsü, şebeke gürültüsü, harici kaynaklardan karışan gürültü vb. gürültülerden işaretin filtreler yardımıyla temizlenmelidir.

Bu adımlar gerçekleştirildikten sonra sayısal işaret işleme adımları gerçekleşmektedir.

1. Veri toplama: Analog bir işaretin sayısal bir işarete dönüştürülebilmesi için ADC'ler tarafından örneklenerek ayrık bir biçime dönüştürülmesi gerekir.
2. Sayısal süzme: Vücuttan alınan ve kuvvetlendirilen işaret, çoğu zaman, analog işaret işleme ünitelerinden geçtikten sonra bile üzerinde gürültü bileşenleri taşıyor olabilir. Bu gürültüler çeşitli sayısal filtreler tarafından yok edilebilir.
3. Veri azaltma: Veri azaltma bilgi sıkıştırmanın dallarından biridir.
4. Amaca yönelik işaret işleme: Bazen işaret üzerinde, özel amaçlar için özel işaret işleme teknikleri kullanılabilir.(Fourier Dönüşümü, z-dönüşümü vb.)
5. Öznitelik bulma: Biyolojik işaretlerin önemli parametrelerinin bulunması işlemidir. Bu parametrelerden bazıları periyodu, gecikme süresi şekil faktörleri (yükselme ve düşme hızları, dalganın süresi vb.) gibi parametrelerdir.
6. Sınıflama: Gözlenen işaretinin ele alınan sınıflardan hangisine dahil olduğunun bulunmasıdır.

2.5 Biyolojik işaretlerin sınıflandırılması

Biyolojik ve fiziksel sistemlerden elde edilen işaretlerin çeşitli özellik ve karakteristikleri vardır. Uygun işaret işleme metotların uygulanabilmesi için işaretin ve işarete karışmış olan gürültülerin genel karakteristiklerinin bilinmesi önem kazanır. İşaretleri iki ana grup altında toplamak mümkündür. Bunlar deterministik (belirgin) işaretler ve rasgele (random) işaretlerdir.

Deterministik işaretler, açık ve belirgin matematiksel bağıntılarla ifade edilen işaretlerdir. Bu bağıntılar zaman ya da frekansın birer fonksiyonu olarak tanımlanabilir ve sonlu sayıda

parametre içerir. Rasgele işaretler ise tam olarak matematiksel bağıntılarla ifade edilemez ancak olasılıksal ve istatistiki verilerle belirlenebilirler.

Deterministik işaretleri periyodik ve periyodik olmayan işaretler diye ikiye ayırmak mümkündür. Periyodik işaretlerin bir periyotluk kısmı işaretin tamamını tanımlamakta yeterlidir. Periyodik olmayan işaretler ise hemen hemen periyodik ve süreksiz işaretler olmak üzere ikiye ayrılır. Hemen hemen periyodik işaretlerde temel frekansı birbirinden farklı olan işaretlerin kombinasyonudur. Süreksiz işaretler ise zaman içinde kısa bir süre ortaya çıkan ve periyodik olmayan işaretlerdir.

Rastgele işaretler durağan ve durağan olmayan işaretler olmak üzere ikiye ayrılır. Durağan işaretler, istatistik özellikleri zamanla değişmeyen işaretlerdir. Bu gruba giren işaretler “ergodik” işaretler olarak tanımlanır. Ergodiklik; bir işaretin herhangi bir anında alınan ortalamanın, işaretin herhangi bir elemanın zaman üzerindeki ortalamasına eşit olmasıdır. Durağan olmayan süreçler hesaplanması en zor süreçlerdir. Bu yüzden durağan olmayan işaretleri her biri durağan olarak varsayılan bölümlere (segment) ayırarak durağanlaştırılmış olarak analiz yapılabilir.

2.6 EMG işaretlerinin analizi

EMG işaretlerinin analizini dört alt başlık altında incelemek mümkündür.

1. Modelleme
2. Zaman Domeni Analizi
3. Frekans Domeni Analizi

2.6.1 Modelleme

Sistem üzerindeki çalışmalarda, model kurma ve sistem simülasyonu, son yıllarda büyük başarı göstermiştir. Bunun en önemli nedeni modellemeyi kolaylaştıran sistem teorisi ve bilgisayar teknolojisindeki ilerlemelerdir. Model kurma, Biyomedikal mühendisleri tarafından daha geniş olarak kullanılmakta ve insan vücudundaki sistemlerin matematiksel modelleri kurularak bu sistemlerin dinamik davranışları ve çalışmaları iyi bir şekilde incelenebilmektedir. Modeller, sistem parametrelerinin direkt olarak ölçülemediği durumlarda sistem giriş ve çıkışları ölçülerek buradan parametre kestirime gidilmesi konusunda başarılı olarak kullanılmaktadır. Bu bağlamda modelleme, sistem modellemesi ve işaret modellemesi (parametrik modelleme) olarak iki başlık altında incelenebilir.

Sistem modellemesi; Sistemi temsil edecek olan modeli kurabilmek için öncelikle, sistem içindeki mekanik, kimyasal ve fiziksel olayları ve bu olaylara ilişkin temel bağıntıları bilmek gerekmektedir. Bu bağıntıların matematiksel ifadeleri oluşturularak, buradan sistemin çalışmasının ve dinamiğinin daha iyi analiz edileceği ortamdaki modeline geçilir. Model kurulduktan sonraki aşamada model parametreleri belirlenir ve sistem ve model girişleri aynı olduğu anda sistem ve model çıkışlarının da aynı olması gerektiğine dikkat edilmelidir. Parametreler belirlendikten sonraki adım modelin test edilmesidir. Uygun test sonuçları sonunda model artık kullanılmaya hazırdır. Elde bulunan matematiksel model aynı zamanda bilgisayar ortamında ve analog ortamda simüle edilebilir.

Parametrik modelleme; Bu modelleme çeşidinde sistemin fiziksel modeli ortada yoktur. Ancak sistemi temsil eden çıkış işaretinin, belli bir matematiksel forma uydurulması ve bu forma uydurulması ve bu formdaki parametrelerin belirlenmesi söz konusudur. Zaman Serileri Analizi veya Doğrusal Öngörme (Linear Prediction) olarak da bilinen bu modelleme çeşidinin belli başlıları durağan olduğu varsayılan işaretlere uygulanan Öz bağılanımlı model (Autoregressive model), Yürüyen Ortalama (Moving Average) modeli ve bunların karışımı olan Öz bağılanımlı Yürüyen Ortalama modelidir. Parametrik modellemede süreç, oransal ve nedensel olarak modellenir. Süreç modellendikten sonra parametrelerle temsil edildiği için, bu işlem, veri sıkıştırma ve sınıflama amaçlarına yönelik olarak tıp elektroniğinde yaygın olarak kullanılmaktadır.

2.6.2 Zaman Domeni Analizi

Bir işaretin, incelenebilecek olan ve işareti karakterize eden birçok zaman domeni ölçümü veya parametresi vardır. Bunların en önemlisi işaretin ortalama (2.3) ve efektif değerleridir (2.4). İşaret rastgele ise bu parametreler işaretin ortalama değeri ile varyansı (2.5) olmaktadır. Bunlar, $x(n)$ ayrık zaman ve $x(t)$ sürekli zaman işaretleri için aşağıdaki eşitlikteki gibi ifade edilebilir.

$$x_0 = \bar{x} = \frac{1}{N} \sum_{n=1}^N x(n) \quad \bar{x} = \frac{1}{T} \int_0^T x(t).dt \quad (2.3)$$

$$x_{rms} = \sqrt{\frac{1}{N} \sum_{n=1}^N x^2(n)} , \quad x_{rms} = \sqrt{\frac{1}{T} \int_0^T x^2(t)dt} \quad (2.4)$$

$$\sigma_x^2 = \frac{1}{N-1} \sum_{n=1}^N [x(n) - \bar{x}]^2 = \frac{1}{N-1} \left[\sum_{n=1}^N x^2(n) - N \cdot \bar{x}^2 \right] \quad (2.5)$$

İşaret ortalamasının kullanıldığı ortak amaçlardan biri de işarettteki işaret/gürültü oranı iyileştirmektir. EMG işaretlerinin analiz etmek ve kasların fizyolojik durumlarını anlamak için frekans domeninde olduğu kadar olduğu kadar zaman domeninde de pek çok parametre kullanılmaktadır. Bu parametreler için mutlak değer ortalama, efektif değer, mutlak değer integral sırasıyla (2.6), (2.7) ve (2.8)'deki gibidir.

$$\overline{|x(t)|} = \frac{1}{T} \int_{t=0}^T |x(t)| dt \quad (2.6)$$

$$x_{rms} = \sqrt{\frac{1}{T} \int_{t=0}^T x^2(t) dt} \quad (2.7)$$

$$I|x(t)| = \int_{t=0}^T |x(t)| dt \quad (2.8)$$

Eşitlikleriyle, sürekli zaman işaretleri için yazılmış olan işaretin mutlak değer ortalaması, efektif değeri ve mutlak değer integrali örnek olarak verilebilmektedir. Bu parametrelere bakılarak kas hastalıklarının incelenmesi, kas yorgunluk seviyelerinin belirlenmesi ve otomatik kol-bacak protezlerinin kontrolü gerçekleştirilebilmektedir.

2.6.3 Frekans Domeni Analizi

Sonlu bir deterministik ayrık-zaman işaretinin, $x(k)$, enerji spektrum yoğunluğu işaretin ayrık zaman Fourier dönüşümünün genliğinin karesine eşittir ($|X(e^{j\omega})|^2$). Bu tanım Parseval teoreminin bir sonucudur[94]. Geniş çaplı durağan bir stokastik sürecin ayrık-zaman Spektral

Güç Yoğunluğu (PSD), işaretin otokorelasyon fonksiyonunun Ayrık-Zaman Fourier dönüşümü olarak tanımlanır.

$$S_{mm}(e^{j\omega}) = \sum_{k=-\infty}^{\infty} r_{mm}(k) e^{-j\omega k} \quad (2.9)$$

Burada;

$e^{-j\omega k}$: işaretin k. harmoniği

$r_{mm}(k)$: işaretin otokorelasyon fonksiyonu

(2.9)'da otokorelasyon dizisi sürecin bütün hesaplamalarını içeren tahminleri bulundurmaktadır. Açıkçası pratikte bu verilerin toplanması mümkün değildir. Bununla birlikte; Ergodik süreç durumunda kestirim işlemini o ana ait ortalama ile yer değiştirirsek otokorelasyon dizisi tahmin edilebilir. Sınırlı sayıda örnek olması durumunda otokorelasyon dizisi aşağıdaki şekli alır.

$$\hat{r}_{mm}(k) = \frac{1}{L} \sum_{\ell=0}^{L-1-k} m(k+1)m(\ell) \quad 0 \leq k \leq L \quad (2.10)$$

(2.9)'da $r_{mm}(k)$ ile $\hat{r}_{mm}(k)$ ile yer değiştirirsek sürecin güç spektrumunu hesaplayabiliriz. Kestirilmiş otokorelasyon dizisi sistematik hatayı (bias) azaltmak için genellikle pencerelenir. Bu sayede;

$$\hat{S}_{mm}(e^{j\omega}) = \frac{1}{L} \left| M(e^{j\omega}) \right|^2 \quad (2.11)$$

(2.11)'de belirtilen kestirici (estimator), Periodogram olarak tanımlanır. Periodogram Güç Spektrumunun asimptotik yansız kestiricisidir (unbiased estimator).

2.7 EMG işaretlerinin uygulama alanları

Klinik elektromiyografi (EMG), içeriği bakımından kas, motor ve duysal sinirler, refleks'ler ve motor sistemini doğrudan ya da dolaylı olarak kapsadığından ötürü, ilgi alanı da çeşitli uzmanlık dalları arasında paylaşılmaktadır. Örneğin EMG sadece Nöroloji'nin değil, ayrıca Nöroşiruji, Fizik Tedavi ve Rehabilitasyon, Ortopedi ve Travmatoloji, Römatooloji, Çocuk Nörolojisi gibi uzmanlık dallarının da ilgi alanına girmiştir.


Yüzeyel EMG sinyallerinin analizi, kuvvet tahmini ve kas yorgunluğunun belirlenmesi çalışmalarında sıklıkla kullanılmaktadır. Ayrıca rehabilitasyon tıbbında, ergonomide, fizyoloji çalışmalarında, kas ve sinir hastalıklarının teşhisinde de EMG sinyallerinden yararlanılmaktadır.

3. EMG İŞARETİNİN KAYIT TEKNİĞİ ve MODELLENMESİ

EMG sinyal kaydetme işlemi ilk zamanlar, ölçüm yapılacak olan kasa ince iğnelerin sokulması ve bu iğnelere bağlı kabloların sinyalleri iletilmesiyle yapılmaktaydı. Elektrod kullanılan yüzeyel ölçüm yöntemine oranla daha doğru ve net sonuçlar vermesine rağmen bu yöntem, ölçüm yapılan insanlara acı vermekte ve bu özelliğiyle sinyal kayıt işlemlerini zor duruma sokmaktadır. Biomedikal çalışmalar üzerine son yıllarda yapılan yoğun çalışmalar neticesinde, elektrodların kullanıldığı yüzeyel EMG sinyal ölçümlerinde elde edilen sonuçların doğruluğu neredeyse iğne kullanılanların ki kadar iyileştirilmiştir. Bu bölümde detaylı olarak yüzeyel EMG sinyallerinin sağlıklı bir şekilde kaydetme yöntemlerinden bahsedilecektir.

EMG sinyali kaydedilirken, sinyalin doğruluğunu etkileyen en önemli unsurlardan biri, sinyal/gürültü (noise), yani EMG sinyalindeki enerjinin, gürültünün enerjisine oranıdır. Genelde gürültü, EMG sinyalindeki istenmeyen elektriksel sinyal olarak tanımlanır. Gürültü farklı kaynaklardan oluşabilir. Örneğin her elektronik cihaz elektriksel bir gürültü oluşturur. Bu gürültünün frekansı sıfırdan birkaç bin Hz'e kadar değişebilir. Bu gürültü tamamıyla engellenemez. Ancak yüksek kalitede cihazlar, zeki devre ve ileri tasarım teknikleri kullanılarak gürültü kirliliği seviyesi düşürülebilir. Elektrik güç hatları, lambalar, televizyon vb. cihazların herbiri elektromanyetik radyasyon 27 kaynaklarıdır. Ayrıca elektrod-deri arasındaki yüzey ve elektrodları yükselticiye ulaştıran kabloların hepsi elektriksel gürültü oluşturabilirler. Gürültüyü, gerçek sinyalden ayırtmak için kullanılabilecek filtreleme yöntemleri, sinyalin karakteristiğinin tam olarak belirlenmesini önleyici olabilir. Dolayısıyla


EMG sinyalinin kaydedilmesi esnasında, sinyalin davranışını bozabilecek her türlü gereksiz filtreleme ve sinyal düzeltme işlemlerinden kaçınılması gerekmektedir. Yaklaşık olarak 0-10 mV arasında değişen EMG sinyal genliği, rastgele (stochastic) bir dağılım gösterir. Sinyalin kullanılabilir enerji aralığı, 0-500 Hz frekans değerleri arasındadır. Kullanılabilir enerjiden kastedilen, genliği elektriksel gürültü seviyesinin yukarısında bulunan sinyallerdir. 0-150 Hz arası ise sinyal genliğinin en büyük olduğu frekans değerleridir. Şekil 3.1'de, bir EMG sinyali ve frekans spektrumunun örneği görülmektedir.



Şekil 3.1: EMG sinyalinin frekans spektrumu


EMG ölçümlerinde kullanılan elektrodların, sinyalin özelliklerini etkileme konusunda önemli rolleri vardır. EMG sinyali kaydedilirken, ölçüm yapılan kasa yakın kaslardaki elektrik aktivasyonu, gerçek sinyale karışabilir ve bundan ötürü sinyalin özelliğini bozabilir. Yanses olarak adlandırılan bu durumun ortaya çıkmasında, büyük yüzeye sahip elektrodların da etkisi vardır. Dolayısıyla elektrod yüzeyinin olabildiğince küçük tutulması, sağlıklı EMG sinyal ölçümü için uygulanan yöntemlerden biridir.

Sinyalin doğru kaydedilmesi için dikkat edilmesi gereken hususlardan bir tanesi de, kas yüzeylerine yerleştirilen elektrodların, kas yüzeyine temas yerlerinin doğru belirlenmesidir. Elektrodların, kasta oluşan elektriksel aktivasyonu tam olarak algılayabilmesi için, kasın tam orta noktalarına yerleştirilmeleri gerekir. Şekil 3.2’de, aynı kasta, farklı bölgelere yerleştirilen elektrodlardan alınan sinyallerin değişik genliklerde olduğu gözlemlenebilir. Şekilde görüleceği üzere, kasın merkezi dışına yerleştirilen bölgelerdeki elektrodlardan kaydedilen EMG sinyallerinin genlikleri, merkeze yerleştirileninkine oranla daha küçüktür. Aynı etki, frekans dağılımlarında da (spektrum) görülmektedir.



Şekil 3.2: Farklı bölgedeki elektrodların sinyal üzerine etkisi

Bu tez çalışması kapsamında elektrodlar, yukarıda anlatılan sebepler dolayısıyla kasların merkezlerine yerleştirilmiştir. Kullanılan yüzeyel elektrotlar Şekil 3.3'teki gibidir.



Şekil 3.3 Uygulamada kullanılan yüzeyel elektrotlar.

Ayrıca, EMG sinyallerini elektriksel gürültüden ayırt etmek için 5Hz ile 500 Hz band geçiren

filtreler kullanılmıştır. Bir sonraki bölümde uygulamada kullanılan kasların görevleri ve kayıt alma şeklinden bahsedilecektir.


3.1 Biceps kası görevleri ve EMG işaretinin kayıt teknikleri

Biceps kası kol ve bacaklarda bulunan uzun bir kastır. Biceps kasının en önemli görevi dirsek kısmını bükülmesi ve kolun dirsekle arasındaki bölgesinin hareket ettirilmesidir. Şekil 3.4'te Biceps kasının yeri gösterilmiştir.



Şekil 3.4 Biceps kası (Upper Extremity Muscle Atlas Michael L. Richardson, M.D.)

Veri toplanmasında Biceps kasına uygulana elektrot yerleşimi Şekil 2.5'teki gibidir. Burada kırmızı kabloyla ölçüm düzeneğine bağlanan elektrot referans elektrotudur. Siyah kablo ile ölçüm düzeneğine bağlanmış olan elektrot ise işaret ölçümünün yapıldığı aktif elektrottur.




Şekil 3.5 Biceps kası için elektrot yerleşimi

Bu kasta ölçüm için kol dirsekten 90°'lik bir açıyla bükülerek 2 kg. ağırlığında bir yükle kasılması sağlanmış ve EMG işaretleri yüzeysel elektrotlar ile alınmıştır. Ölçüm tekniği şekil 3.6'da gösterilmiştir.



Şekil 3.6 Biceps kası için EMG ölçüm düzeneği

Bu ölçümler sonucunda Şekil 3.7’deki Biceps kasına ait EMG işareti elde edilmiştir.



Şekil 3.7 Ölçüm aşamalarının sonucunda elde edilen Biceps kasına ait EMG işareti

3.2 Frontalis kası görevleri ve EMG işaretinin kayıt teknikleri

Frontalis kası kaş üstünde bulunan bir kas çeşididir. Frontalis kasının görevleri ise gözün kasılmasını ve kaş hareketlerini organize etmektedir. Şekil 3.8’de Frontalis kasının yeri gösterilmiştir.



Şekil 3.8’de Frontalis kası

Veri toplanmasında Frontalis kasına uygulana elektrot yerleşimi Şekil 3.9'daki gibidir. Burada kırmızı kabloyla ölçüm düzeneğine bağlanan elektrot referans elektrotudur. Siyah kablo ile ölçüm düzeneğine bağlanmış olan elektrot ise işaret ölçümünün yapıldığı aktif elektrottur.




Şekil 3.9 Frontalis kası için elektrot yerleşimi

Bu kasta ölçüm için kaşın 10 sn boyunca kaldırılması sağlanmış ve EMG işaretleri yüzeyel elektrotlar ile alınmıştır. Ölçüm tekniği şekil 3.10'da gösterilmiştir.



Şekil 3.10 Frontalis kası için EMG ölçüm düzeneği


Bu ölçümler sonucunda Şekil 3.11'deki Frontalis kasına ait EMG işareti elde edilmiştir.



Şekil 3.11 Ölçüm aşamalarının sonucunda elde edilen Frontalis kasına ait EMG işareti


3.3 Abduktör Pollisis Brevis kası görevleri ve EMG işaretinin kayıt teknikleri

Abduktör Pollisis Brevis (APB) kası başparmağın üstünde bulunan bir kas çeşididir. Şekil 3.12'de APB kasının yeri gösterilmiştir.




Şekil 3.12 APB kasının yeri(Upper Extremity Muscle Atlas Michael L. Richardson, M.D.)

APB kasının görevi parmak hareketlerini organize etmektir. Bu kasta ölçüm için başparmağın ucu serçe parmağın ucu ile birleştirilmiştir. Bu sayede kasın kasılması sağlanmıştır. Ölçüm için elektrot yerleşimi şekil 3.13'deki gibidir. Siyah kablo ile ölçüm düzeneğine bağlanmış olan elektrot ise işaret ölçümünün yapıldığı aktif elektrottur.



Şekil 3.13 APB kası için elektrot yerleşimi ve ölçüm düzeneği

10 sn boyunca parmakların birbirini tutması sağlanmış ve EMG işaretleri yine yüzey elektrotları ile alınmıştır. Bu ölçümler sonucunda Şekil 3.14'deki APB kasına ait EMG işareti elde edilmiştir.



Şekil 3.14 Ölçüm aşamalarının sonucunda elde edilen Frontalis kasına ait EMG işareti

3.4 EMG İşaretlerinin Parametrik Modellenmesi

Eğer bir sürecin istatistiksel özellikleri zaman ile değişiyor ise bu tür bir süreç için durağan olmayan süreç denebilir. EMG işaretlerinin de istatistiksel özellikleri zamanla değiştiği için durağan değildir. Bu yüzden sürecin spektrum analizini kestiriciler ile yapmak uygun değildir. Özellikle, geçmiş spektrum analiz teknikleri her hangi bir zaman uyarlaması yapmadan frekans bilgisi verir. Örneğin; yüzeysel EMG işaretlerinin kas kasılmaları sonucu karakteristikleri değişir. Eğer bu işaret yorucu ve uzun bir süre alınıyorsa ve bütün alınan verilerden tek bir spektrum analizi yapılıyorsa, kasılma anındaki değişiklikler hakkında hiçbir bilgi elde edilemez. Sadece frekans içerikleri ile ilgili ortalama değerler elde edilebilir. Bütün zaman ve frekans içeriklerini elde edebilmek için yapılabilecek en basit uygulama; işaretleri parçalara (epoch) bölmektir. Her bir adımda işaret geniş çaplı durağan (wide sense stationary) olarak kabul edilebilir. Bu yöntem kısa-süreli Fourier dönüşümünün temelini oluşturmaktadır. Öz Bağımlı (Auto-regressive) metotlar için ise veriyi pencereleyerek işaret durağanlaştırılır.

Bu bölümün altında öz bağımlı modellerin oluşturulabilmesi için gerekli olan temel kavramlar açıklanacaktır.

3.4.1 Durağan Süreçler ve Modeller

Stokastik süreç veya rasgele süreç terimleri; olasılık kurallarına bağlı olan istatistiksel olayların zaman değişiminin tanımlanması için kullanılır. Zaman değişiminden kasıt stokastik sürecin belirli bir gözlem aralığında değişen zamanın bir fonksiyonu olduğudur. Olayın istatistiksel doğası derken zaman içindeki değişimi tam manası ile tarif edilememesi anlamına gelmektedir. Stokastik süreç örnekleri konuşma işaretleri, televizyon işaretleri, radar işaretleri, sayısal bilgisayar verileri, iletişim kanal çıkışları, sismik veriler ve gürültü gösterilebilir.

İlgilenilen stokastik süreçlerden biri, anlık zaman içerisinde ayrık ve düzenli olarak belirtilen süreçlerdir (Box ve Jenkins,1976; Priestly, 1981). Bilgisayar verileri ve radar işaretleri gibi uygulama alanlarında yukarıdaki gibi sınırlamalar görülmektedir. Buna ilaveten Stokastik süreçler zamanın gerçek değerleri içinde tanımlanabilir. Bu tanımlamayı yaparken zamanda düzenli örnekleme yapılmalı ve örnekleme oranının en yüksek frekans elemanın 2 katı seçilmiş olması gerekmektedir (Haykin, 1988).

Stokastik süreçler sadece zamanın tekil bir fonksiyonu değildir, aynı zamanda teoride sürecin sonsuz sayıda gerçekleşmesidir. Ayrık-Zaman Stokastik Süreçlerin bir özel gerçekleşmesi

Ayrık-Zaman serileri veya basitçe zaman serileri olarak isimlendirilir. Notasyonun uygunluğu için örnekleme periyoduna uygun olarak zaman normalize edilmiştir. Örneğin, $u(n)$, $u(n-1)$, $\dots$, $u(n-M)$ dizisi $u(n)$ 'nin “ n ” anındaki şimdiki değeri ve “ $n-1$ ”, $\dots$, “ $n-M$ ” anlarındaki M adet geçmiş değerinin oluşturduğu bir zaman serisidir.

Bir zaman ötelemesi sonucu sürecin istatistiksel özellikleri değişmez ise sürecin “katı bir biçimde durağan” tanımlaması yapılabilir.

3.4.2 Ayrık – Zaman Stokastik Süreçlerin Kısmi Karakterizasyonu

Pratikte, stokastik süreç üzerinde yapılan ardışık incelemelere ait birleşik olasılık yoğunluk fonksiyonlarının belirlenmesi mümkün değildir. Bu bağlamda, sürecin 1. ve 2. hareketlerini belirten kısmi bir karakterizasyon yapılmalıdır.

$u(n)$, $u(n-1)$, $\dots$, $u(n-M)$ ile gösterilen bir ayrık – zaman stokastik süreç ele alalım, sürecin ortalama değerini (mean – value) şu şekilde tanımlayabiliriz,

$$\mu(n) = E[u(n)] \quad (3.1)$$

Burada E istatistiksel tahmin (expectation) operatörüdür. Sürecin oto korelasyon fonksiyonunu şu şekilde tanımlayabiliriz,

$$r(n, n-k) = E[u(n)u^*(n-k)], k=0, \pm 1, \pm 2, \dots, \quad (3.2)$$

“*” kompleks konjugeyi göstermektedir. Oto kovaryans fonksiyonunu şu şekilde tanımlayabiliriz,

$$c(n, n-k) = E[(u(n) - \mu(n))(u(n-k) - \mu(n-k))^*], k=0, \pm 1, \pm 2, \dots, \quad (3.3)$$

(3.1) ve (3.2) denklemlerinden, sürecin ortalama değer, oto korelasyon, oto kovaryans fonksiyonlarının ilişkisi Denklem 3.4'deki gibidir.

$$c(n, n-k) = r(n, n-k) - \mu(n)\mu^*(n-k) \quad (3.4)$$

Kısmi karakterizasyon için birçok n ve k değerleri için ortalama değer, oto korelasyon ve oto kovaryans fonksiyonlarının belirlenmesi gerekir.

Bu tip bir kısmi karakterizasyonun iki önemli avantajı bulunmaktadır.

- 1) Pratik ölçme sağlar.
- 2) Stokastik süreçler üzerindeki lineer işlemler için çok uygundur.

Katı bir biçimde durağan olan stokastik süreçler için (3.1), (3.2) ve (3.3) denklemleri daha basit bir şekilde kabul edilebilir. (3.1) denklemi için,

$$\mu(n) = \mu, \text{ bütün } n\text{'ler için} \quad (3.5)$$

Oto korelasyon ve oto kovaryans fonksiyonlarının ise n ve $n-k$ inceleme zamanlarının arasındaki farka (ki buda k 'dır) bağımlı olduğu bulunmuştur.

$$r(n, n-k) = r(k) \quad (3.6)$$

ve

$$c(n, n-k) = c(k) \quad (3.7)$$

$k=0$ olduğunda $r(0)$ değeri $u(n)$ 'nin ortalama karesel değerine eşit olmaktadır.

$$r(0) = E[|u(n)|^2] \quad (3.8)$$

ve $c(0)$ 'da $u(n)$ 'nin varyansına eşit olmaktadır.

$$c(0) = \sigma^2 \quad (3.9)$$

(3.5), (3.6) ve (3.7) ayrık – zaman stokastik sürecin katı bir biçimde durağan olduğunu garanti etmek için yeterli değildir. Bu özellikleri barındıran fakat katı bir biçimde durağan olmayan stokastik süreçler için geniş çapta duyarlı (wide - sense) veya 2. dereceden durağan tanımlamaları yapılabilir. Katı bir biçimde durağan olan bir sürecin geniş çaplı durağan olarak nitelendirilebilmesi için gerek şart ise (Doob , 1953)

$$E[|u(n)|^2] < \infty, \text{ bütün } n \text{ ' ler için}$$

3.4.3 Korelasyon Matrisi

$M \times 1$ 'lik gözlem vektörü $u(n)$; $u(n)$, $u(n-1)$, ... , $u(n-M+1)$ zaman serisinin elemanlarını temsil etsin.

$$\mathbf{u}^T(n) = [u(n), u(n-1), \dots, u(n-M+1)] \quad (2.10)$$

Burada T transpozeyi göstermektedir. Durağan ayırık – zaman stokastik sürecin korelasyon matrisi, zaman serisinin gözlem vektörü $u(n)$ 'nin ürünleri ve kendisinin tahmini olarak gösterilmektedir. $\mathbf{R}$; $M \times M$ 'lik ve bu yolla oluşturulan korelasyon matrisi olsun. Böylece;

$$\mathbf{R} = E [u(n)u^H(n)] \quad (3.11)$$

H ; burada Hermitian Transpozesidir. (3.10) ve (3.11) denklemlerini birbirinden çıkartarak ve geniş çaplı durağanlık ilkesini kullanarak korelasyon matrisi $\mathbf{R}$ 'nin açılmış biçimini açıklayabiliriz:

$$R = \begin{bmatrix} r(0) & r(1) & . & . & . & r(M-1) \\ r(-1) & r(0) & . & . & . & r(M-2) \\ . & . & . & . & . & . \\ . & . & . & . & . & . \\ . & . & . & . & . & . \\ r(-M+1) & r(-M+2) & . & . & . & r(0) \end{bmatrix} \quad (3.12)$$

Köşegende bulunan $r(0)$ değerleri her zaman için gerçektir ve diğer elemanlar kompleks değerler olabilirler.

Korelasyon Matrisinin Özellikleri

Korelasyon matrisi $\mathbf{R}$; istatistiksel analizde anahtar bir rol üstlenmektedir. Bu yüzden korelasyon matrisinin özelliklerini iyi bir şekilde anlamak gerekmektedir. Kısacası; (3.11) denklemini kullanarak durağan ayırık zamanlı stokastik sürecin korelasyon matrisine ait aşağıdaki özellikler belirtilmiştir.

Özellik 1. Durağan ayırık zamanlı stokastik sürecin korelasyon matrisi Hermitiandır. Kompleks değerli bir matris eğer konjuge transposuna eşit ise bu matris hermitiandır.

$$\mathbf{R}^H = \mathbf{R} \quad (3.13)$$

Korelasyon matrisi $\mathbf{R}$ 'nin Hermitian olduğunu belirlemek için bir diğer yol ise stokastik süreç oto korelasyon fonksiyonu $r(k)$ 'nin aşağıdaki şekilde yazılması ile elde edilir.

$$r(-k) = r^*(k) \quad (3.14)$$

Geniş-çaplı stokastik sürece ait korelasyon matrisi R 'yi tanımlayabilmek için; $k=0,1,\dots,M-1$ değerleri için oluşan oto korelasyon fonksiyonu $r(k)$ “ M ” değerlerine ihtiyaç duyulmaktadır.

$$R = \begin{bmatrix} r(0) & r(1) & \cdot & \cdot & \cdot & r(M-1) \\ r^*(1) & r(0) & \cdot & \cdot & \cdot & r(M-2) \\ \cdot & \cdot & \cdot & & & \\ \cdot & \cdot & & \cdot & & \\ \cdot & \cdot & & & \cdot & \\ r^*(M-1) & r^*(M-2) & \cdot & \cdot & \cdot & r(0) \end{bmatrix} \quad (3.15)$$

Buradan, yukarıda ki gösterimi geniş-çaplı durağan ayrık zaman stokastik sürece ait korelasyon matrisinin genişletilmiş halinin yazılması için kullanılacaktır. Gerçek – değerli veriler için her k için $r(k)$ reeldir ve korelasyon matrisi R simetriktir.

Özellik 2: Durağan ayrık zaman stokastik sürecin korelasyon matrisi *Toeplitz*'dir.

Eğer karesel matrisin ana köşegenindeki elemanlar birbirine eşit ve ana köşegene paralel olan diğer elemanlar birbirine eşit ise bu matris *Toeplitz*'dir. (3.14)'ü kullanarak ana köşegendeki elemanların birbirine eşit olduğu ve ana köşegene paralel olan elemanların birbirine eşit olduğu gözlemleri yapılabilir. Bu sayede korelasyon matrisi R 'nin *Toeplitz* olduğu aşıkardır.

Gözlem vektörü $u(n)$ tarafından gösterilen ayrık zaman stokastik sürecinin geniş çaplı durağan olduğu kabulünün direk bir sonucu R matrisinin *Toeplitz* olduğudur.

Özellik 3: Negatif olmayan belirlilik Herhangi bir kompleks değerli X vektörü için ilişki matrisi R aşağıdaki özelliği sağlar.

$$X^H R X \geq 0 \quad (3.16)$$

Böylece R ilişki matrisi daima negatif olmayan veya pozitif yarı belirli bir matristir.

Özellik 4: Durağan ayrık-zamanlı bir sürecin gözlem vektörünü oluşturan elemanların geriye doğru düzenlenmesi (backward rearrangement) ile oluşan etki korelasyon matrisinin transpozunu almayla eşdeğerdir.

$u^{BT}(n)$; $u(n)$ 'nin geriye doğru düzenlenmesini göstermektedir. Buna göre;

$$\mathbf{u}^T(n) = [u(n), u(n-1), \dots, u(n-M+2), u(n-M+1)] \quad (3.17)$$

$$\mathbf{u}^{BT}(n) = [u(n-M+1), u(n-M+2), \dots, u(n-1), u(n)] \quad (3.18)$$

Burada “ B ” geriye doğru ifadesini temsil etmektedir. $\mathbf{u}^B(n)$ vektörüne ait korelasyon matrisi aşağıdaki şekildedir.

$$E[\mathbf{u}^B(n)\mathbf{u}^{BH}(n)] = \begin{bmatrix} r(0) & r^*(1) & \cdot & \cdot & \cdot & r^*(M-1) \\ r(1) & r(0) & \cdot & \cdot & \cdot & r^*(M-2) \\ \cdot & \cdot & \cdot & & & \\ \cdot & \cdot & & \cdot & & \\ \cdot & \cdot & & & \cdot & \\ r(M-1) & r(M-2) & \cdot & \cdot & \cdot & r(0) \end{bmatrix} \quad (3.19)$$

(3.19)’u (3.15)’e göre düzenlersek aşağıdaki tanımlama ortaya çıkar.

$$E[\mathbf{u}^B(n)\mathbf{u}^{BH}(n)] = \mathbf{R}^T \quad (3.20)$$

Özellik 5: Durağan ayırık-zaman stokastik bir sürecin M ve $M+1$ anlarındaki gözlemlerinden oluşan $\mathbf{R}_M$ ve $\mathbf{R}_{M+1}$ korelasyon matrisleri arasındaki ilişkiyi gösterirsek;

$$\mathbf{R}_{M+1} = \left[\begin{array}{c|c} \mathbf{r}(0) & \mathbf{r}^H \\ \hline \mathbf{r} & \mathbf{R}_M \end{array} \right] \quad (3.21)$$

veya

$$\mathbf{R}_{M+1} = \left[\begin{array}{c|c} \mathbf{R}_M & \mathbf{r}^{B*} \\ \hline \mathbf{r}^{BT} & \mathbf{r}(0) \end{array} \right] \quad (3.22)$$

Burada $r(0)$ sürecin sıfır zaman farkı için öz ilişkisidir (autocorrelation).


$$\mathbf{r}^H = [r(1), r(2), \dots, r(M)] \quad (3.23)$$

ve

$$\mathbf{r}^{BT} = [r(-M), r(-M+1), \dots, r(-1)] \quad (3.24)$$

3.5 Stokastik Modeller

Model terimi; ilgilenilen verileri anlamakta yardımcı olan saklı kuralları açıklayan veya tanımlayan herhangi bir hipotez için kullanılır. Stokastik bir sürecin bir modelle gösterilmesi Yule (1927) tarafından ortaya atılan bir fikre göre başlamıştır. Bu fikir; gözlemlerle yüksek derecede ilişkili olan bir zaman serisi, $u(n)$, birbirinden istatistiksel olarak bağımsız olan bir dizi şokun (shocks) şeklindeki gibi lineer bir filtreye, $v(n)$, uygulanması ile elde edilebilmesidir.



Şekil 3.15 Rasgele süreç tarafından oluşturulan ayrık zaman stokastik süreç blok diyagramı

Şoklar genellikle sabit dağılım ile belirlenen rasgele değişkenlerdir. Bu dağılım genellikle sıfır ortalamalı ve sabit varyanslı Gauss dağılımıdır. Özel olarak şeklindeki girişi , $v(n)$, şu şekilde tanımlayabiliriz.

$$E[v(n)] = 0, \text{ bütün } n\text{'ler için} \quad (3.25)$$

$$E[v(n)v^*(k)] = \begin{cases} \sigma_v^2, & k = n \\ 0, & \text{aksitakdirde} \end{cases} \quad (3.26)$$

σ_v^2 burada gürültü varyansıdır.

Zaman domeninde şekilde belirtilen stokastik süreç için verilen giriş çıkış ilişkisi aşağıdaki şekilde yazılabilir.

$$\begin{pmatrix} \text{Modelin} \\ \text{çıkışının} \\ \text{şimdiki} \end{pmatrix} + \begin{pmatrix} \text{Modelin} & \text{çıkışının} \\ \text{geçmiş değerlerine ait} \\ \text{lineer kombinasyonu} \end{pmatrix} = \begin{pmatrix} \text{Modelin girişinin geçmiş} \\ \text{ve şimdiki değerlerine ait} \\ \text{lineer kombinasyonu} \end{pmatrix}$$

Şekil 3.16 Lineer filtre yapısı

Şekilde verilen lineer filtrenin yapısını denklemde belirtilen iki kombinasyonla belirlenir. Bu stokastik modelleri popüler olan 3 yolla yapabiliriz.

- 1) Öz bağımlı (Autoregressive) modeller
- 2) Hareketli Ortalamalı (Moving Average) modeller
- 3) Öz bağımlı Hareketli Ortalamalı (Autoregressive- Moving Average) modeller

3.5.1 Öz bağımlı (Autoregressive) Modeller

M. dereceden bir zaman serisi $u(n)$, $u(n-1)$, ..., $u(n-M)$, eğer aşağıdaki fark denklemini sağlıyorsa M.dereceden bir özbağımlı (AR) modeldir denir.

$$u(n) + a_1^* u(n-1) + a_2^* u(n-2) + \dots + a_M^* u(n-M) = v(n) \quad (3.27)$$

Burada $a_1, a_2, \dots, a_M$ sabitleri AR parametreleri olarak adlandırılır. $\{v(n)\}$ beyaz gürültü sürecidir. “Öz-bağımlı” kelimesi tam anlayabilmek için denklemi tekrardan yazalım.

$$u(n) = w_1^* u(n-1) + w_2^* u(n-2) + \dots + w_M^* u(n-M) + v(n) \quad (3.28)$$

Burada $w_k = -a_k$ 'dir. Burada sürecin şuan ki değeri $u(n)$, sürecin geçmiş değerlerinin sonlu lineer kombinasyonları olan $u(n-1)$, ..., $u(n-M)$ değerleri ile hata terimi olan $v(n)$ 'nin toplamıdır. Bu sayede “öz-bağımlı” teriminin kullanım nedeni görülmüştür. Genellikle, $x_1, x_2, \dots, x_n$ bağımsız değişkenleri ile bir hata terimi “v”nin toplamıyla oluşan kümeye bağımlı olan y değişkeninden oluşan lineer modele bağımlı (regression) model olarak tanımlanır.

$$y = \sum_{k=1}^M w_k^* x_k + v \quad (3.29)$$

(3.28)'te $u(n)$ değişkeni kendisinin önceki değerlerine bağımlıdır. Bu yüzden öz-bağımlı (autoregressive) olarak isimlendirilir. (3.27)'ün sol tarafı $u(n)$ giriş dizisinin ve a_n^* parametre dizisinin konvolüsyonunu göstermektedir. Bu denklemi konvolüsyon toplamı şeklinde tekrar yazarsak,

$$\sum_{k=0}^M a_k^* u(n-k) = v(n) \quad (3.30)$$

Burada $a_0=1$ 'dir. (3.30)'un her iki tarafının z-dönüşümünü alınırsa,

$$V(z) = H_A(z).U(z) \quad (3.31)$$

$$H_A(z) = \sum_{n=0}^M a_n^* z^{-n} \quad (3.32)$$

$$U(z) = \sum_{n=0}^{\infty} u(n) z^{-n} \quad (3.33)$$


$$V(z) = \sum_{n=0}^{\infty} v(n) z^{-n} \quad (3.34)$$

(3.31)'in z-dönüşümü $u(n)$ ÖB sürecinin kullanım şekline göre, yani giriş veya çıkış olmasına göre, iki türlü gösterim imkânı sağlar.

- 1) $u(n)$ 'i giriş olarak kabul eden Analiz metodu
- 2) $u(n)$ 'i çıkış olarak kabul eden Sentez metodu

3.5.1.1 Analiz metodu

Beyaz gürültü $\{v(n)\}$ 'i üretmek için ÖB bir süreç olan $\{u(n)\}$ 'i giriş olarak kullanan Şekil 3.17'deki filtre kullanılır. Filtrenin parametreleri ÖB süreç $\{u(n)\}$ 'nin parametreleri ile birebir eşleşme gösterir. Bu bağlamda, bu filtre $H_A(z) = V(z) / U(z)$ ayrık transfer fonksiyonuna sahip süreç analizörünü (process analyzer) gösterir. Süreç analizörünün dürtü yanıtı $H_A(z)$ 'nin ters z-dönüşümüdür. Bu dönüşüm sonlu sürelidir. Görüldüğü gibi $H_A(z)$ 'nin sadece sıfırları vardır. Böylece analiz modeli daima kararlıdır.



Şekil 3.17 Süreç analizörü

3.5.1.2 Sentez modeli


ÖB süreç $\{u(n)\}$ 'i üretmek için beyaz gürültü $\{v(n)\}$ 'i giriş olarak kullanan Şekil 3.18'deki filtre kullanılır. Bu bağlamda sözü geçen filtre bir süreç üreticiyi temsil etmektedir. bu filtrenin transfer fonksiyonu;

$$H_s(z) = \frac{U(z)}{V(z)} = \frac{1}{H_A(z)} = \frac{1}{\sum_{n=0}^M a_n^* z^{-n}} \quad (3.35)$$

Süreç üreticinin dürtü yanıtı $H_s(z)$ 'nin ters z-dönüşümüdür. Bu dönüşüm sonsuz sürelidir. Görüldüğü gibi $H_s(z)$ sadece kutupları vardır. Bu nedenle sentez modelinin kararlılığı kutuplarının yeri tarafından belirlenir.

$$H_s(z) = \frac{1}{(1 - p_1 z^{-1})(1 - p_2 z^{-1}) \dots (1 - p_M z^{-1})} \quad (3.36)$$

Bu sürecin kararlı olabilmesi için bütün kutuplarının z-düzleminde bulunan birim çember içinde bulunması gerekmektedir.



Şekil 3.18 Süreç üretici

3.5.2 Hareketli Ortalama (Moving Average) Modeller


Hareketli Ortalama modelinde, Şekil 3.15'deki ayrık-zaman lineer filtre beyaz gürültü tarafından sürülen tüm sıfır filtre içermektedir. Süreç sonucu olan $u(n)$ aşağıdaki fark denklemiyle tanımlanan filtre çıkışından oluşmaktadır.

$$u(n) = v(n) + b_1^* v(n-1) + \dots + b_K^* v(n-K) \quad (3.37)$$

$b_1, \dots, b_K$ parametreleri burada HO (hareketli ortalama) parametrelerini göstermektedir. (3.37)'de $v(n)$ hariç denklemin sağ tarafında kalan bütün terimler iç çarpımları göstermektedir. HO sürecinin derecesini "K" değeri ifade etmektedir. Eğer $v(n)$ 'nin tüm gerçeklemelerini verilmişse, $u(n)$ 'i; $v(n), v(n-1), \dots, v(n-K)$ değerlerinin ağırlıklı ortalamaları ile hesaplayabiliriz.

(3.37)'den Şekil 3.19'de verilen HO modeli elde edebiliriz. Burada öncelikle bir beyaz gürültü süreci ile başlanır ve model çıkışında derecesi "K" olan HO süreci $u(n)$ elde edilir.

Tersi durumda beyaz gürültü süreci $v(n)$ 'i üretmek için verilen bir HO süreci $u(n)$ için tüm kutup filtre kullanılır. Görüldüğü gibi HO sürecinde, süreç üretici ve analizörü için kullanılan filtreler ÖB süreçlerdekinin tam tersidir.



Şekil 3.19. Hareketli Ortalama Modeli (süreç üretici)


3.5.3 Öz Bağımlı Hareketli Ortalama (Autoregressive-Moving Average) Modeller

$u(n)$ Öz Bağımlı Hareketli Ortalama (ÖBHO) sürecini oluşturmak için transfer fonksiyonu tüm sıfır ve tüm kutup filtreleri içeren Şekil 3.15'deki ayrık zaman lineer filtre kullanılır. Süreç sonucu oluşan ve bir ÖBHO süreç olan $u(n)$ aşağıdaki fark denklemiyle tanımlanan filtre çıkışından oluşmaktadır.

$$u(n) + a_1^* u(n-1) + \dots + a_M^* u(n-M) = v(n) + b_1^* v(n-1) + \dots + b_K^* v(n-K) \quad (3.38)$$

Burada $a_1, \dots, a_M$ ve $b_1, \dots, b_K$ terimleri ÖBHO parametreleridir. (3.38)'in sağ taraftaki $u(n)$ ve sol taraftaki $v(n)$ hariç denklemin sağ ve sol taraflarında kalan bütün terimler iç çarpımları göstermektedir. ÖBHO sürecinin derecesini (M,K) değeri ifade etmektedir.

(3.38)'den Şekil 3.20'yi çıkartabilmek mümkündür. Şekil 3.20'yi Şekil 3.18 ve şekil 3.19 ile mukayese edersek ÖB ve HO modellerinin ÖBHO modelinin özel durumları olduğu gözlemlenir.



Şekil 3.20 (M,K) derecelerinde ÖBHO (süreç üretici) modeli

Hesapsal bakış açısıyla Öz bağımlı (ÖB) modelinin, Hareketli Ortalama (HO) modeli ve Öz Bağımlı – Hareketli Ortalama (ÖBHO) modeline göre avantajlıdır. Özellikle, Şekil 3.17’deki ÖB katsayıların hesaplanması Yule-Walker olarak bilinen doğrusal denklemlerin çözülmesi ile elde edilebilir. Ayrıca, Şekil 3.19’da verilen HO modeli ve Şekil 3.20’de verilen ÖBHO modeli katsayılarının hesaplanması daha karmaşıktır. Bu iki hesaplamaların yapılabilmesi için doğrusal olmayan denklemlerin çözülmesini içermektedir. Bu nedenle pratikte, ÖB modeller HO ve ÖBHO modellerine göre daha popülerdir.

3.5.4 Wold Ayrıştırması

Wold 1983 yılında, herhangi bir durağan ayırık zamanlı rasgele süreç; bir genel doğrusal süreç

ve bir deterministik sürecin toplamına eşit olan temel bir teoremi kanıtlamıştır.

$$x(n) = u(n) + s(n) \quad (3.39)$$

Burada;

- 1) $u(n)$ ve $s(n)$ ilişkisiz süreçlerdir.
- 2) $u(n)$; (3.40)'daki gibi gösterilen bir doğrusal süreçtir.

$$u(n) = \sum_{k=0}^{\infty} b_k^* v(n-k) \quad (3.40)$$

$b_0=1$ ve


$$\sum_{k=0}^{\infty} |b_k|^2 < \infty \quad (3.41)$$

ve $v(n)$; $s(n)$ ile ilişkisiz beyaz gürültü sürecidir.

$$E[v(n)s^*(k)] = 0 \text{ (bütün } k \text{ ve } n\text{'ler için)} \quad (3.42)$$

- 3) $s(n)$ deterministik (belirli) bir süreçtir. Yani bu süreç bir öngörü varyansı ile ve kendi geçmişi ile öngörülebilir.


Bu sonuçlar Wold ayrıştırma teoremi olarak bilinir. (3.40)'a göre; genel doğrusal bir süreç tüm sıfır filtre ve Şekil 3.21'deki gibi bir beyaz gürültü tarafından oluşturulabilir. Bu filtrenin transfer fonksiyonunun sıfırları denklemin köklerine eşittir.



Şekil 3.21 . Genel doğrusal süreç oluşturulması için tüm sıfır filtreye dayanan model

$$\sum_{n=0}^{\infty} b_n^* z^{-n} \quad (3.43)$$

Bir tüm sıfır filtrenin bütün sıfırları z -domeninde birim çember içerisinde ise bu filtre için minimum fazlı denilebilir. Böyle bir durumda; Şekil 3.22'deki gibi tüm sıfır filtreyi, aynı darbe cevabına sahip ($\{h_n\} = \{b_n^*\}$) tüm kutup filtre ile yer değiştirmek mümkündür.



Şekil 3.22 Genel doğrusal süreç oluşturulması için tüm kutup filtreye dayanan model

3.5.5 Öz Bağlılımlı Sürecin Korelasyon Fonksiyonu

Bir öz bağlantımlı sürecin korelasyon fonksiyonu için ardışık bir ilişki bulmak istenmektedir.

$$u(n) + a_1^* u(n-1) + a_2^* u(n-2) + \dots + a_M^* u(n-M) = v(n) \quad (3.44)$$

Bu nedenle (3.44)'deki eşitliğin her iki tarafına aynı ifadeyle çarpılıp beklendik değer işlemi uygulanırsa,

$$E\left[\sum_{k=0}^M a_k^* u(n-k) u^*(n-l)\right] = E[v(n) u^*(n-l)] \quad (3.45)$$

(3.45)'in sol tarafını, beklendik değer ile toplama işlemi yer değiştirerek ve $E[u(n-k)u^*(n-l)]$ ifadesinin bir “ $l-k$ ” gecikmesi için ÖB sürecin oto korelasyon fonksiyonu olduğunu düşünerek sadeleştirebiliriz. (3.45)'in sağ tarafını ise “ $l>0$ ” için 0 kabul edebiliriz. Bu sayede (3.45) aşağıdaki şekilde sadeleştirilmiş olur.

$$\sum_{k=0}^M a_k^* r(l-k) = 0 \quad , l>0 \quad (3.46)$$

Burada $a_0=1$ 'dir. Burada ÖB sürecin oto korelasyon fonksiyonunun (3.47)'deki fark denklemini sağladığı gözlemlenmektedir.

$$r(l) = w_1^* r(l-1) + w_2^* r(l-2) + \dots + w_M^* r(l-M) \quad , l>0 \quad (3.47)$$

Burada $w_k = -a_k$ 'dir. Bu fonksiyonun genel çözümü (3.48)'deki gibidir.

$$r(m) = \sum_{k=1}^M C_k p_k^m \quad (3.48)$$

Burada $C_1, C_2, \dots, C_M$ sabitler ve $p_1, p_2, \dots, p_M$ (3.36)'nın kökleridir.

3.5.6 Öz Bağlılımlı Modellerin Karakterizasyonu

M. dereceden bir öz bağlantımlı modeli tanımlayabilmek için bu modele ait katsayılarını ve varyansını belirlemek gerekir.

3.5.7 Yule-Walker Denklemleri

(3.47)'yi $l=0, 1, \dots, M$ için yazarsak, ÖB sürecin bilinen $r(0), r(1), \dots, r(M)$ ile ÖB sürecin bilinmeyen $a_1, a_2, \dots, a_M$ ile gösterilen ÖB katsayılarını içeren M adet denklem yazılabilir. Bu denklemler bir matris şeklinde yazılabilir.

$$\begin{bmatrix} r(0) & r(1) & . & . & . & r(M-1) \\ r^*(1) & r(0) & . & . & . & r(M-2) \\ . & . & . & . & . & . \\ . & . & . & . & . & . \\ . & . & . & . & . & . \\ r^*(M-1) & r^*(M-2) & . & . & . & r(0) \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ . \\ . \\ . \\ w_M \end{bmatrix} = \begin{bmatrix} r^*(1) \\ r^*(2) \\ . \\ . \\ . \\ r^*(M) \end{bmatrix} \quad (3.49)$$

Burada $w_k = -a_k$ 'dır. Bu denklem kümesi Yule-Walker denklemleri olarak bilinir (Yule, 1927; Walker, 1931). Yule-Walker denklemlerinin daha genel bir ifadesi (3.50)'deki şekilde yazılabilir ve çözümü (3.51)'deki gibidir.

$$Rw = r \quad (3.50)$$

$$w = R^{-1}r \quad (3.51)$$

3.6 Kaydedilen EMG İşaretlerinin Öz Bağlılıklı Metot İle Modellenmesi

Bu bölümden önceki bölümlerde EMG işaretinin yapısını ve özellikleri açıklanmıştır. Buna ilaveten Öz bağılılıklı (ÖB) modellerin özellikleri ve ÖB katsayılarının hesaplanış yöntemleri ifade edilmiştir. Bu bölümde ise uygulamada kaydedilen EMG işaretlerinin Öz bağılılıklı modellerle parametrik modellemesi yapılmıştır.

EMG işaretlerinin parametrik modellemesinde MATLAB System Identification Toolbox kullanılmıştır. System Identification Toolbox; ölçülmüş veriler üzerine kurulmuş sistemlerin matematiksel modelinin oluşturulmasını sağlayan bir araç kutusudur. Burada kullanılan teknikler çok genel modellere uygulanabilirler. En fazla kullanılan metotlar öz bağılılıklı ve öz bağılılıklı-hareketli ortalama modelleridir.

EMG işaretlerinin modellenmesi için öz bağılılıklı modeller seçilmiştir. Bu seçimin nedeni; pratik uygulamalarda ÖB katsayıların, HO katsayıları ve ÖBHO katsayılarına göre daha kolay ve hızlı hesaplanabilmesidir. Ayrıca pratikte belli bir derecede durdurulmuş, teorikte sonsuz bir ÖB modelinin HO ve ÖBHO modellerini temsil etmesi mümkündür (Makhoul, 1995).


System Identification Toolbox kullanılarak uygulamada kaydedilen Biceps, Frontalis,

Abductor Pollicis Brevis kaslarının parametrik modellenmesi yapılmıştır. Burada öz bağımlı model için üç farklı derece belirlenmiştir. Bu dereceler sırasıyla 5, 10, 20'dir.

Toplam 15 denekten alınan 3 kasa ait 5'er örnek sonucunda toplam 225 adet örnek toplanmıştır. Alınan bütün bu örnekler Öz bağımlı modelle modellenmiştir. Bu modelleme sayesinde kaydedilen EMG işaretlerinin Öz bağımlı katsayıları oluşturulmuştur. Bu oluşan katsayılarla Yapay Sinir Ağlarının kullanacağı eğitime ve test kümeleri oluşturulmuştur.

3.6.1 Biceps Kasının Öz Bağımlı Model ile Parametrik Modellenmesi

Biceps kasına ait EMG üç farklı derece ile modellenmiştir. Bunlar N=5, N=10, N=20 değerleridir.




Şekil 3.23 Birinci denekten alınan Biceps kasına ait EMG işareti

Birinci denekten alınan Şekil 3.23'deki Biceps kası örneğine 5. dereceden öz bağımlı modellerin uygulanması ile aşağıdaki (3.52)'deki öz bağımlı model elde edilmiştir.

$$u(n) = -3,1462 * u(n - 1) + 4,2592 * u(n - 2) - 3,3529 * u(n - 3) + 1,617 * u(n - 4) - 0,3721 * u(n - 5) \quad (3.52)$$

Denklem 3.52'de bulunan iç çarpımlardaki sayılar öz bağımlı katsayıların değeridir. Bu katsayılar öz bağımlı model katsayılarını göstermektedir.

Öz bağımlı model sonucu oluşan EMG işaretine ait katsayılar Şekil 3.24'deki gibidir.




Şekil 3.24. Biceps kasına ait EMG işaretinin 5. dereceden öz bağılanımlı model katsayıları

Birinci denekten alınan Şekil 3.23'deki Biceps kası örneğine bu sefer 10. dereceden öz bağılanımlı modellerin uygulanması ile (3.53)'deki öz bağılanımlı model elde edilmiştir.

$$\begin{aligned}
 u(n) = & -3,1043 * u(n-1) + 4,2116 * u(n-2) - 3,5488 * u(n-3) + 1,9893 * u(n-4) \\
 & - 0,3423 * u(n-5) - 0,72848 * u(n-6) + 0,93996 * u(n-7) - 0,57379 * u(n-8) \\
 & + 0,17436 * u(n-9) - 0,014146 * u(n-10)
 \end{aligned} \quad (3.53)$$

Öz bağılanımlı model sonucu oluşan EMG işaretine ait katsayılar Şekil 3.25'deki gibidir.




Şekil 3.25. Biceps kasına ait EMG işaretinin 10. dereceden öz bağılanımlı model katsayıları

Birinci denekten alınan Şekil 3.23'deki Biceps kası örneğine bu sefer 20. dereceden öz bağımlı modellerin uygulanması ile (3.54)'deki öz bağımlı model elde edilmiştir.

$$\begin{aligned}
 u(n) = & -3,3021 * u(n-1) + 4,8893 * u(n-2) - 4,493 * u(n-3) + 2,7333 * u(n-4) \\
 & - 0,619 * u(n-5) - 0,89759 * u(n-6) + 1,2322 * u(n-7) - 0,60182 * u(n-8) \\
 & - 0,23206 * u(n-9) + 0,6276 * u(n-10) - 0,46229 * u(n-11) + 0,017429 * u(n-12) \\
 & + 0,337 * u(n-13) - 0,36568 * u(n-14) + 0,11936 * u(n-15) + 0,16427 * u(n-16) \\
 & - 0,29813 * u(n-17) + 0,25745 * u(n-18) - 0,13388 * u(n-19) + 0,035695 * u(n-20)
 \end{aligned} \tag{3.54}$$


Öz bağımlı model sonucu oluşan EMG işaretine ait katsayılar Şekil 3.26'daki gibidir.



Şekil 3.26 Biceps kasına ait EMG işaretinin 20. dereceden öz bağımlı model katsayıları

3.6.2 Frontalis Kasının Öz Bağımlı Model ile Parametrik Modellenmesi

Frontalis kasına ait EMG üç farklı derece ile modellenmiştir. Bunlar N=5, N=10, N=20 değerleridir.




Şekil 3.27 Birinci denekten alınan Frontalis kasına ait EMG işareti

Birinci denekten alınan Şekil 3.27’deki Frontalis kası örneğine 5. dereceden öz bağımlı modellerin uygulanması ile (3.55)’deki öz bağımlı model elde edilmiştir.

$$u(n) = -2,8224 * u(n - 1) + 3,5312 * u(n - 2) - 2,8803 * u(n - 3) + 1,581 * u(n - 4) - 0,40275 * u(n - 5) \quad (3.55)$$

Öz bağımlı model sonucu oluşan EMG işaretine ait katsayılar Şekil 3.28’deki gibidir.




Şekil 3.28. Frontalis kasına ait EMG işaretinin 5. dereceden öz bağımlı model katsayıları

Birinci denekten alınan Şekil 3.27’deki Frontalis kası örneğine bu sefer 10. dereceden öz

bağımlı modellerin uygulanması ile (3.56)'daki öz bağımlı model elde edilmiştir.

$$\begin{aligned} u(n) = & -2,9368 * u(n-1) + 3,7359 * u(n-2) - 2,9193 * u(n-3) + 1,4106 * u(n-4) \\ & + 0,031323 * u(n-5) - 0,80176 * u(n-6) + 0,82258 * u(n-7) - 0,46019 * u(n-8) \\ & + 0,1338 * u(n-9) - 0,0090036 * u(n-10) \end{aligned} \quad (3.56)$$

Öz bağımlı model sonucu oluşan EMG işaretine ait katsayılar Şekil 3.29'daki gibidir.




Şekil 3.29 Frontalis kasına ait EMG işaretinin 10. dereceden öz bağımlı model katsayıları

Birinci denekten alınan Şekil 3.27'deki Frontalis kası örneğine bu sefer 20. dereceden öz bağımlı modellerin uygulanması ile (3.57)'deki öz bağımlı model elde edilmiştir.

$$\begin{aligned} u(n) = & -2,9975 * u(n-1) + 4,1766 * u(n-2) - 3,9256 * u(n-3) + 2,5688 * u(n-4) \\ & - 0,70708 * u(n-5) - 0,70135 * u(n-6) + 1,1069 * u(n-7) - 0,6726 * u(n-8) \\ & - 0,028084 * u(n-9) + 0,47802 * u(n-10) - 0,45549 * u(n-11) + 0,11521 * u(n-12) \\ & + 0,24885 * u(n-13) - 0,35491 * u(n-14) + 0,18367 * u(n-15) + 0,07979 * u(n-16) \\ & - 0,25396 * u(n-17) + 0,24872 * u(n-18) - 0,14886 * u(n-19) + 0,047905 * u(n-20) \end{aligned} \quad (3.57)$$


Öz bağımlı model sonucu oluşan EMG işaretine ait katsayılar Şekil 3.30'daki gibidir.



Şekil 3.30 Frontalis kasına ait EMG işaretinin 20. dereceden öz bağlanımlı model katsayıları

3.6.3 Abductor Pollicis Brevis Kasının Öz Bağlanımlı Model ile Parametrik Modellenmesi

Abductor Pollicis Brevis kasına ait EMG üç farklı derece ile modellenmiştir. Bunlar N=5, N=10, N=20 değerleridir.




Şekil 2.31. Birinci denekten alınan Abductor Pollicis Brevis kasına ait EMG işareti

Birinci denekten alınan Şekil 2.31'deki Abductor Pollicis Brevis kası örneğine 5. dereceden öz bağlanımlı modellerin uygulanması ile (3.58)'deki öz bağlanımlı model elde edilmiştir.

$$u(n) = -2,4042 * u(n - 1) + 2,2992 * u(n - 2) - 1,2064 * u(n - 3) + 0,3801 * u(n - 4) - 0,037879 * u(n - 5) \quad (3.58)$$

Öz bağımlı model sonucu oluşan EMG işaretine ait katsayılar Şekil 3.32’deki gibidir.




Şekil 3.32 Abductor Pollicis Brevis kasına ait EMG işaretinin 5. dereceden öz bağımlı model katsayıları

Birinci denekten alınan Şekil 3.31’deki Abductor Pollicis Brevis kası örneğine bu sefer 10. dereceden öz bağımlı modellerin uygulanması ile (3.59)’daki öz bağımlı model elde edilmiştir.

$$u(n) = -3,6328 * u(n - 1) + 6,1776 * u(n - 2) - 6,7258 * u(n - 3) + 5,1949 * u(n - 4) - 2,5965 * u(n - 5) + 0,12861 * u(n - 6) + 1,2751 * u(n - 7) - 1,3846 * u(n - 8) + 0,75922 * u(n - 9) - 0,18443 * u(n - 10) \quad (3.59)$$

Öz bağımlı model sonucu oluşan EMG işaretine ait katsayılar Şekil 3.33’deki gibidir.




Şekil 3.33 Frontalis kasına ait EMG işaretinin 10. dereceden öz bağımlı model katsayıları

Birinci denekten alınan Şekil 2.31'deki Abductor Pollicis Brevis kası örneğine bu sefer 20. dereceden öz bağımlı modellerin uygulanması ile (3.60)'daki öz bağımlı model elde edilmiştir.

$$\begin{aligned}
 u(n) = & -2,4074 * u(n - 1) + 2,3307 * u(n - 2) - 1,2931 * u(n - 3) + 0,50403 * u(n - 4) \\
 & - 0,11135 * u(n - 5) - 0,040629 * u(n - 6) + 0,044487 * u(n - 7) + 0,054483 * u(n - 8) \\
 & - 0,11456 * u(n - 9) + 0,16547 * u(n - 10) - 0,22226 * u(n - 11) + 0,26964 * u(n - 12) \\
 & - 0,27374 * u(n - 13) + 0,15029 * u(n - 14) + 0,093244 * u(n - 15) - 0,2767 * u(n - 16) \\
 & + 0,32496 * u(n - 17) - 0,32232 * u(n - 18) + 0,19753 * u(n - 19) - 0,036062 * u(n - 20)
 \end{aligned} \quad (3.60)$$

Öz bağımlı model sonucu oluşan EMG işaretine ait katsayılar Şekil 3.34'deki gibidir.




Şekil 3.34 Abductor Pollicis Brevis kasına ait EMG işaretinin 20. dereceden öz bağlanımlı model katsayıları

4. YAPAY SİNİR AĞLARININ GENELTANIMI

Yapay Sinir Ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştirilen sistemlerdir. Yapay Sinir Ağları, insanlar tarafından oluşturulan ve gerçekleştirilmiş örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üretebileceğini belirleyen sistemlerdir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme, optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır. Örneklerden elde ettikleri bilgiler ile kendi deneyimleri oluşturur ve daha sonra benzer konularda benzer kararları verirler.

Yapay Sinir Ağları (YSA) birçok probleme çözüm üretebilecek değişik şekillerde tanımlanabilir. Bunların en başında YSA'nın birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden oluşmaktadır. İşlem elemanı olarak adlandırılan hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değerinin olduğu kabul edilmektedir. İşlem elemanlarının birbirlerine bağlanmaları sonucu oluşan yapıya Yapay Sinir Ağı denir. Bu ağın oluşturulmasında biyolojik sinir sisteminden esinlenilmiştir.



Şekil 4.1 Bir yapay sinir ağı örneği

Bir yapay sinir ağının en temel görevi, kendisine uygulanan bir giriş kümesine ait bir çıkış kümesi oluşturmaktır. Bunun için ağın ilgili olaya ait örneklerle eğitilmesi gerekmektedir. Bu eğitim sayesinde ağı bir genelleme yeteneği kazandırılır. Bu yetenek sayesinde benzer

olaylara karşı kullanabilecek duruma gelir.

Yapay sinir ağıları aynı zamanda “bağlantılı ağılar (connectionist networks)”, “paralel dağıtılmış ağılara (parallel distributed networks)” ve “nöromorfik sistemler (neuromorphic systems)” olarak da adlandırılır.

4.1 Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının özellikleri uygulanan ağ yapısına göre değişiklik göstermektedir. Bu bölümde değişik modeller için genel geçerlilik gösteren özellikler ele alınacaktır.

- Yapay sinir ağıları makine öğrenmesini gerçekleştirir.
- Yapay sinir ağlarında bilgi, ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır.
- Yapay sinir ağıları örnekleri kullanarak öğrenirler. Örnekleri kullanarak ilgilenilen olay hakkında genelleme yapabilecek yeteneğe kavuşur. Örnekler ise gerçekleşmiş olan olaylardır. Ağa olayla ilgili bütün değişkenleri kapsayan bir eğitim verisi uygulanamazsa başarılı sonuçların elde edilemez. Bu nedenle örneklerin etkin bir şekilde oluşturulması yapay sinir ağlarında çok önemli bir noktadır.
- Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekir.
- Görülmemiş örnekler hakkında bilgi üretebilirler.
- Algılamaya yönelik uygulama ve olaylarda kullanılabilirler.
- Örüntü ilişkilendirme ve sınıflama yapabilirler.
- Örüntü tamamlama yapabilirler.
- Kendi kendine organize etme ve öğrenebilme yeteneklerine sahiptirler.
- Eksik bilgiler ile çalışabilmektedirler.
- Hata toleransına sahiptirler.

- Belirsiz, tam olmayan bilgileri işleyebilmektedirler.
- Dereceli bozulma (Graceful degradation) gösterirler. Yapay sinir ağlarının hatalara karşı toleranslı olmaları bozulmalarının da dereceli olmasına neden olur. Bir ağ zaman içerisinde yavaş yavaş ve zarif bir şekilde bozulur. Bu bozulma eksik bilgiden veya hücrelerin bozulmasından kaynaklanır.
- Dağıtık belleğe sahiptirler. Yapay sinir ağlarında bilgi ağa yayılmış durumdadır. Hücrelerin birbirleriyle olan bağlantıların değerleri ağın bilgisini oluşturur. Bu yüzden ağ öğrendiği bilgilerle olayın bütünü karakterize eder. Bu ise dağıtık bir belleğin oluşmaktadır.
- Sadece nümerik bilgiler ile çalışmaktadırlar. Sembolik ifadelerle gösterilen bilgiler nümerik bilgilere çevrilmelidirler.

Yukarıda belirtilen bilgiler ile beraber her ağın kendine ait özellikleri bulunmaktadır.

Yapay Sinir Ağlarının Dezavantajları

Bir önceki bölümde yapay sinir ağlarının birçok avantajlı yönlerinden söz edilmektedir. Bununla beraber yapay sinir ağlarının dezavantajlı özellikleri de vardır. Bu özelliklerden kısaca bahsedelim.

- Yapay sinir ağlarının donanıma bağımlı çalışmaları bir dezavantaj olarak görülebilir. Ağların temel var oluş nedenlerinden biride paralel işlemciler üzerinden çalışabilmeleridir. Günümüzdeki makinelerin çoğu seri şekilde çalışabilmektedir ve aynı zamanda sadece tek bir bilgiyi işleyebilmektedir. Paralel işlemleri seri makinelerde yaparken zaman kaybı olabilir.
- Probleme uygun ağ yapısının seçimi genellikle deneme yanılma yöntemi ile yapılmaktadır. Bu ise önemli bir problemdir. Eğer uygun ağ bulunamazsa çözümü olan sorunun çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusu olabilir.
- Bazı ağlarda ağ parametrelerinin seçimi için bir kuralın olmaması diğer bir problemdir. Bu parametrelerin belirlenmesi kullanıcının tecrübelerine dayanarak alacağı bir karardır.

- Ağın öğreneceği problemin ağı tanıtılması da bir diğer önemli sorundur.
- Ağı eğitiminin ne zaman bitirileceği hakkında yine genel geçer bir kural yoktur. Ağı örnekler üzerindeki hatasının belirli bir değerin altına indirilmesi eğitim tamamlanması için yeterli görülüp eğitim kesilmektedir.

Yukarıda belirtilen dezavantajlara rağmen yapay sinir ağları birçok probleme değişik şekillerde çözümler üretebilmekte ve başarılı uygulamalar sağlayabilmektedir.

4.2 Uygulamada Kullanılan Yapay Sinir Ağları

4.2.1 Çok Katmanlı Algılayıcı Ağları (Multi-layer Perceptron)

Bir yapay sinir ağının öğrenmesi istenen olayların girdi ve çıktıları arasındaki ilişkiler doğrusal olmayan ilişkiler olursa basit algılayıcı (Perceptron) gibi modellerle öğrenme gerçekleştirmek mümkün değildir. Bu tür olayların öğrenilmesi için daha gelişmiş modellere ihtiyaç vardır. Çok katmanlı ağ (ÇKA) modeli bu modellerden biridir. Olayın doğrusal olup olmadığı konusunu en iyi XOR problemiyle anlayabiliriz. Bu problemin özelliği doğrusal olmayan bir ilişkiyi göstermesidir. Yani çıktıların arasına bir doğru veya doğrular çizerek onları iki veya daha fazla sınıfa ayırmak mümkün değildir. Bu problem Çizelge 4.1’de gösterilmektedir.

Çizelge 4.1. XOR problemi


X_1	X_2	Çıkış (Y)
0	0	0
0	1	1
1	0	1
1	1	1

XOR problemini çözmek amacıyla yapılan çalışmalar sonucunda çok katmanlı algılayıcı ağları (ÇKA) geliştirilmiştir. Rumelhart ve arkadaşları (Rumelhart ve Hinton ve Williams, 1986) tarafından geliştirilen bu modele hata yayma modeli veya geriye yayılım modeli (backpropagation network) de denmektedir. ÇKA modeli yapay sinir ağlarına olan ilgiyi

arttırmıştır. Bu modeller özellikle sınıflandırma, tanıma ve genelleme yapılması gereken problemlerde kullanılırlar. Bu model Delta öğrenme kuralı denen bir öğrenme yöntemini kullanırlar.

4.2.1.1 Çok Katmanlı Ağların Yapısı

Çok katmanlı ağların yapısı Şekil 4.2'deki gibidir.



Şekil 4.2 Çok katmanlı ağ yapısı


Şekil 4.2'de görüldüğü gibi ÇKA modeli üç katmandan oluşmaktadır. Bu katmanlar sırasıyla giriş katmanı, saklı katman, çıkış katmanıdır.

- **Giriş Katmanı:** Probleme ait verilerin geldiği katmandır. Bu katmanda bilgi işleme olmaz. Gelen her bilgi geldiği gibi bir sonraki katmana yani saklı katmana iletilir.
- **Saklı Katman:** Giriş katmanından gelen bilgiler bu katmanda işlemlerden geçer. Saklı katman sayısı ile ilgili bir sınırlama yoktur. Saklı katmandaki her işlem elemanı sonraki katmanlardaki her bir işlem elemanına bağlantısı vardır.
- **Çıkış Katmanı:** Saklı katmandan gelen bilgileri işleyerek ağa giriş katmanından verilen bilgilere ait çıkışları üretir. Çıkış katmanında birden fazla işlem elemanı bulunabilir. Her işlem elemanın sadece bir çıkışı vardır.

4.2.1.2 Çok Katmanlı Ağlarda Öğrenme

ÇKA ağlarda eğitici öğrenme kullanılır. Ağ hem örnekler hem de bu örneklerle ait çıktılar verilir. Ağ bu verilere göre genelleme yapar ve daha sonra gelen verilere bu genellemeye dayanarak çıktılar üretir. Bu ağ tipinin kullandığı öğrenme kuralı en küçük kareler yöntemini kullanan Delta Öğrenme Kuralının genelleştirilmiş halidir. Ağın öğrenebilmesi için bir eğitme kümesine ihtiyacı vardır. Genelleştirilmiş Delta Kuralı iki fazdan oluşmaktadır.

1. İleri doğru hesaplama: Ağın çıktısını hesaplama fazıdır.
2. Geriye doğru hesaplama: Ağırlıkları değiştirme fazıdır.



Şekil 4.3 ÇKA’larda öğrenme

1. İleri doğru hesaplama: Bu safhada bilgi işleme eğitim kümesindeki bir örneğin giriş katmanından ($x_1, x_2 \dots$) ağa verilmesi ile başlar. Bilindiği üzere giriş katmanında herhangi bir işlem yapılmaz. Gelen girdiler hiçbir değişiklik olmadan saklı katmana gönderilirler. Burada işlem elemanlarına gelen girişler ağırlıklar ($w_1, w_2, \dots$) ile işlenerek net girdi “F(NET)” elde edilir.

$$NET_j^a = \sum_{k=1}^n w_{kj} x_k^i \quad (4.1)$$

Burada “ w_{kj} ” giriş katmanı işlem elemanını j. ara katman elemanına bağlayan bağlantının ağırlık değerini göstermektedir. j. ara katman elemanının çıktısı ise bu net girdinin aktivasyon fonksiyonundan geçirilmesiyle hesaplanır. Önemli olan kullanılan aktivasyon fonksiyonunun türevinin alınabilir olmasıdır. Çünkü geriye doğru hesaplama fazında bu fonksiyonun türevi alınacaktır. Bu nedenle net girdinin hesaplanmasında kullanılan aktivasyon fonksiyonunun bu kriterlere uyan herhangi bir fonksiyon olması gerekmektedir. Aktivasyon fonksiyonu olarak “Sigmoid” fonksiyonu kullanılırsa

$$y_j^a = \frac{1}{1 + e^{-(F(NE T)_j^a + \beta_j^a)}} \quad (4.2)$$

Burada “ β_j ” , ara katmanda bulunan j. elemana bağlanan eşik değer elemanını ağırlığını göstermektedir. bu eşik değeri elemanının çıkışı sabit olup 1’e eşittir. Ağırlık değeri ise sigmoid fonksiyonunun uyumunu belirlemek üzere konulmuştur. Eğitim esnasında ağ bu değeri kendisi belirlemektedir.

Saklı katmanın bütün işlem elemanları ve çıkış katmanının işlem elemanlarının çıkışlarının aynı şekilde kendilerine gelen net girdinin hesaplanması ve aktivasyon fonksiyonuna tabi tutulması sonucu belirlenir. çıkış katmanından çıkan değerler bulununca ağın ileri yönde hesaplama işlemi bitmiş olur.

2. Geriye Doğru Hesaplama:

Ağa sunulan giriş için ağın ürettiği çıkış beklenen çıkışlarla ($d_1, d_2, \dots$) karşılaştırılır. Bunların arasındaki fark hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. Bundan dolayı geriye doğru hesaplamada bu hata ağın ağırlık değerlerine dağıtılarak bir sonraki adımda hatanın azaltılması sağlanır. Çıkış katmanındaki m. işlem elemanı için oluşan hata;

$$E_m = d_m - y_m \quad (4.3)$$

şeklindedir. Bu bir işlem elemanı için oluşan hatadır. Çıktı katmanı için oluşan toplam hatayı (TH) bütün hataların toplanması gerekmektedir. Bazı hata değerleri negatif olacağından toplamın sıfır olmasını önlemek amacıyla ağırlıkların kareleri alınarak sonucun kare kökü alınır. Toplam hata şu formülle bulunur.

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (4.4)$$

Toplam hatayı en aza indirmek için hatanın kendisine neden olan işlem elemanlarına dağıtılması gerekmektedir. Bu da işlem elemanlarının ağırlıklarını değiştirmek demektir. Ağırlıkların değiştirilmesi için iki durum söz konusudur.

- Saklı katman ile çıkış katmanı arasındaki ağırlıkların değiştirilmesi
- Saklı katmanlar arası veya giriş katmanı arasındaki ağırlıkların değiştirilmesi

Saklı katman ile çıkış katmanı arasındaki ağırlıkların değiştirilmesi

Saklı katmandaki j . işlem elemanı ile çıkış katmanındaki m . işlem elemanına bağlayan bağlantının ağırlığındaki değişim miktarına Δw^a denirse; herhangi bir “ t ” anında ağırlığın değişim miktarı şöyle hesaplanır.

$$\Delta w_{jm}^a(t) = \alpha \delta_m x_j^a + \eta \Delta w_{jm}^a(t-1) \quad (4.5)$$

Burada α öğrenme katsayısı, η ise momentum katsayısını göstermektedir. öğrenme katsayısı ağırlıkların değişim miktarını, momentum ise ÇKA ağırlık öğrenmesi esnasında yerel bir optimum noktaya takılıp kalmaması için ağırlık değişim değerinin belirli bir oranda bir sonraki değişime eklenmesini sağlar. (4.5)’deki “ δ_m ” ise m . çıkış ünitesinin hatasını göstermektedir. Hesaplanma şekli (4.6)’daki gibidir.

$$\delta_m = f'(NET).E_m \quad (4.6)$$

Buradaki $f'(NET)$ aktivasyon fonksiyonunun türevidir. Sigmoid fonksiyonunun kullanılması durumunda;

$$\delta_m = y_m(1 - y_m).E_m \quad (4.7)$$

olacaktır. Değişim miktarı hesaplandıktan sonra ağırlıkların t . adımdaki yeni değerleri şöyle olacaktır.

$$w_{jm}^a(t) = w_{jm}^a(t-1) + \Delta w_{jm}^a(t) \quad (4.8)$$

Benzer şekilde eşik değeri ünitesinin de ağırlıklarının değiştirilmesi gerekmektedir. Bu yüzden öncelikle değişim miktarını hesaplamak gerekir. Eğer çıkış katmanında bulunan işlem elemanlarının eşik değeri aralıkları β^c ile gösterilirse;

$$\Delta\beta_m^c(t) = \alpha\delta_m + \eta\Delta\beta_m^c(t-1) \quad (4.9)$$

olacaktır. Eşik değeri t . adımdaki ağırlığının yeni değeri ise,

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta\beta_m^c(t) \quad (4.10)$$

şeklinde hesaplanır.

Saklı katmanlar arası veya saklı katman giriş katmanı arasındaki ağırlıkların değiştirilmesi

Saklı katman ile çıkış katmanı arasındaki ağırlıkların değişiminde her ağırlık için sadece çıkış katmanındaki bir işlem elemanının hatası dikkate alınmıştır. Bu hataların oluşmasında giriş katmanı ile saklı katman arasındaki ağırlıkların payı vardır. Çünkü en son saklı katmana gelen bütün bilgiler giriş katmanı veya önceki saklı katmanlardan gelmektedir. O nedenle giriş katmanı ile saklı katman arasındaki veya iki saklı katman arasındaki ağırlıkların değiştirilmesinde çıkış katmanındaki işlem elemanlarının hepsinin hatası dikkate alınmalıdır. Mesela giriş katmanı ile çıkış katmanı arasındaki ağırlıkların değişimi Δw^i ile gösterilirse değişim miktarı;

$$\Delta w_{kj}^i(t) = \alpha\delta_j^a x_k^i + \eta\Delta w_{kj}^i(t-1) \quad (4.11)$$

olacaktır. Buradaki hata terimi δ^a ise;

$$\delta_j^a = f'(NET) \sum_m \delta_m w_{jm}^a \quad (4.12)$$

şeklindedir. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu düşünülürse bu hata değeri aşağıdaki şekilde hesaplanacaktır.

$$\delta_j^a = y_j^a(1 - y_j^a) \sum_m \delta_m w_{jm}^a \quad (4.13)$$

Hata değeri hesaplandıktan sonra yukarıda verilen eşitlik ile değişim miktarını bulmak mümkündür. Ağırlıkların yeni değerleri aşağıdaki şekildedir.

$$w_{kj}^i(t) = w_{kj}^i(t-1) + \Delta w_{kj}^i(t) \quad (4.14)$$

Benzer şekilde, eşik değeri ünitesinin yeni ağırlıkları da yukarıdaki gibi hesaplanır. Saklı katman eşik değeri ağırlıkları β^a ile gösterilirse değişim miktarı;

$$\Delta \beta_j(t) = \alpha \delta_j + \eta \Delta \beta_j(t-1) \quad (4.15)$$

olacaktır. Ağırlıkların yeni değerleri ise t. adımda şöyle hesaplanacaktır.

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta \beta_j^a(t) \quad (4.16)$$

Bu sayede ağırlıkların hepsi değiştirilmiş olacaktır. Bir adım hem ileri hem de geriye hesaplamaları yapılarak tamamlanmış olacaktır. İkinci bir örnek verilerek sonraki adıma başlanır ve aynı işlemler öğrenme tamamlanıncaya kadar yinelenir.

4.2.2 Radyal Temelli Fonksiyon Ağları

Yapay Sinir Ağlarının bir türü olan Radyal Temelli Fonksiyon Ağları (RTFA) 80'lerin sonunda ortaya çıkmıştır. Bu ağların kökleri; potansiyel fonksiyonlar, kümeleme (clustering), fonksiyonel yaklaşım gibi eski örüntü tanıma yöntemlerine dayanmaktadır (Tou ve Gonzalez, 1974). RTFA saklı her ünitesi Radyal fonksiyonları temsil eden iki katmanlı bir yapay sinir ağıdır. Ağın çıkışı saklı ünitelerin çıkışlarının toplamıdır. RTFA'nın girişi non-lineer iken çıkışları lineerdir. Bu ağların lineer olmayan yaklaşım fonksiyonlarından dolayı, RTFA'lar karmaşık haritalamalarda modelleme için kullanılmaktadır. Bu durumlarda Perceptron ağları birçok katmanlar kullanarak ancak bu işlemi yapabilmektedir (Haykin, 1994).

Radyal Temelli Fonksiyon Ağlarını kullanabilmek için bazı tanımları belirlemek gerekir. Bunlar; saklı ünitelerin aktivasyon fonksiyonu, öğrenme algoritması, işlemci ünitelerin sayısı gibi parametrelerdir. RTFA'nın ağırlıklarının bulunması ağın eğitilmesidir. Eğer elimizde eğitime kümesi olarak bilinen giriş ve çıkış çiftleri bulunuyorsa; elde edilen çıkışların bilinen çıkışlara göre optimize ederek ağın parametreleri bulunur. Bu parametreleri hesaplarken genelde ortalama karesel hata (mean square error) yöntemi kullanılmaktadır. Eğitimden sonra, RTFA eğitime verisine benzer özellikteki veri için kullanılabilir.

RTF ağları; interpolasyon (Broomhead ve Lowe, 1988; Matej ve Lewitt, 1996), kaotik zaman serileri modelleme (Moody, 1989; Casdagli, 1989), sistem tanımlama, kontrol mühendisliği

(Saner ve Slotine,1994), elektronik aletlerin parametre modellemesi, kanal eşitleme (Bors ve Gabbouj, 1994), ses tanıma (Niranjan ve Fallside, 1990), görüntüleri yenileme (Cha ve Kassam, 1996), 3-D modelleme (Bors ve Pitas, 1999), hareket tahmini (Bors ve Pitas, 1998) gibi geniş çaplı uygulamalarda kullanılmaktadır.

4.2.2.1 Ağ Topolojisi

Radyal Temelli Fonksiyonlar 2-katmanlı ileri beslemeli Yapay Sinir Ağının içine gömülmüştür. Böyle bir ağ giriş kümesi ve çıkış kümesi ile karakterize edilmektedir. Giriş ve çıkışların arasında saklı birimler olarak tanımlanan işlem elemanlarından oluşan bir katman bulunmaktadır. Bu birimlerin her biri Radyal temelli fonksiyonları yerine getirmektedir. Örüntü tanıma ve zaman serileri analizinde kullanılan ağlarda veri modelleme yöntemleri farklılık göstermektedir. Birinci durumda, girişler belirli bir aralıkla örneklenmiş geçmişe ait veri örneklerini göstermektedir ve işaret değerini temsil eden bir çıkıştan oluşmaktadır. Örüntü tanıma uygulamasında giriş özellik değerlerini ve her çıkışta bir sınıfı göstermektedir. Saklı birimlerse alt sınıfları göstermektedir.

İlk katman; giriş vektörleriyle merkez vektörleri arasındaki uzaklığa bağlı çok boyutlu bir fonksiyondur. RTF ağının ilk katmanı depolanmış veri kümelerinin ağ girişlerine ne kadar uzak olduğunu hesaplar. Giriş katmanından saklı katmana olan bağlantıların ağırlıksız olduğu düşünülür. Her bir temel fonksiyon burada hesaplanan bir uzaklıkla ilişkili bir fonksiyondur. En fazla bilinen uzaklık ölçüsü (4.17)'de gösterilen "Euclidean" uzaklığıdır. Bir diğer uzaklık çeşidi ise (4.18)'de gösterilen "Hamming" uzaklığıdır.

$$r = \|x - c\| \quad (4.17)$$

$$D = \sum_k |x_k - c_k| \quad (4.18)$$

Radyal temelli fonksiyon ağlarının genel formülü ise aşağıdaki şekildedir.

$$F(x) = \sum_{i=1}^N w_i \phi(\|x - c\|) \quad (4.19)$$

Bu ağlarda RTF seçildikten sonra yapılması gereken en önemli şey veri uzayını doğru bir şekilde ayırmak için ağırlık parametrelerinin belirlenmesidir. Temel bir RTF ağında merkezler ve uzaklık ölçekleme (genişlik, σ) parametreleri genellikle sabit tutulur ve öğrenme işlemi

anında değiştirilmezler. Sadece ağırlıklar güncellenir. Aşağıdaki tabloda en önemli Radyal temelli fonksiyonlar verilmiştir.

Çizelge 4.2 Çeşitli radyal temelli fonksiyonlar

Fonksiyon adı	$\phi(r)$
Parçalı doğrusal yaklaşım	r
Kübik yaklaşım	r^3
Gauss fonksiyonu	$\exp(-r^2/\sigma^2)$
Multi-quadratik fonksiyon	$\sqrt{r^2 + \sigma^2}$
İnce tabaka eğrileri	$r^2 \log(r)$
Ters Multi-quadratik fonksiyon	$\frac{1}{\sqrt{r^2 + \sigma^2}}$

4.2.2.2 Radyal Temelli Fonksiyon Ağlarının Eğitilmesi

Radyal Temelli fonksiyon ağlarının eğitilmesi genelde 3 adımda yapılır. Bu adımlar merkezlerin yerleştirilmesi, ölçekleme parametrelerinin bulunması, ağırlıkların eğitilmesi adımlarıdır.

Merkezlerin yerleştirilmesi

Bir merkezle bu merkeze karşı gelen saklı katman işlem elemanı, eğitme kümesindeki her bir giriş vektörüne yerleştirilebilir. Bu yöntemin dezavantajı gereğinden fazla saklı katman işlem elemanının karşımıza çıkmasıdır. Bu da uzun eğitim ve çok sayıda hesaplama ortaya çıkarır.

En basit teknik merkez vektörlerini eğitme verilerinin bir alt kümesinden rasgele seçmektir. Böyle bir durumda saklı işlem elemanlarının sayısı bütün giriş uzayını kapsıyacak şekilde geniş olmalıdır.

Ölçekleme Parametrelerinin Belirlenmesi

Ölçek parametrelerinin belirlenmesinin amacı; giriş uzayının mümkün olduğu kadar alıcı alanlarla kaplamaktır. Merkezler birbirinden çok uzaksa uzaklık ölçekleme parametresi “ σ ” yeterince büyük olmalıdır. Merkezler birbirine çok yakınsa tersi durum söz konusudur.

Ağırlıkların eğitilmesi

Hatayı istenen bir değere minimize edecek şekilde saklı katman ve eğitme çıkış verilerini kullanarak en küçük kareler (linear least squares) metoduyla saklı katmandan çıkışa olan ağırlıklar ayarlanır.

4.2.2.3 Radyal Temelli Fonksiyon Ağları Öğrenme Algoritmaları

Sabit merkezlerle en küçük kareler algoritması

Bu yöntemde RTFA merkezlerinin yerleşimlerini ağ giriş vektörlerinden veya giriş verilerinin bulunduğu bölgeden rasgele seçilir. Merkezler sabitlendikten sonra eğitici modda en küçük kareler metoduyla ağırlıklar güncellenir.

Ortogonal en küçük kareler algoritması

Bu yöntemde RTFA için tek bir merkez alınır ve hata kontrolü yapılır. Hata istenilen seviyede değilse bir merkez daha eklenir. İstenilen seviyeye ulaşıldığında merkez eklenmesi kesilir ve ağ eğitici moda geçer ve en küçük kareler yöntemi ile ağırlıklar güncellenir.

İteratif Kümeleme ve en küçük kareler algoritması

RTFA merkezleri iteratif bir kümeleme algoritması kullanılarak ayarlanır. Bu işlem kendi kendine organize (self - organizing) olan bir işlemdir. Çıkış katmanının ağırlıkları eğitici bir öğrenme kuralı kullanılarak hesaplanır ve güncellenir.

4.2.3 Olasılıksal Yapay Sinir Ağları

Olasılıksal yapay sinir ağları genellikle örüntü sınıflama için kullanılan özel bir yapay sinir

ağları çeşididir. Bu tip ağlar bilinmeyen bir örneğin önceden bilinen sınıflarla aynı olması olasılığını hesaplayan ağlardır. Olasılıklar, önceden bilinen merkezlerin Gauss dağılımına göre hesaplanır. Olasılığı en fazla olan örnekler girişlerin elemanı olacağı sınıfları oluşturur.

Olasılıksal yapay sinir ağlarının temelini “Bayes Sınıflayıcısı” (Bayesian Classifier) oluşturmaktadır. Bu sınıflayıcı x 'in c_i sınıfında olma olasılığını belirler.

$$P(c_i / x) = \frac{P(x / c_i)P(c_i)}{\sum_{j=1}^n P(x / c_j)P(c_j)} \quad (4.20)$$


Burada, $P(x / c_i)$ verilen bir c_i kümesindeki x 'in koşullu olasılık yoğunluk fonksiyonudur. $P(c_j)$ ise bahsi geçen verinin diğer sınıf olan c_j 'de olma olasılığıdır. x vektörünün c_i kümesinde olabilmesi için (4.21) sağlanmalıdır.

$$P(c_i / x) > P(c_j / x), \forall j = 1, 2, \dots, n, j \neq i, \quad (4.21)$$

Bayes sınıflayıcısı, verinin alındığı olasılık yoğunluk fonksiyonunu bir öncelik olarak farz eder. Bu kabul bayes sınıflayıcısının hayat geçirilmesindeki en büyük kısıttır. Olasılıksal yapay sinir ağları bayes sınıflayıcısını oluşturmak için, istenilen istatistiki bilgileri sağlayan bir eğitime kümesi kullanarak bu kısıtı ortadan kaldırır. Bir sınıfın istenen olasılık yoğunluk fonksiyonu olasılıksal yapay sinir ağları tarafından yaklaştırılır. Olasılıksal yapay sinir ağları x vektörünün c_i sınıfına ait olmasını belirleyen olasılığını, verilen her eğitim adımında kullanılan ağırlıklı Gauss dağılımı ile yaklaştırır.

$$P(c_i / x) = \frac{1}{(2\pi)^{\frac{N}{2}} \sigma^N n_{i_i}} \sum_{j=1}^{n_{i_i}} \exp\left[-\frac{(x - x_j^i)^T (x - x_j^i)}{2\sigma^2}\right] \quad (4.22)$$

Burada x_j^i i sınıfındaki j. eğitime vektörünü, σ ise yumuşatma parametresidir. “N” giriş vektörünün boyutunu, n_{i_i} ise i sınıfındaki eğitime örneklerinin sayısıdır. Doğrusal olmayan uygulamalarda σ yumuşatma parametresi olabildiğince küçük seçilmelidir. Şekil 4.4’de olasılıksal yapay sinir ağlarının yapısı gösterilmiştir.



Şekil 4.4 Olasılıksal yapay sinir ağının yapısı


Şekil 4.4’de de görüldüğü gibi olasılıksal yapay sinir ağları 4 katmandan oluşmaktadır. Bu katmanlar giriş katmanı, örnek katmanı, toplama katmanı ve çıkış katmanıdır. Giriş katmanı giriş vektörünü örnek katmanına yönlendirir. Örnek katmanı, her eğitme örneğini içere (4.22)’de verilen olasılık yoğunluk fonksiyonunu hesaplar. Toplama katmanı ise örnek kümesinde örneklerle tanımlanan her bir sınıfta bulunan giriş vektörleri için olasılığı ($f_i(x)$) hesaplar. Çıkış katmanı ise toplama katmanında hesaplanan olasılıklara göre sınıfları belirler. Giriş vektörü bu hesaplamalardan sonra sınıflanır.

Olasılıksal yapay sinir ağları için bir diğer husus ise yumuşatma parametresi için doğru değeri hesaplamaktır. Genellikle bu parametrenin seçimi için “çapraz geçerlilik” (cross-validation) metodu kullanılır. Pratikte yumuşatma parametresi için ilk değer rasgele verilir. Eğer sınıflama istenilen sonucu üretmezse bu değer değiştirilir ve yapay sinir ağı tekrardan test edilir. Bu süreçler istenilen değer aralığına ulaşana kadar devam eder.

4.2.4 Genelleştirilmiş Regresyon Yapay Sinir Ağları

Genelleştirilmiş regresyon yapay sinir ağları (GRYSA) herhangi bir fonksiyon yaklaşımı probleminde kullanılabilirler. GRYSA’ların öğrenme süreci, çok boyutlu uzayda eğitme verisine en uygun yüzeyi bulma işlemi ile eşdeğerdir. Bu işlem yapılırken bazı istatistiki

duyarlılıklarca belirlenen “en uygun (best fit) ” kriterine uygun olmalıdır. Genelleme ise bu çok boyutlu yüzeyleri test verilerini değerlendirme için kullanılmasıdır.



Şekil 4.5 Genelleştirilmiş regresyon yapay sinir ağının yapısı

Şekil 4.5’de GRYSA’nın gerçekleştirilmesi için gerekli olan topoloji belirtilmiştir. Görüleceği gibi GRYSA üç katmandan oluşmaktadır. Giriş katmanı, girişlerin uygulandığı katmandır. Saklı katman, giriş katmanından saklı katmana geçerken verilere doğrusal olmayan bir dönüşüm fonksiyonunun uygulandığı katmandır. Çıkış katmanı ise çıkışların üretildiği katmandır.

Dönüşüm fonksiyonu “ ϕ ” için en fazla kullanılan fonksiyon Gauss fonksiyonudur. Saklı katmanın çıkışları (4.23)’teki şekildedir.

$$\phi_k(x) = \exp\left[-\frac{(x - v_k^x)^T (x - v_k^x)}{2\sigma^2}\right] \quad (4.23)$$


Saklı katman işlem elemanlarının çıkışı GRYSA çıkışını üretmek için ağırlıklar ile çarpılır. Herhangi bir k saklı katman elemanı için ağırlıklar;

$$w_k = \frac{v_k^y}{\sum_{k=1}^K N_k \exp\left[-\frac{d(x, v_k^x)^2}{2\sigma^2}\right]} \quad (4.24)$$

Bağıntısı ile bulunur. İyi bir genelleştirme özelliği için yeterli miktarda eğitime verisinden oluşan kümeler oluşturmak gereklidir.

4.3 Çapraz Geçerlilik Metodu ile Eğitime ve Test Verisinin Oluşturulması

Çapraz geçerlilik yöntemi, verilen bir modelin hatasını basitçe hesaplamak için veya verilen bir verinin alt kümelerine ayırmak için kullanılabilir. k-katlı (k-fold) çapraz geçerlilik dendiğinde ilgilenilen veri k tane eşit büyüklükte alt kümeye bölünür. Oluşan bu alt kümelerden bir tanesi dışarıda bırakılarak eğitime kümesi oluşturulur. Eğitime kümesinin dışında kalan alt küme ise ağın testi için kullanılır. Bahsedilen bu işlemler k defa tekrar edilerek işlem tamamlanır.



Şekil 4.6. Çapraz geçerlilik metodu ile veri kümesinin alt kümelere ayrılması

Bu uygulamada EMG verilerinin modellenmesi sonucu oluşan Öz bağımlı katsayılar 5-katlı çapraz geçerlilik metoduyla alt kümelerine ayrılmıştır. Yani 10 x 225 veri kümesi, 10 x 45'lik 5 alt küme (A1, A2, A3, A4, A5) tarafından oluşturulmuştur. Oluşan bu alt kümelerden eğitime ve test verileri oluşturulmuştur. Her defasında bir alt küme dışarıda bırakılarak eğitime kümesi oluşturularak kullanılan ağ tipleri eğitilmiştir. Dışarıda bırakılan alt küme ise test verisi olarak belirlenmiştir ve ağın test edilmesinde kullanılmıştır. Bu işlemler 5 kez tekrarlanmıştır.

Çapraz geçerlilik sonucu oluşan eğitime ve test kümeleri Çizelge 4.3'de belirtilmiştir

Çizelge 4.3 Çapraz geçerlilik sonucu oluşan eğitime ve test kümeleri

Sınıflama Kümesi No	Eğitime Kümesi	Test Kümesi
1	A1, A2, A3,A4	A5
2	A1, A3, A4, A5	A2
3	A1, A2, A4, A5	A3
4	A1, A2, A3, A5	A4
5	A2, A3, A4, A5	A1

4.4 Uygulamada kullanılan YSA'ların topolojisi

Sınıflama için kullanılan İleri Beslemeli Geri Yayılımlı ağ tipi 3 katmandan oluşmuştur. 1. katman olan giriş katmanı 10 giriş işlem elemanından oluşmuştur. 2.katman olan saklı katman 20 saklı işlem elemanından oluşmuştur. 3.katman olan çıkış katmanı da 2 çıkış elemanından oluşmaktadır. Farklı öğrenme değerleri için bu ağ eğitilmiştir. Ağın eğitiminde Levenberg-Marquardt eğitim algoritması kullanılmıştır.

İleri beslemeli geri yayılımlı ağlar ilk koşullara bağımlı olduğu için, bu ağ birçok kere art arda eğitilerek çalıştırılmış ve çıkan sonuçların ortalaması alınmıştır.

Sınıflama için kullanılan bir diğer YSA tipi ise Radyal Temelli Fonksiyon Ağlarıdır. Bu ağ tipi 2 katmandan oluşmaktadır. Bu katmanlar saklı katman ve çıkış katmanıdır. Saklı katmanda 10 adet işlem elemanı bulunmaktadır. Çıkış katmanında ise çıkış değerlerinin elde edildiği 2 adet işlem elemanı bulunmaktadır. Bu ağ tipinde ise farklı yayılım (spread) değerleri için ağ eğitilmiş ve test edilmiştir.

Sınıflamada kullanılan üçüncü ağ yapısı ise Genelleştirilmiş Regresyon Ağlarıdır. Bu ağ tipi 2 katmandan oluşmuştur. Girişlerin uygulandığı saklı katmanda 10 işlem elemanı bulunmakta

ve çıkış katmanında 2 işlem elemanı bulunmaktadır. Farklı yayılım değerleri için ağ eğitilmiş ve test edilmiştir.

Son kullanılan ağ tipi ise Olasılıksal Yapay Sinir Ağlarıdır. İki katmandan oluşan bu ağda girişleri uygulandığı ve 10 işlem elemanından oluşan bir saklı katman ve 2 işlem elemanından oluşan bir çıkış katmanı bulunmaktadır. Değişik yayılım değerleri için ağ eğitilmiş ve test edilmiştir.

5. SONUÇLAR ve ÖNERİLER

5.1 SONUÇLAR

Bu bölümde Yapay Sinir Ağlarının eğitilmesi sonucu oluşturulan ağların test sonuçları verilecektir.

5.1.1 İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağları Test Sonuçları

İleri Beslemeli Yapay Sinir Ağları değişik öğrenme oranları (lr) için test edilmiştir. Bu öğrenme oranları 0,5, 0,75, 0,8, 0,85, 0,9 değerleridir. 5-katlı çapraz geçerlilik testi sonucu oluşturulan eğitme ve test verilerini yukarıda bahsedilen öğrenme oranlarını kullanarak ileri beslemeli geri yayılımlı ağın doğruluk oranı belirlenmiştir. İleri beslemeli geri yayılımlı ağda her eğitme kümesi ve test kümesi için ağ üst üste 10 defa çalıştırılmış ve doğruluk oranlarının ortalaması alınmıştır. Bunun nedeni ileri beslemeli geri yayılımlı ağların ilk koşullara olan bağımlılığıdır.

Çizelge 5.1’de $lr=0,5$ değeri için ve 5-katlı çapraz geçerlilik işleminin sonucunda üretilen doğruluk oranı belirtilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.1’de bahsedilen Test1; 5-katlı çapraz geçerlilik sonucu elde edilen 5 alt kümeden (A1,A2,A3,A4,A5) A1, A2, A3, A4 kümeleri ile ağın eğitilmesi sonucunda oluşan ağ yapısının ve değerlerinin A5 alt kümesi ile test edilme işlemidir.

Aynı şekilde Test 2 ise 5-katlı çapraz geçerlilik sonucu elde edilen 5 alt kümeden (A1,A2,A3,A4,A5) A1, A3, A4, A5 kümeleri ile ağın eğitilmesi sonucunda oluşan ağ yapısının ve değerlerinin A2 alt kümesi ile test edilme işlemidir.

Test 3 işlemi ise 5-katlı çapraz geçerlilik sonucu elde edilen 5 alt kümeden (A1,A2,A3,A4,A5) A1, A2, A4, A5 kümeleri ile ağın eğitilmesi sonucunda oluşan ağ yapısının ve değerlerinin A3 alt kümesi ile test edilme işlemidir.

Test 4 işlemi ise 5-katlı çapraz geçerlilik sonucu elde edilen 5 alt kümeden (A1,A2,A3,A4,A5) A1, A2, A3, A5 kümeleri ile ağın eğitilmesi sonucunda oluşan ağ yapısının ve değerlerinin A4 alt kümesi ile test edilme işlemidir.

Test 5 işlemi ise 5-katlı çapraz geçerlilik sonucu elde edilen 5 alt kümeden (A1,A2,A3,A4,A5) A2, A3, A4, A5 kümeleri ile ağı eğitilmesi sonucunda oluşan ağ yapısının ve değerlerinin A1 alt kümesi ile test edilme işlemidir. Test sonuçları Çizelge 5.1’de gösterilmiştir.

Çizelge 5.1 $lr=0,5$ için ileri beslemeli geri yayımlı ağ test sonuçları

Test Numarası	BI	FR	APB	Doğru Sayısı	%
Test 1	14	14,3	12	40,3	89,55556
Test 2	13,8	14,2	13,2	41,2	91,55556
Test 3	13,6	11,8	13,2	38,6	85,77778
Test 4	11,8	14,2	14,2	40,2	89,33333
Test 5	13,6	14,8	12,8	41,2	91,55556
Ortalama	13,36	13,86	13,08	40,3	89,55556

Çizelge 5.2’de $lr=0,75$ değeri için ve 5-katlı çapraz geçerlilik işleminin sonucunda üretilen doğruluk oranı belirtilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir. Test sonuçları Çizelge 5.2’de gösterilmiştir.

Çizelge 5.2 $lr=0,75$ için ileri beslemeli geri yayımlı ağ test sonuçları

Test Numarası	BI	FR	APB	Doğru Sayısı	%
Test 1	13,9	14,4	12,4	40,7	90,44444
Test 2	13,8	12,9	13,3	40	88,88889
Test 3	13,9	12,3	13,2	39,4	87,55556
Test 4	14,5	13,9	13,2	41,6	92,44444
Test 5	12,7	14,7	12,6	40	88,88889
Ortalama	13,76	13,64	12,94	40,34	89,64444

Çizelge 5.3’de $lr=0,8$ değeri için ve 5-katlı çapraz geçerlilik işleminin sonucunda üretilen

doğruluk oranı belirtilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir. Test sonuçları Çizelge 5.3’de gösterilmiştir.

Çizelge 5.3 $lr=0,8$ için ileri beslemeli geri yayımlı ağ test sonuçları

Test Numarası	BI	FR	APB	Doğru Sayısı	%
Test 1	14,5	14,3	12,3	41,1	91,33333
Test 2	13,8	14,3	13,8	41,9	93,11111
Test 3	14	11	13,1	38,1	84,66667
Test 4	14,8	13,7	13,7	42,2	93,77778
Test 5	11,7	14,9	13,1	39,7	88,22222
Ortalama	13,76	13,64	13,2	40,6	90,22222

Çizelge 5.4’de $lr=0,85$ değeri için ve 5-katlı çapraz geçerlilik işleminin sonucunda üretilen doğruluk oranı belirtilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir. Test sonuçları Çizelge 5.4’de gösterilmiştir.

Çizelge 5.4 $lr=0,85$ için ileri beslemeli geri yayımlı ağ test sonuçları

Test Numarası	BI	FR	APB	Doğru Sayısı	%
Test 1	14,5	14	12,1	40,6	90,22222
Test 2	12,3	12,6	13,1	38	84,44444
Test 3	13	14,2	13,8	41	91,11111
Test 4	14,4	12,7	13,7	40,8	90,66667
Test 5	13	15	12,6	40,6	90,22222
Ortalama	13,44	13,7	13,06	40,2	89,33333

Çizelge 5.5’de $lr=0,8$ değeri için ve 5-katlı çapraz geçerlilik işleminin sonucunda üretilen doğruluk oranı belirtilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis

(FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir. Test sonuçları Çizelge 5.5’de gösterilmiştir.

Çizelge 5.5 $lr=0,9$ için ileri beslemeli geri yayımlı ağ test sonuçları

Test Numarası	Bl	FR	APB	Doğru Sayısı	%
Test 1	14,2	14,4	11,7	40,3	89,55556
Test 2	13,7	14,7	13,4	41,8	92,88889
Test 3	13,2	12,1	13,1	38,4	85,33333
Test 4	14,8	14,2	13,5	42,5	94,44444
Test 5	12,6	15	12,9	40,5	90
Ortalama	13,7	14,08	12,92	40,7	90,44444

Elde edilen sonuçların genel değerleri Çizelge 5.6’da verilmiştir.

Çizelge 5.6 Çeşitli lr değerleri için ileri beslemeli geri yayımlı ağ test sonuçları

Öğrenme oranı	Bl	FR	APB	Doğru Sayısı	%
0,5	13,36	13,86	13,08	40,3	89,55556
0,75	13,76	13,64	12,94	40,34	89,64444
0,8	13,76	13,64	13,2	40,6	90,22222
0,85	13,44	13,7	13,06	40,2	89,33333
0,9	13,7	14,08	12,92	40,7	90,44444

5.1.2 Radyal Temelli Fonksiyon Ağları İçin Test Sonuçları

Radyal Temelli Fonksiyon Ağları; değişik yayılma katsayıları (sp) için test edilmiştir. Bu yayılma katsayıları 70, 71, 80 ve 82 değerleridir. 5-katlı çapraz geçerlilik testi sonucu oluşturulan eğitme ve test verilerini yukarıda bahsedilen yayılma katsayılarını kullanarak Radyal temelli fonksiyon ağının doğruluk oranı belirlenmiştir

Çizelge 5.7’de test 1 verisi, $sp=70, 71, 80, 82$ değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının

kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.7 Test1 verisi için farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları

sp	BI	FR	APB	Doğru Sayısı	%
70	14	15	13	42	93,333
71	14	15	13	42	93,333
80	14	15	12	41	91,111
82	14	15	12	41	91,111

Çizelge 5.8’de test 2, verisi sp=70, 71, 80, 82 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.8 Test 2 verisi için farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları

sp	BI	FR	APB	Doğru Sayısı	%
70	12	13	13	38	84,444
71	12	13	14	39	86,667
80	12	13	13	38	84,444
82	13	12	13	38	84,444

Çizelge 5.9’da test 3 verisi, sp=70, 71, 80, 82 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.9 Test 3 verisi için farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları

sp	BI	FR	APB	Doğru Sayısı	%
70	15	12	13	40	88,889
71	15	12	14	41	91,111
80	15	12	14	41	91,111
82	15	12	13	40	88,889

Çizelge 5.10’da test 4 verisi, sp=70, 71, 80, 82 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.10 Test 4 verisi için farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları

sp	BI	FR	APB	Doğru Sayısı	%
70	15	15	13	43	95,556
71	15	14	13	42	93,333
80	15	14	13	42	93,333
82	15	14	15	44	97,778

Çizelge 5.11’de test 5 verisi, sp=70, 71, 80, 82 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.11 Test 5 verisi için farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları

sp	Bl	FR	APB	Doğru Sayısı	%
70	13	14	13	40	88,889
71	14	14	13	41	91,111
80	13	14	14	41	91,111
82	14	14	14	42	93,333

Radyal temelli fonksiyon ağının genel değerlerini bulabilmek için test 1, test 2, test 3, test 4, test 5 işlemlerinin ortalamaları alınmıştır. Bu değerler Çizelge 5.12’de verilmiştir.

Çizelge 5.12 Farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları

sp	Bl	FR	APB	Doğru Sayısı	%
70	13,8	13,8	13	40,6	90,22222
71	14	13,6	13,4	41	91,11111
80	13,8	13,6	13,2	40,6	90,22222
82	14,2	13,4	13,4	41	91,11111

5.1.3 Genelleştirilmiş Regresyon Ağları İçin Test Sonuçları

Genelleştirilmiş Regresyon Ağları; değişik yayılma katsayıları (sp) için test edilmiştir. Bu yayılma katsayıları 0,02, 0,07 ve 0,5 değerleridir. 5-katlı çapraz geçerlilik testi sonucu oluşturulan eğitme ve test verilerini yukarıda bahsedilen yayılma katsayılarını kullanarak genelleştirilmiş regresyon ağının doğruluk oranı belirlenmiştir.

Çizelge 4.13’de test 1 verisi, sp=0,02, 0,07 ve 0,5 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.13 Test 1 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları

sp	Bl	FR	APB	Doğru Sayısı	%
0,02	10	6	3	19	42,222
0,07	13	11	10	34	75,556
0,5	10	10	7	27	60,000

Çizelge 5.14’de test 2 verisi, $sp=0,02$, 0,07 ve 0,5 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.14 Test 2 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları

sp	Bl	FR	APB	Doğru Sayısı	%
0,02	8	6	4	18	40,000
0,07	8	11	8	27	60,000
0,5	10	10	7	27	60,000

Çizelge 5.15’de test 3 verisi, $sp=0,02$, 0,07 ve 0,5 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.15 Test 3 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları

sp	Bl	FR	APB	Doğru Sayısı	%
0,02	8	8	5	21	46,667
0,07	13	12	10	35	77,778
0,5	9	9	8	26	57,778

Çizelge 5.16’de test 4 verisi, $sp=0,02$, $0,07$ ve $0,5$ değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.16 Test 4 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları

sp	BI	FR	APB	Doğru Sayısı	%
0,02	11	9	3	23	51,111
0,07	13	12	8	33	73,333
0,5	11	8	9	28	62,222

Çizelge 5.17’de test 5 verisi, $sp=0,02$, $0,07$ ve $0,5$ değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.17 Test 5 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları

sp	BI	FR	APB	Doğru Sayısı	%
0,02	9	8	4	21	46,667
0,07	13	12	9	34	75,556
0,5	9	10	11	30	66,667

Genelleştirilmiş regresyon ağının genel değerlerini bulabilmek için test 1, test 2, test 3, test 4, test 5 işlemlerinin ortalamaları alınmıştır. Bu değerler Çizelge 5.18’de verilmiştir.

Çizelge 5.18 Farklı sp değerlerinde radyal temelli fonksiyon ağı test sonuçları

sp	Bl	FR	APB	Doğru Sayısı	%
0,02	9,2	7,4	3,8	20,4	45,33333
0,07	12	11,6	9	32,6	72,44444
0,5	9,8	9,4	8,4	27,6	61,33333

5.1.4 Olasılıksal Yapay Sinir Ağları İçin Test Sonuçları

Olasılıksal Yapay Sinir Ağları; değişik yayılma katsayıları (sp) için test edilmiştir. Bu yayılma katsayıları 0,0125, 0,2 ve 0,5 değerleridir. 5-katlı çapraz geçerlilik testi sonucu oluşturulan eğitme ve test verilerini yukarıda bahsedilen yayılma katsayılarını kullanarak genelleştirilmiş regresyon ağının doğruluk oranı belirlenmiştir.

Çizelge 5.19’da test 1 verisi, sp=0,0125, 0,2 ve 0,5 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (Bl), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.19 Test 1 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları

sp	Bl	FR	APB	Doğru Sayısı	%
0,0125	13	12	0	25	55,556
0,2	12	12	0	24	53,333
0,5	12	10	0	22	48,889

Çizelge 5.20’de test 2 verisi, sp=0,0125, 0,2 ve 0,5 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (Bl), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.20 Test 2 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları

sp	Bl	FR	APB	Doğru Sayısı	%
0,0125	10	13	0	23	51,111
0,2	13	13	0	26	57,778
0,5	13	13	0	26	57,778

Çizelge 5.21’de test 3 verisi, $sp=0,0125$, 0,2 ve 0,5 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.21 Test 3 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları

sp	Bl	FR	APB	Doğru Sayısı	%
0,0125	13	14	0	27	60,000
0,2	13	11	0	24	53,333
0,5	13	9	0	22	48,889

Çizelge 5.22’de test 4 verisi, $sp=0,0125$, 0,2 ve 0,5 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.22 Test 4 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları

sp	Bl	FR	APB	Doğru Sayısı	%
0,0125	12	13	0	25	55,556
0,2	14	13	0	27	60,000
0,5	14	12	0	26	57,778

Çizelge 5.23’de test 5 verisi, $sp=0,0125$, 0,2 ve 0,5 değerleri için test edilmiştir. Aynı zamanda test verilerinde bulunan Biceps (BI), Frontalis (FR) ve Abductor Pollicis Brevis (APB) kaslarının kaçının doğru tahmin edildiği ve toplam doğru sayısı verilmiştir.

Çizelge 5.23 Test 5 verisi için farklı sp değerlerinde genelleştirilmiş regresyon ağının test sonuçları

sp	BI	FR	APB	Doğru Sayısı	%
0,0125	13	14	0	27	60,000
0,2	14	14	0	28	62,222
0,5	14	12	0	26	57,778

Olasılıksal yapay sinir ağının genel değerlerini bulabilmek için test 1, test 2, test 3, test 4, test 5 işlemlerinin ortalamaları alınmıştır. Bu değerler Çizelge 5.24’de verilmiştir.

Çizelge 5.24 Farklı sp değerlerinde olasılıksal yapay sinir ağı test sonuçları

sp	BI	FR	APB	Doğru Sayısı	%
0,0125	12,2	13,2	0	25,4	56,44444
0,2	13,2	12,6	0	25,8	57,33333
0,5	13,2	11,2	0	24,4	54,22222

5.1.5 Alıcı Çalışma Karakteristikleri Analizi

Tanılama, teşhis gibi konularda yoğun klinisyenlere ve bu konulardaki hasta önemini arttırmak için birçok akıllı medikal sistemler geliştirilmiştir. Fakat bu medikal sistemlerin çok azı uygulamalarda kullanılmaktadır. Bunun nedeni ise sistemlerin güvenlik, performans ve etkinliği hakkında bir kesinlik yoktur. Bu konulara dayanıklı metotların, elde edilen sonuçların objektif bir şekilde o işin uzmanları tarafından kıyaslanmasına izin vermesi gerekmekte ve doğru tahmin yapabilmesi ile bu akıllı sistemlerin performansının istenilen düzeyde olması gerekmektedir. Güvenliğin kritik olduğu durumlarda, bu tür sistemlerin klinik uygulamalarda genel bir geçerliliğinin olması için değerlendirme yapabilmek için objektif bir metoda sahip olmak gerekmektedir.

Alıcı Çalışma Karakteristikleri (Receiver Operating Characteristics) eğrileri medikal sistemlerde kuvvetli ve objektif değerlendirmeler için bir temel form oluştururlar. Bu yöntem alanında uzman kişilerin verdiği bilgilerle elde edilen tanının karşılaştırılmasına izin vermektedir. Sistemin performansındaki istatistiksel belirsizlikler nicel olarak belirlenmesi ile sistemin riski hesaplanabilir. Var olan alıcı çalışma karakteristikleri (AÇK) analizlerinde geniş çaplı istatistiksel veriler gerekmektedir.

AÇK eğrileri genellikle iki sınıflı bir sınıflayıcıda kullanılırlar (Metz C.E., 1978,1986). İki sınıfa sahip bir sınıflayıcı için değişik performans ölçme yöntemleri bulunmaktadır. Bunlardan bazıları çiftli karşılaştırma (pairwise comparison), Hand and Till M fonksiyonları, bire karşı tüm karşılaştırılması (one-versus-all) ve örümcek ağı (cobweb) gösterimidir.

5.1.5.1 Bire karşı tüm karşılaştırması (one-versus-all)

Bu karşılaştırmada, S-sınıflı bir sınıflandırma problemi, bire karşı diğerleri şeklinde ikili biçime ayrılabilir. S tane sınıfı olan bir sınıflandırma probleminde S adet ikili gösterim mevcuttur. Uygulamadaki sınıflama probleminin 3 adet sınıfı olduğundan, 3 adet ikili gösterim bulunmaktadır. Bu gösterimler Biceps'e karşı Frontalis ve Abductor Pollicis Brevis, Frontalis'e karşı Biceps ve Abductor Pollicis Brevis ve son ikili gösterim ise Abductor Pollicis Brevis'e karşı Biceps ve Frontalis gösterimidir.

Bu karşılaştırmaların yapılabilmesi için duyarlılık (sensitivity), belirlilik (specificity) ve $d_{\text{gerçek}}$ kavramlarına ihtiyaç vardır. Bu kavramları Çizelge 5.25 üzerinden incelersek,

Çizelge 5.25 Hata Matrisi (confusion matrix)

		Beklenen Sınıf	
		P	N
Tahmin Edilen Sınıf	T	TP	FP
	F	FN	TN

Burada eğer örnek pozitif ise ve tahmin edilen değer pozitif ise bu değer TP (True Positive) olarak nitelendirilir. Eğer negatif olarak tahmin edilirse FN (False Negative) olarak nitelendirilir. Eğer örnek negatif ise ve tahmin edilen değer negatif ise TN (True Negative) olarak nitelendirilir. Eğer örnek pozitif olarak tahmin edilmişse FP (False Positive) olarak nitelendirilir. Bu bağlamda duyarlılık, belirlilik, $d_{\text{gerçek}}$ kavramları aşağıdaki gibi tanımlanır.

$$\text{Duyarlılık} = TP / (TP + FN) \quad (5.1)$$

$$\text{Belirlilik} = TN / (TN + FP) \quad (5.2)$$

$$d_{\text{gercek}} = \sqrt{(1 - \text{duyarlilik})^2 (1 - \text{belirlilik})^2} \quad (5.3)$$

Burada d_{gercek} ne kadar küçük olursa sınıflayıcının performansı da o derecede yüksektir.

Duyarlılık, belirlilik, d_{gercek} değerlerinin hesaplanmasında testlerde sonucu en iyi değer veren İleri Beslemeli Geri Yayılımlı YSA ve Radyal Temelli Fonksiyon Ağı için bulunmuştur. İleri beslemeli geri yayılımlı ağı için en iyi değer, $lr = 0,9$ olan test 4 tarafından sağlanmıştır. Bu teste ait hata matrisi Çizelge 5.26’da verilmiştir.

Çizelge 5.26 İleri beslemeli geri yayılımlı YSA için test 4 Hata Matrisi

		Beklenen Sınıf		
		Bl	FR	APB
Tahmin Edilen Sınıf	Bl	15	0	0
	FR	1	14	0
	APB	0	0	15

Radyal temelli fonksiyon ağı için en iyi değer, $sp = 82$ olan test 4 tarafından sağlanmıştır. Bu teste ait hata matrisi Çizelge 5.27’da verilmiştir.

Çizelge 5.27 Radyal temelli fonksiyon ağı için test 4 Hata Matrisi

		Beklenen Sınıf		
		Bl	FR	APB
Tahmin Edilen Sınıf	Bl	15	0	0
	FR	0	14	0
	APB	0	0	15

Yukarıda da bahsedildiği gibi bire karşı tüm tekniğini kullanarak Biceps’e karşı Frontalis ve Abductor Pollicis Brevis, Frontalis’e karşı Biceps ve Abductor Pollicis Brevis, Abductor Pollicis Brevis’e karşı Biceps ve Frontalis ikilileri için Çizelge 5.26 ve 5.27’de verilen hata

matrislerini kullanarak duyarlılık, belirlilik, $d_{\text{gerçek}}$ değerleri hesaplanacaktır. Biceps'e karşı Frontalis ve Abductor Pollicis Brevis'e ait değerler Çizelge 5.28'de gösterilmiştir.

Çizelge 5.28 Biceps'e karşı Frontalis ve Abductor Pollicis Brevis'e ait değerler

Ağ Tipi	Duyarlılık	Belirlilik	$d_{\text{gerçek}}$
İleri Beslemeli Geri Yayılımlı YSA	0,9375	1	0,0625
Radyal Temelli Fonksiyon Ağı	1	1	0

Frontalis'e karşı Biceps ve Abductor Pollicis Brevis'e ait değerler Çizelge 5.29'da gösterilmiştir.

Çizelge 5.29 Frontalis'e karşı Biceps ve Abductor Pollicis Brevis'e ait değerler

Ağ Tipi	Duyarlılık	Belirlilik	$d_{\text{gerçek}}$
İleri Beslemeli Geri Yayılımlı YSA	1	0,9677	0,0323
Radyal Temelli Fonksiyon Ağı	1	1	0

Abductor Pollicis Brevis'e karşı Biceps ve Frontalis'e ait değerler Çizelge 5.30'da gösterilmiştir.

Çizelge 5.30 Abductor Pollicis Brevis'e karşı Biceps ve Frontalis'e ait değerler

Ağ Tipi	Duyarlılık	Belirlilik	$d_{\text{gerçek}}$
İleri Beslemeli Geri Yayılımlı YSA	1	1	0
Radyal Temelli Fonksiyon Ağı	1	1	0

5.2 ÖNERİLER

Bölüm 5.1’de verilen ve test sonuçlarından oluşan çizelgelerden yola çıkarak Biceps, Frontalis ve Abductor Pollicis Brevis kaslarına ait sınıflama probleminde, olasılıksal yapay sinir ağı ve genelleştirilmiş regresyon ağlarının performanslarının düşük olduğu gözlemlenmiştir.

Bu sınıflama problemine karşı performansı en yüksek olan ağ yapısı radyal temelli fonksiyon ağlarıdır. İkinci en yüksek performans ise ileri beslemeli geri yayımlı ağ yapısıdır.

Radyal temelli fonksiyon ağının bu yüksek performansının yanında hata matrisinde de görüldüğü gibi Frontalis sınıfına ait 15 örnekten 14’ünü sınıflayabilmiştir. Fakat bir örnek için hiçbir sınıf belirleyememiştir. Eşik değerleri üzerinde ne kadar oynanırsa oynansın bu tablo tekrardan yaşanmaktadır. Bu özellik uygulamada kullanılan radyal temelli fonksiyon ağı için bir dezavantajdır.

İleri beslemeli geri yayımlı ağ yapısının performansı, radyal temelli fonksiyon ağının performansından düşük olmasına rağmen hata matrisine bakıldığında her sınıfın örnekleri hakkında doğru veya yanlış bir sınıflama yapmıştır.

Bu çalışma EMG sinyali ile kayıt kası ilişkisinin kurulması; nörojen tutulumunu, miyojen tutulumundan ayırt etmek için bir temel oluşturacaktır. Kol kasından kaydedilen EMG işareti, yüz kasının işareti gibi sınıflanırsa inceleme altındaki kasın miyojen tutulumu olduğu; el kası gibi sınıflanırsa da nörojen tutulumu olduğu kestirilecektir.

KAYNAKLAR

- Christodoulou, C., Pattichis, C.S., (1995), "A new technic for the classification and decomposition of EMG signals ", IEEE international Conference on Neural Networks Proceedings, Vol. 5, IEEE, New York, pp. 2303- 2308
- De Luca, J.C., (1993), "Precision decomposition of EMG signals", Methods Clin Neurophysiol 4, 1-28,
- Fawset, T., (2005), "An introduction to ROC analysis" , Pattern Recognition Letters 27 (2006) 861-874
- Graupe, D., Cline, W.K., (1975), "Functional seperation of EMG signals via ARMA identification methods for prosthetic control purposes", IEEE Trans. Syst. Man Cybern 5, 252-259
- Haykin, S. (1991), Adaptive Fitler Theory, PRENTICE HALL
- Ioannidis, J.P.A., McQueen P.G., Goedert J.J., Kaslow R.A., (1998), "Use of Neural Networks to Model Complex Immunogenetic Associations of Disease: Human Leukocyte Antigen Impact on the Progression of Human Immunodeficiency Virus Infection", American Journal of Eptdemlotogy Vol. 147, No. 5
- Kelly, M., Parker, P.A., (1990), "The Application of Neural Networks to myoelectric signal analysis: A preliminary study ", IEEE Trans BME 37, 221-230
- Kiryu T., De Luca, C.J., Saitoh, Y., (1994), "AR modelling of myoelectric interference signals during a ramp contraction", IEEE Trans BME 41, 1031-1038
- Kyberd, P., (2000), "Intelligent hand", IEEE Rev. 31-35
- Maranzana , M., Fabbro, M., (1981), "Autoregressive description of EMG signals", ISEK Far East Regional Meeting
- Merletti , R., Conte, L.L., (1995), "Advances in processing surface of surface myoelectric signals. Part 1 ", Med. Biol. Eng. Comp. 33, 362-72
- Merletti, R. ve Parker, P. A., (2004), Electromyography Phsiology, Engineering and Noninvasive Applications, WILEY – INTERSCIENCE
- Öztemel E., (2003), Yapay Sinir Ağları, Papatya Yayıncılık Eğitim Bilgisayar Sis. San. ve Tic. A.Ş.
- Paiss, O., Inbar, G., (1987), "Autoregressive modelling of surface EMG and its spectrum with application to fatigue ", IEEE Trans BME 34, 761-770
- Reaz, M. B. I., Hussain M. S., Mohd-Yasin, F., (2006), " Techniques of EMG signal analysis: detection, processing, classification and applications", Biological Procedures Online, 8(1): 11-35
- Stegeman, D.J., Blok J.H., Hermens, H.J., Roeleveld , K., (2000), "Surface EMG models: Properties and Applications", J Electromyogr Kinesiol 10, 313-326
- Tsuji T., Fukuda O., Kaneko M. and Ito K., (2000), " Pattern classication of time-series EMG signals using neural networks", INTERNATIONAL JOURNAL OF ADAPTIVE CONTROL AND SIGNAL PROCESSING, 14:829-848
- Tokan, F., Türker, N., Yıldırım, T., (2005), "EKOKARDİYOGRAM VERİLERİNİN YAPAY SİNİR AĞLARI İLE DEĞERLENDİRİLMESİ", Biyomedikal Mühendisliği Ulusal Toplantısı, BİYOMUT 2005, İstanbul-TÜRKİYE
- Übeyli, E.D., Güler, İ., (2004), "AR VE ARMA METOTLARININ KULLANIMI İLE

TEŞHİS SİSTEMLERİ İÇİN ÖZNİTELİK ÇIKARMA: OFTALMİK ATARDAMAR DOPPLER İŞARETLERİNİN DURUM ANALİZİ”, Gazi Üniv. Müh. Mim. Fak. Der. Cilt 19, No 4, 405-413

Yazgan,E. ve Korürek, M, (1996), Tıp Elektronik, İstanbul Teknik Üniversitesi Elektrik-Elektronik Fakültesi Ofset Baskı Atölyesi

ÖZGEÇMİŞ

Doğum tarihi 11.08.1981

Doğum yeri Bolu

Lise 1996-1999 Erzurum İbrahim Hakkı Fen Lisesi

Lisans 2000-2004 Sakarya Üniversitesi Mühendislik Fak.
Elektrik-Elektronik Mühendisliği Bölümü

Yüksek Lisans 2004-2007 Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü
Elektronik ve Haberleşme Müh. Anabilim Dalı, Elektronik
Programı

Çalıştığı kurum(lar)

2004-Devam ediyor İstanbul Büyükşehir Belediyesi