



T.C.
KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EMG İŞARETLERİNİN SINIFLANDIRILMASI VE ÖBEKLEŞTİRİLMESİ

MÜCAHİD GÜNAY

YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

KAHRAMANMARAŞ 2011

T.C.
KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EMG İŞARETLERİNİN SINIFLANDIRILMASI
VE ÖBEKLEŞTİRİLMESİ

MÜCAHİD GÜNAY

Bu tez,
Elektrik-Elektronik Mühendisliği Anabilim Dalında
YÜKSEK LİSANS
derecesi için hazırlanmıştır.

KAHRAMANMARAŞ 2011

Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü öğrencisi Mücahid GÜNAY tarafından hazırlanan “EMG İşaretlerinin Sınıflandırılması ve Öbekleştirilmesi” adlı bu tez, jürimiz tarafından 10/01/2011 tarihinde oy birliği ile Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Yrd.Doç.Dr.Ahmet ALKAN(DANIŞMAN)

Elektrik-Elektronik Mühendisliği Anabilim Dalı, K.S.Ü.

Prof.Dr.M.Kemal KIYMIK(ÜYE)

Elektrik-Elektronik Mühendisliği Anabilim Dalı, K.S.Ü.

Yrd.Doç.Dr.M.Sait BOZGEYİK(ÜYE)

Fizik Mühendisliği Anabilim Dalı, K.S.Ü.

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylarım.

Prof.Dr.Hakkı ALMA

Fen Bilimleri Enstitüsü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

Mücahid Günay

Bu çalışma KSÜ Bilimsel Araştırma Projeleri Yönetim Birimi tarafından desteklenen “Protez Kollar için EMG İşaretlerinin Sınıflandırılması ve Tanımlanması” adlı Yüksek Lisans Projesi tarafından desteklenmiştir.
Proje No: 2010/5-8 YLS

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

EMG İŞARETLERİNİN SINIFLANDIRILMASI VE ÖBEKLEŞTİRİLMESİ (YÜKSEK LİSANS TEZİ)

MÜCAHİD GÜNAY

ÖZ

Bu çalışmada Elektromiyografi (EMG) işaretleri kullanılarak başarılı bir kol protez kontrolü için gerekli olan işaretlerin öbekleştirilmesi ve sınıflandırılması araştırılmıştır. Çalışmada dört farklı hareket için biceps ve triceps kaslarından üretilen EMG işaretleri incelenmiştir. Bu amaçla çalışmada koldan alınan 4 farklı harekete ait EMG işareti K-Ortalama, Bulanık C Ortalama, Destek Vektör Makineleri, Diskriminant Analizi, Olasılıksal Sinir Ağları ve İleri Beslemeli Yapay Sinir Ağları algoritmaları kullanılarak öbekleştirme ve sınıflandırma gerçekleştirilmiştir. Bu algoritmalar kullanılmadan önce işaretlerin bir ön işlemeden geçirilmesi gerekmektedir. Ön işlemede çok değişik uygulamalar mevcuttur. Bu amaçla işaretlerin Ortalama Mutlak Değer, Hareketli Averaj Filtresi, Eğri Uydurma ve Özbağlanım metotlarıyla özellik vektörleri elde edilmiştir. Elde edilen bu özellik vektörleri öbekleştirme algoritmalarına giriş olarak uygulanmıştır. Kullanılan veri seti üzerinde oldukça başarılı öbekleştirme ve sınıflandırma sonuçları elde edilmiştir.

Anahtar Kelimeler: EMG; DVM; LDA; YSA; Olasılıksal Sinir Ağları; K-Ortalama; Bulanık C-Ortalama.

Kahramanmaraş Sütçü İmam Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı, 01 / 2011

Danışman: Yrd.Doç.Dr.Ahmet ALKAN

Sayfa sayısı: 84

CLASSIFICATION AND CLUSTERING OF EMG SIGNALS

(M.Sc. THESIS)

MÜCAHİD GÜNAY

ABSTRACT

In this thesis, classification and clustering of electromyography (EMG) signals studied required for a prosperous arm prosthesis control. EMG signals generated by biceps and triceps muscles for four different movements are examined. To this end, clustering and classifying is carried out to EMG signals regarding to four different movements captured from the arm, by using K-Means, Fuzzy C Means, Support Vector Machine, Discriminant Analysis, Probabilistic Neural Network and Feed Forward Artificial Neural Network algorithms. Prior to these algorithms, signals need to be preprocessed. There exists abundant different appliances in preprocessing. For this purpose, by using Mean Absolute Value, Moving Average Filter, Curve Fitting and Autoregressive methods, the feature vectors of the signals are acquired. These feature vectors are provided as inputs to the classification/clustering algorithms. On the used data sets, very high classification/clustering performances are achieved.

Key Words: EMG; SVM; LDA; ANN; PNN; K-Means; Fuzzy C-Means.

Kahramanmaraş Sütçü İmam University
Institute for Graduate Studies in Science and Technology
Department of Electrical-Electronics Engineering 01 / 2011

Supervisor: Assist.Prof.Dr.Ahmet ALKAN

Page number: 84

EMG İŞARETLERİNİN SINIFLANDIRILMASI VE ÖBEKLEŞTİRİLMESİ

ÖZET

Bu çalışmada Elektromiyografi (EMG) işaretleri kullanılarak başarılı bir kol protez kontrolü için gerekli olan işaretlerin öbekleştirilmesi ve sınıflandırılması araştırılmıştır. EMG işaretleri kas liflerinin kasılması sonucu oluşan çok sayıda aksiyon potansiyellerin birleşimi olup deri yüzeyinde algılanmaktadır. Çalışmada dört farklı hareket için biceps ve triceps kaslarından üretilen EMG işaretleri incelenmiştir. Her EMG işaretinin tek bir örüntüsü olup, bu örüntülerin doğru ayrıştırılması ve sınıflandırılması önemlidir. Özellikle protez kol tasarımlarında değişik hareketler yapılırken elde edilen EMG işaretlerinin analizi oldukça önemlidir. Bu amaçla çalışmada koldan alınan 4 farklı harekete ait EMG işareti K- Ortalama, Bulanık C Ortalama, Destek Vektör Makineleri, Diskriminant Analizi, Olasılıksal Sinir Ağları ve İleri Beslemeli Yapay Sinir Ağları algoritmaları kullanılarak öbekleştirme ve sınıflandırma gerçekleştirilmiştir. Bu algoritmalar kullanılmadan önce işaretlerin bir ön işlemeden geçirilmesi gerekmektedir. Ön işlemede çok değişik uygulamalar mevcuttur. Bu amaçla işaretlerin Ortalama Mutlak Değer, Hareketli Averaj Filtresi, Eğri Uydurma ve Özbağlanım metotlarıyla özellik vektörleri elde edilmiştir. Elde edilen bu özellik vektörleri öbekleştirme algoritmalarına giriş olarak uygulanmıştır. Kullanılan veri seti üzerinde oldukça başarılı öbekleştirme ve sınıflandırma sonuçları elde edilmiştir.

CLASSIFICATION AND CLUSTERING OF EMG SIGNALS

SUMMARY

In this thesis, classification and clustering of electromyography (EMG) signals studied required for a prosperous arm prosthesis control. The signal is the synthesis of numerous action potentials and captured from the skin surface. In this work, EMG signals generated by biceps and triceps muscles for four different movements are examined. Each EMG signal has one single pattern and it is essential to separate and to classify these patterns properly. To this end, clustering and classifying is carried out to EMG signals regarding to four different movements captured from the arm, by using K-Means, Fuzzy C Means, Support Vector Machine, Discriminant Analysis, Probabilistic Neural Network and Feed Forward Artificial Neural Network algorithms. Prior to these algorithms, signals need to be preprocessed. There exists abundant different appliances in preprocessing. For this purpose, by using Mean Absolute Value, Moving Average Filter, Curve Fitting and Autoregressive methods, the feature vectors of the signals are acquired. These feature vectors are provided as inputs to the classification/clustering algorithms. On the used data sets, very high classification/clustering performances are achieved.

TEŞEKKÜR

Tez çalışmam boyunca bilgi ve tecrübesiyle yol gösteren danışmanım Sayın Yrd. Doç. Dr. Ahmet ALKAN'a, maddi ve manevi desteklerini hiçbir zaman esirgemeyen annem ve babama, bu çalışmamda gösterdikleri anlayıştan dolayı, sevgili eşim ve kızıma çok teşekkür ederim.

“Protez Kollar için EMG İşaretlerinin Sınıflandırılması ve Tanımlanması” adlı Yüksek Lisans Projesini destekleyen KSÜ Bilimsel Araştırma Projeleri Yönetim Birimi'ne teşekkürü bir borç bilirim.

İÇİNDEKİLER

	Sayfa No
ÖZ	i
ABSTRACT	ii
ÖZET	iii
SUMMARY	iv
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	x
SİMGELER VE KISALTMALAR DİZİNİ	xi
1. GİRİŞ.....	1
1.1. EMG İşaretleri	1
1.1.1. EMG İşaretlerinin Ölçülmesi.....	3
1.1.2. EMG'nin Temel İlkeleri	4
2. ÖNCEKİ ÇALIŞMALAR	6
3. MATERYAL VE METOT	10
3.1. Materyal	10
3.1.1. Kullanılan Veri	10
3.2. Metot.....	10
3.2.1. Önışleme Metotları	10
3.2.1.1. Ortalama Mutlak Değer	10
3.2.1.2. Özbağlanım (AR) Katsayıları	11
3.2.1.2.1. Özbağlanım Spektrum Kestirimi için Burg Yöntemi	12
3.2.1.2.2. Özbağlanım Spektrum Kestirimi için Otokorelasyon Yöntemi	13
3.2.1.2.3. Özbağlanım Spektrum Kestirimi için Kovaryans Yöntemi	14
3.2.1.2.4. Özbağlanım Spektrum Kestirimi için İ.Kovaryans Yöntemi	15
3.2.1.3. Hareketli Averaj Filtresi	15
3.2.2. Öbekleştirme Yöntemleri	15
3.2.2.1. K-Means	15
3.2.2.2. Bulanık C Ortalama	17
3.2.3. Sınıflandırma Yöntemleri	18
3.2.3.1. Destek Vektör Makineleri	18
3.2.3.1.1. Destek Vektör Makinelerinde Öğrenme.....	19
3.2.3.1.2. Destek Vektör Makine Algoritması.....	23
3.2.3.1.3. DVM'de Kullanılan Çekirdek Fonksiyonları	28
3.2.3.1.3.1. Doğrusal Fonksiyon.....	28
3.2.3.1.3.2. Polinomal Fonksiyon.....	28

3.2.3.1.3.3. Radyal Tabanlı Fonksiyon.....	29
3.2.3.1.3.4. Sigmoid Fonksiyon.....	30
3.2.3.2. Diskriminant Analizi	31
3.2.3.2.1. Çok Boyutlu Ölçekleme Analizi.....	33
3.2.3.2.2. Çok Değişkenli Normal Dağılım	33
3.2.3.2.3. Tek Değişkenli Normal Dağılım Eşitlikleri.....	34
3.2.3.2.4. Çok Değişkenli Normal Dağılım Eşitlikleri	36
3.2.3.2.5. Diskriminant Analizinin Varsayımları	37
3.2.3.2.6. Diskriminant Analizine Geometrik Yaklaşım	41
3.2.3.2.7. Lineer Diskriminant Analizi (LDA)	42
3.2.3.2.8. Lineer Diskriminant Fonksiyonunun Katsayıları	47
3.2.3.3. Diskriminant Analizi	49
3.2.3.3.1. Yapay Sinir Ağlarının Temel Özellikleri	49
3.2.3.3.2. Yapay Sinir Hücresi Modeli	50
3.2.3.3.3. Tek katmanlı-ileri beslemeli sinir ağları (FFNN).....	52
3.2.3.3.4. Çok katmanlı-ileri beslemeli sinir ağları (MLFFNN)	53
3.2.3.4. Diskriminant Analizi	54
3.2.3.4.1. Matematiksel Temel	54
3.2.3.4.2. Eğitim.....	55
3.2.3.4.3. Test Etme	55
3.2.3.4.4. Uyarılama	56
4. BULGULAR VE TARTIŞMA.....	57
4.1. Önışleme Yöntemlerinin EMG İşaretlerine Uygulanması	57
4.1.1. Ortalama Mutlak Değer (OMD) Yönteminin Kullanılması	57
4.1.2. Hareketli Averaj Filtresi Yönteminin Kullanılması	58
4.1.3. Özbaklanım Yöntemlerinin Kullanılması.....	58
4.1.4. Eğri Uydurma Yönteminin Kullanılması	59
4.2. Öbekleştirme ve Sınıflandırma Yöntemlerinin Özellik Vektörüne Kullanılması	59
4.2.1. K-Ortalama Metodunun Kullanılması	59
4.2.2. Bulanık C Ortalama Metodunun Kullanılması	59
4.2.3. DVM Sınıflandırıcı Metodunun Kullanılması.....	60
4.2.4. Diskriminant Analizi Metodunun Kullanılması	60
4.2.5. İleri Beslemeli YSA Metodunun Kullanılması	61
4.2.6. Olasılıksal Sinir Ağları Metodunun Kullanılması.....	61
5. SONUÇLAR	63
KAYNAKLAR.....	65
ÖZGEÇMİŞ.....	69

ŞEKİLLER DİZİNİ

	Sayfa No
Şekil 3.1 Modelleme hatasının eğitim veri kümesi boyutu ilişkisi	20
Şekil 3.2 Veri görevlerinden öğrenme işleminin standardı	21
Şekil 3.3 Eğiten veri takımını toplarken öğrenmenin rastgele gösterimi	22
Şekil 3.4 Öğrenen makinenin modeli	23
Şekil 3.5 Destek Vektör Makine Algoritması	23
Şekil 3.6 Sınıflandırma örneği.....	24
Şekil 3.7. Destek Vektörleri ve Sınırlar	25
Şekil 3.8. Doğrusal Olmayan Sınıflandırma	26
Şekil 3.9. Çekirdek fonksiyonları ile üst boyuta taşıma işlemi	26
Şekil 3.10. Haritalama işlemi	27
Şekil 3.11. Örnek DVM modeli	27
Şekil 3.12. İki Boyutlu Örnek Uzayında Doğrusal Fonksiyon Gösterimi.....	28
Şekil 3.13. Doğrusal ve Doğrusal Olmayan Sınıflandırma Gösterimi	29
Şekil 3.14. İki Boyutlu Örnek Uzayında Polinomial Fonksiyon Gösterimi.....	29
Şekil 3.15. RTF ile Sınıflandırılarak Farklı Boyuta Taşınması.....	30
Şekil 3.16. İki Boyutlu Örnek Uzayında Radyal Tabanlı Fonksiyon Gösterimi.....	30
Şekil 3.17. Sigmoid Fonksiyon	31
Şekil 3.18. Hatalı Sınıflandırma Örneği	31
Şekil 3.19.(a),(b) Ortalaması ve varyansı olan bir normal yoğunluk ve eğri altındaki alanlar	35
Şekil 3.20. Ayırt edici değişkenler ve gruplar arasındaki ilişkiler	39
Şekil 3.21. Diskriminant analizine geometrik yaklaşım.....	41
Şekil 3.22. Yapay Sinir Ağının Fiziksel Yapısı	50
Şekil 3.23. Temel yapay sinir hücre yapısı	51

Şekil 3.24. Aktivasyon fonksiyonları; (a) Log-sigmoid aktivasyon fonksiyonu, (b) Tan-sigmoid aktivasyon fonksiyonu, (c) Doğrusal aktivasyon fonksiyonu	51
Şekil 3.25. Çok katmanlı ağ yapısı.....	52
Şekil 3.26. Tek katmanlı yapay sinir ağı	53
Şekil 3.27. Çok katmanlı yapay sinir ağı.....	54
Şekil 3.28. Olasılıksal Sinir Ağı Yapısı	55
Şekil 4.1. Dört Ayrı Hareketten Alınmış İşlenmemiş EMG Verisi (a) Dirsek Açma (b) Dirsek Kapama (c) Ön Kolu İçe Döndürme (d) Ön Kolu Dışa Döndürme.....	57
Şekil 4.2. Ayrı Hareketten Alınmış, Pencereleme ile Elde Edilen Ortalama Mutlak Değerler. (a) Dirsek Açma (b) Dirsek Kapama (c) Ön Kolu İçe Döndürme (d) Ön Kolu Dışa Döndürme.....	58
Şekil 4.3. Öbekleştirme İşleminin Başarısını Gösteren Siluet Değerleri	59

ÇİZELGELER DİZİNİ

	Sayfa No
Çizelge 4.1. Bulanık C Ortalama için başarı oranları.....	60
Çizelge 4.2. AR-DVM ikilisi için sınıflandırma başarıları	60
Çizelge 4.3. Diskriminant analizi için başarı yüzdeleri.....	61
Çizelge 4.4. İleri Beslemeli YSA için başarı oranları	61
Çizelge 4.5. Olasılıksal Sinir Ağları için başarı oranları.....	62
Çizelge 4.6. Önişleme yöntemlerine göre sınıflandırma yöntemlerinin başarıları.....	63
Çizelge 4.7.Önişleme yöntemlerine göre sınıflandırma yöntemlerinin süreleri.....	63

SİMGELER VE KISALTMALAR DİZİNİ

EMG	: Elektromiyogram
OMD	: Ortalama Mutlak Değer
HAF	: Hareketli Averaj Filtre
AR	: Özbağlanım
DVM	: Destek Vektör Makinesi
LDA	: Lineer Diskriminant Analizi
YSA	: Yapay Sinir Ağı
PNN	: Olasılıksal Sinir Ağı
BCO	: Bulanık C Ortalama
MÜAP	: Motor ünite aksiyon potansiyeli
ISEK	: The International Society of Electromyography and Kinesiology
SENIAM	: Surface EMG for Noninvasive Assesment of Muscles
DC	: Doğru Akım
AC	: Alternatif Akım
A/D	: Analog/Dijital
FEBANN	: İleri beslemeli hata geri yayımlı yapay sinir ağları
SOM	: Self Organizing Map
CANFM	: Cascaded Architecture of Neural Networks with Feature Map
MLP	: Çok katmanlı perseptron
ABA	: Ana Bileşenler Analizi
BBA	: Bağımsız Bileşenler Analizi
YRM	: Yapısal risk minimizasyonu
FFNN	: Tek katmanlı-ileri beslemeli sinir ağları
MLFFNN	: Çok katmanlı-ileri beslemeli sinir ağları

1. GİRİŞ

Teknolojinin gelişimine paralel olarak elde edilen veri gün geçtikçe artmaktadır. Elde edilen verinin içerdiği bilgi de doğru orantılı bir şekilde artmaktadır. Bu verilerin kısa zamanda ve yüksek doğrulukta yorumlanması da önem kazanmaktadır. Bu büyük ve kısmen karmaşık verinin anlamlı bir bilgiye dönüştürülmesi istatistiksel işaret işlemenin konusudur. İşaret işleme, verinin anlaşılır bir şekle dönüştürülmesi için çeşitli yöntemlerle veriyi işlemeye çalışır. Bu yöntemler, işaret işleme algoritmalarının sürekli geliştirilmesini sağlamıştır. Bu algoritmalar, bilgisayarlar tarafından verilerin hızlı bir şekilde işlenerek yorumlanması için kullanılır.

Bu çalışmada, biyoelektriksel işaretlerden olan EMG'nin sınıflandırılması ve bu sınıflandırmada kullanılan yöntemlerin karşılaştırılması yapılmıştır.

1.1.EMG İşaretleri

Elektromiyogram (EMG), kasın kasılması sonucu ortaya çıkan biyopotansiyel işaretlerdir. Elektromiyogram işaretlerin kaynağı vücutta meydana gelen çeşitli elektrokimyasal olaylardır. İstemli kas hareketleri, beyinde oluşan aksiyon potansiyellerinin sinirler yoluyla kasa iletilmesi sonucu ortaya çıkar. İskelet kaslarının fonksiyonel olarak temel birimi, motor ünitelerdir. Gevşek demetlerde motor ünitesinin bileşenleri boyunca uzanır. Çeşitli motor ünitelerinin lifleri iç içe durumda bulunmaktadır.

EMG işaretleri günümüzde kas-sinir hastalıkları teşhisi gibi klinik uygulamalarda, uzuv kesilmelerinde kesik yere takılan protez uzuvların miyoelektriksel kontrollerinde kaynak işaret olarak kullanılmaktadır.

Kelime anlamı itibariyle, elektriksel aktivite ile ilgili olarak “electro”, Yunanca “muscle” kökünden gelen “myo” ve kayıt miktarı anlamına gelen “gram” terimlerinden oluşan Elektromiyogramın tarihsel gelişimine bakıldığında 1666 yılında İtalyan hekim Francesco Redi'nin kaslarda elektrik üretimini ilk olarak fark eden bilim adamı olduğu kayıtlarda yer almaktadır. Galvani 1791'de kurbağının gastrocnemius kası üzerinde çalışarak kas kasılmasıyla elektrik üretimi arasında bir ilişki olduğunu gözlemlemiştir. Alman bilim adamı Alexander von Humboldt(1769- 1859) ilk elektrotları tasarladı ve birçok deneyde uyarıcı olarak denedi. Johannes S.C. Sweigger 1820'de Oersted manyetizması temelli ilk pratik galvanometreyi yaptı. 1900'lü yıllara kadar teknolojinin

gelişimine paralel olarak bu alanda çalışmalar yapıldı . H.Piper 1912 yılında Almanya da tel galvanometre ile çalışma yapan EMG araştırmacılarından. 1924 yılında Gasser ve Erlanger benzer çalışmaları osiloskop kullanarak yapmışlardır. 4 yıl sonra Proebster bu işaretlerin denervated kaslar tarafından üretildiğini gözlemlemiş ve klinik EMG'nin alanını açmıştır. 1929 yılında Adrian ve Bronk'un geliştirdiği ortak merkezli iğne elektrotu hala EMG çalışmalarında geniş bir kullanım alanı olan güçlü bir araçtır. Motor ünite aksiyon potansiyeli nicel analiz ve metotlarının (MÜAP) geliştiricileri olarak anılan Kugelberg, Petersen, Buchtal, Guld, Gydikov, Kosarov, Pinelli, Rosenfalck ve Stalberg vakum tüpü yükselticileri ve daha sonra katı hal devrelerini on yıllarca kullandılar. Devrin birçok çalışması arasında Denny-Brown'un 1949 yılındaki "EMG işaretlerinin yorumu" çalışması sözü edilen çalışmalardandır. Uchizono 1953 yılında kara kurbağasının sartorius kasındaki işaretlerin yayılımını tanımlamıştır. Willison 1964 yılında EMG işaretlerinin genlik analizini yapmıştır. Şu an 5. baskısı yayında olan ve kilometre taşı sayılan J.V. Basmajian tarafından yazılan "Muscles alive " adlı kitabın ilk baskısı 1962 yılında yayınlanmıştır. 1979 yılında EMG işaretlerinin fizyolojisi ve matematiğini birleştiren De Luca tarafından yayımlanan makale bu konuda bir ilk olup EMG içerik bilgisi ve çıkarımı ile ilgili temel bir yaklaşım oluşturmuştur. EMG çalışmalarında bilgisayarların kullanımı modellerin gelişimi ve simülasyon yöntemlerinin kullanımını kolaylaştırmıştır. 1970'ler ve 1980'lerde birçok grup ve araştırmacı bu konuyla ilgilenmiş, yayınlar yayınlamış ve bu alanda oldukça gelişme kaydedilmiştir. Dimitrova ve Lindstrom modelleme alanının öncülerindendir. Bu modeller EMG işaretinin biyofiziğinin anlaşılmasına oldukça katkı sağlamış ve böylece işaretin içerdiği bilgilerin çıkarımını kolaylaştırmıştır. Ayrıca bu modeller iyi bir eğitim aracı olmakla birlikte mevcut uygulamalar ile yeni uygulamaların geliştirilmesiyle uğraşan uzmanlar için temel çalışma kaynağıdır. EMG işaretlerinin ilk ve doğal alanlarından biride protez kontrolüdür. Miyoelektrik kontrol olarak da bilinen ve ilk olarak 1940'larda açılan bu alan 1960, 1970 ve 1980'lerde hızla gelişmiştir. Potansiyel ile eşzamanlı çalışan çok fonksiyonlu EMG örüntüsü temelli protezler güncel ve gelişen bir alandır. J.V. Basmajian, S. Carlsöö, B. Johnson, M. MacConaill, J. Pauly ve L. Scheving 1965 yılında yaptıkları toplantıda uluslararası Elektromiyografi ve Kas bilimi topluluğunu (The International Society of Electromyography and Kinesiology) kurmayı kararlaştırdılar ve 1966 yılında ISEK'i resmileştirdiler. Bu topluluk EMG ilgili toplantılar, konferanslar ve sempozyumlar organize etmektedir. 1988 yılında EMG araştırma sonuçlarının bir dergide

yayınlanması önerisi ISEK konseyi tarafından kabul edilmiştir. Electromyography and Kinesiology dergisinin ilk sayısı 1991 yılında yayınlanmıştır. 1995 yılında bir grup araştırmacının önderliğinde ve Avrupa Birliğinin katkılarıyla Kasların Noninvasive Değerlendirilmeleri için Yüzeyel EMG (Surface EMG for Noninvasive Assessment of Muscles) projesi hazırlanmış ve 1996 yılında finanse edilmiştir. SENIAM'ın amacı; bu konularda çalışan laboratuvarların kabul edilebilir bir seviyeye getirilmesidir. Bilgisayar girdili aygıtların kullanımı ile sinir-kas bozulmalarını önleme(Prevention of Neuromuscular Disorders in the Use of Computer Input Devices) isimli çalışma ise Avrupa Birliği tarafından finanse edilen ikinci anlaşmadır (Yazıcı, 2008).

1.1.1.EMG İşaretinin Ölçülmesi

EMG işaretleri yüzey elektrotları ve iğne elektrotlar olmak üzere iki tip elektrot aracılığıyla ölçülmektedir. Bunlardan yüzey elektrotları ile yapılan ölçümlerde geniş bir alandaki elektriksel aktivite ile ilgili bilgi edinilmektedir. Bir motor ünitesinin veya üniteler grubunun incelenmesinde, elektrotların bilgi topladıkları alttaki alan çok geniş olabilir. Ayrıca yüzeydeki kasların faaliyetinin alttaki kaslardan gelen bilgiyi maskeleymesi sebebiyle yüzey elektrotlarını yalnız yüzeydeki kasların incelenmesinde kullanmak gerekmektedir. Bir kas grubunun faaliyetinin diğer bir kas grubu faaliyetini maskeleymesi olayı, çok miktarda motor birim aksiyon potansiyellerinin karışması ile olur ve bu olay “girişim olayı” olarak bilinir. Kasılma şiddeti sonucu aktif motor birim sayısı artar. Aynı anda birçok kas lifinin etkinleşmesiyle, her bir kas lifinin ürettiği işaret bir diğerini yok edebilir ya da kuvvetlendirebilir (Bozkurt, 2007).

Özel olarak bir motor ünitesinin veya üniteler grubunun incelenmesinde, elektrotların bilgi topladıkları alttaki alan çok geniş olabilir. Ayrıca, yüzeydeki kasların faaliyeti alttan gelen bilgiyi maskelediğinden yüzey elektrotlar, sadece yüzeydeki kasların incelenmesinde kullanılabilir (Çevikcan, 2007).

Yüzey elektrotlar, bağlanacak yüzey iletkenliği önleyecek kir, yağ tabakası vs. gibi maddelerden temizlemek maksadıyla asetonlu pamukla silindikten sonra bağlanır. Yüzey temizleme işleminden sonra elektrot çiftine iletkenliği artırmak maksadıyla jel sürülür ve ölçüm yapılacak bölgeye yerleştirilir. Elektrotlardan gelen EMG işaretlerinin genliği kuvvetlendirici tarafından yükseltilir. Daha sonra yükseltilmiş bu işaret kesim frekansı 10 Hz olan bir yüksek geçiren filtreden geçirilerek istenmeyen DC bileşenlerden arındırılır. Ayrıca şebekeden kaynaklanan 50 Hz'lik gürültüyü engellemek maksadıyla bant genişliği

2 Hz olan bir çentik filtre kullanılır. İşaretin AC değerinin düzgün olarak elde edilebilmesi için ortalama değerinin alınması gerekir. Bunun için önce işaret tam dalga doğrultucudan ve sonra alçak geçiren filtrelerden geçirilir. Bu aşamada elde edilen EMG işareti girişteki ham EMG işaretinin yükseltirmiş ve ortalama değeri alınmış şeklindedir. Bu aşamadan sonra elde edilen EMG işareti A/D dönüştürücüden geçirilerek bilgisayar ortamında kayıt edilebilir (Bozkurt, 2007).

Tek bir motor ünitesinden uyarılma sonucu, iğne elektrotlarla elde edilen hücre dışı potansiyel değişimleri 3–15 ms arasında sürer ve motor ünitesinin büyüklüğüne bağlı olarak genliği 20–2000 mV'dur. Deşarj frekansı genellikle saniyede 6–30 darbe arasındadır. EMG kayıtlamada yüzey elektrotlar kullanılmakla birlikte kas içine doğrudan girilmesi gereken uygulamalarda iğne elektrotlar kullanılır. İşaretlerin kuvvetlendirilmesinde fark kuvvetlendiriciler kullanılır. EMG işaretinin bilgisi kaslarda harcanan güce, elektrotların yerleşimi gibi faktörlere bağlıdır. Tek fibere batırılan iğne elektrot ile sadece o fibere ait potansiyel ve gürültü ölçülür iken, yüzey elektrotlarla yapılan ölçümlerde elektrotların yerleştirildiği bölgedeki örtüşmüş kasların gürültüsü ve potansiyellerinin ortalaması ölçülecektir (Yazıcı, 2008).

1.1.2.EMG'nin Temel İlkeleri

Elektromiyogramda meydana gelen anormal değişimlerin tanımlanması ve açıklanması, kas aksiyon potansiyellerinin karakteristik özelliklerinin, şeklinin, genliğinin, süresinin ve frekansının dikkatli incelenmesine bağlıdır.

Elektromiyografi aşağıdaki konularda büyük kolaylık sağlar:

- Denervation 'in bulunması
- Motor sinir liflerinin durumlarıyla ilgili gerekli bilginin bulunması (bunlar sinir iletim zamanı ve hızıdır.)

- Sinir hasarlarının yerlerinin belirlenmesi
- Reinnervation'da duyarlı bir fibrinin sağlanması
- Motor düzenleme hareketini izleme

Aşağıdaki bilgiler elektromiyografinin teşhise yönelik kullanımıyla ilgilidir:

- Elektromiyografinin amacı klinik teşhisi desteklemektir, teşhis koymak değildir
- Metodun kullanımı kolaydır ve hastayı rahatsız etmez.
- Uyarım elektromiyografisi, sinirlerdeki motor iletim zamanlarının ve iletim hızlarının belirlenmesinde kolaylık sağlar.

- İstemli hareket veya sinir uyarımlarına cevap olarak kaslardan alınan motor aksiyon potansiyellerinin dağılımı ve yapısı, sinir iletiminin normal, kısmi veya tamamen kesilmiş veya zayıflamış olup olmadığını gösterir.

- Sinir iletim hızındaki düşme, bağlantı noktasındaki gecikmedeki artış ve motor ünitesi potansiyellerinin zaman, genlik ve Sayıca azalması iletimi zayıflatan bir bölgenin olduğunu gösterir.

- Etkilenen kas veya kaslardan birkaç motor ünitesi potansiyelinin bulunması, en az birkaç lifin hasar gördüğü bir bölgeyi gösterir.

- Bir kas denerve edildiği zaman çırpırır. Bu kasın düzgün, hızlı, eşzamanlı olmayan kasılmaları formundadır ve kas yüzeyine zayıf, sürekli, dalgalı bir hareket verir. Bu hareket deri üzerinden görülemez.

- İstemli bir harekete ve sinir uyarımlarına rağmen durgunluğun devam etmesi, daha sonra bunun kendiliğinden meydana gelen çırpımın aksiyon potansiyelleri tarafından takip edilmesi iletimin tamamen kesintiye uğradığını gösterir.

- Kendiliğinden meydana gelen çırpınımalar, axonal (sinir hücresi) devamlılığın olmadığı sinir bölgeleri tarafından denerve edilen kasların karakteristik bir özelliğidir. Bu ikinci, üçüncü, dördüncü veya beşinci dereceden bir hasar olduğunda meydana gelir. Bu kategoriler arasında elektromiyografide bir fark gözlenmez.

- Axon sürekliliğinin korunduğu fakat iletimin bloke edildiği birinci dereceden bir hasarda, etkilenen kaslar çırpınmaz (Altınbaş, 2007).

2. ÖNCEKİ ÇALIŞMALAR

Mohamed (1989), “EMG sınıflandırma için Walsh fonksiyonunun bir uygulaması” üzerine bir çalışma yaparak, makale yazmıştır. Makalede, Walsh Dönüşümü EMG sinyal boyutunu azaltmak için kullanılmıştır. Walsh dönüşümünün çok boyutlu bir datayı nasıl tek boyuta düşürdüğü anlatılmış ayrıca EMG işaretinin sınıflandırmasında Fourier ve Walsh fonksiyonları karşılaştırılmıştır.

Yang ve ark.(1996), “EMG sınıflandırma uygulaması ile örüntü tanıma için yeni bir bulanık yaklaşım” üzerine bir çalışma yaparak makale yazmışlardır. Makalede, hata yayılım algoritması ile iyi tanımlanmış bulanık kümeler elde edilmiş ve bu kümeler EMG işaretlerinin sınıflandırması için kullanılmıştır. Ayrıca bu sınıflandırma Yapay Sinir Ağlarıyla yapılan sınıflandırma ile kıyaslanmıştır.

Kwon ve ark. (1998), “Sürekli EMG sınıflandırma amacı için işaret hibrid HMM-GA-MLP sınıflandırıcısı” üzerine bir çalışma yaparak, makale yazmışlardır. Makalede, Genetik algoritma (GA) ile çok katmanlı perceptron (MLP) ve gizli Markov metodunun (HMM's) hibrid sınıflandırıcısı kullanılarak EMG işaretlerinin sınıflandırılması konusu ele alınmıştır. Sınıflandırma için 4 ayırıcı strateji (HMM-MLP, HMM-GA-MLP, HMM-CPN ve HMM-GACPN) uygulanarak denenmiştir.

Cai ve ark. (1999), “Dalgacık Dönüşümü temelli bir EMG sınıflandırma metodu” üzerine bir çalışma yaparak, makale yazmışlardır. Makalede, EMG işaretlerinin Dalgacık Dönüşümü ile özellik çıkarımı yapılmış ve Yapay Sinir Ağları kullanılarak işaret sınıflandırılmıştır. Ayrıca kullanılan Yapay Sinir Ağlarının yapısı ayrıntılı olarak anlatılmıştır. Ön işlemede uygulanan Dalgacık Dönüşümü sayesinde sınıflandırmada %90'lık bir başarı elde edilmiştir.

Chan ve ark. (2000), “Protez kontrolü için bulanık EMG sınıflandırması” üzerine bir çalışma yaparak, makale yazmışlardır. Makalede, protez kontrolü için EMG sinyallerinin sınıflandırılması amaçlanmıştır. Sınıflandırmanın kontrolü konusunun önemine vurgu yapılmıştır. Bahsettiği sistemde; EMG işaretleri, kabul edilebilir bir hız ve gerçekçi bulanık sistem yapısı elde etmek için çalıştırma safhasının başında denetleme olmadan Basic Iso-Data algoritmasını kullanarak kümelenir ve kümeleme sonuçları bulanık sistem parametrelerini başlatmak için kullanılır. Daha sonra, sistemdeki bulanık kurallar geri yayılım algoritması ile çalıştırılır. Daha sonra, sistemdeki bulanık kurallar geri yayılım algoritması ile çalıştırılır. Bulanık yaklaşım Yapay Sinir Ağları ile dört örnekte

karşılaştırılır ve çok benzer sınıflandırma sonuçları elde edilir. Öncekilere göre en az üç noktada üstündür: yüksek doğrulama oranı; aşırı çalıştırmaya duyarsızlık ve daha tutarlı çıktılar, böylece daha yüksek güvenilirlik sağlar. Bulanık yaklaşımın ANN yaklaşımına göre potansiyel avantajları da tartışılmıştır.

Englehart (2001), “Çok fonksiyonlu miyoelektrik kontrolü için dalga temelli sürekli sınıflandırma şeması” üzerine bir çalışma yaparak, makale yazmışlardır. Bu çalışmada üst kolların kontrolünün miyoelektrik sinyaller kullanarak iyileştirilmesi açıklanmaktadır. Bahsedilen miyoelektrik kontrol şemasının başarısı problemin doğru tanımlanmasına ve sınıflandırmanın hassasiyetine bağlı olduğu bildirilmiştir. Daha önceki çalışmalardan daha fazla hassasiyet gösteren yeni bir yaklaşım açıklanmıştır. Bu yaklaşımın başarısının temeli, ana bileşen analizi ile boyutu azaltılmış bir dalgacık temelli özellikler dizisinin kullanılmasıdır. Ayrıca, dört kanallı miyoelektrik verinin; tek veya iki kanala kıyasla, sınıflandırma hassasiyetini önemli bir şekilde artırdığını göstermektedir. Verinin devam eden akışı üzerinde sınıf kararları üreten güçlü bir online sınıflandırıcı oluşturulmuştur. Bu metodun gelişiminin ilk aşamalarında olmasına rağmen daha sağlıklı ve verimli sonuçlar ürettiğinden bahsedilmiştir.

Huang ve ark. (2003), “Sinir Ağları ve SOM'un kademelendirilmiş mimarisini kullanarak kavrama durumları için EMG sınıflandırması” üzerine bir çalışma yaparak, makale yazmışlardır. Makalede, sekiz ayrı ön kol kavrama hareketinin sınıflandırılmasında yüksek sınıflandırma oranını ve kısa öğrenim zamanı için sınıflandırıcı geliştirilmiştir. Bu amaç için Özellik haritalı sinir ağının basamaklı mimarisi (CANFM - Cascaded Architecture of Neural Networks with Feature Map) ele alınmış ve bu mimarinin iki ögesi olan, danışmansız öğrenmeye sahip SOM ve danışmanlı öğrenmeye sahip 'çok katmanlı ileribeslemeli sinir ağı' ayrıntılı olarak açıklanmıştır. Bu mimarinin k-en yakın komşu, bulanık k-en yakın komşu ve geriyayılımlı sinir ağı'ndan daha iyi bir sınıflandırma yaptığından bahsetmektedir.

Hu ve ark.(2005), “RWPE kullanılarak EMG işaretlerinin sınıflandırılması” üzerine bir çalışma yaparak, makale yazmışlardır. Makalede, EMG işaretinden özellik çıkarımı için yeni ve basit bir metot olan RWPE, dalgacık paket dönüşümüne istinaden önerilmiştir. Burada bahsedilen RWPE'nin en önemli işlevi işarettaki gürültüyü bastırırken sınıflandırma için ayırt edici özelliklerini daha belirgin hale getirmesidir.

Kocyigit ve Korurek (2005), “EMG işaretlerini dalgacık dönüşümü ve bulanık mantık sınıflayıcı kullanarak sınıflama” üzerine bir çalışma yaparak, makale yazmışlardır. Bu çalışmada öznitelik çıkartma yöntemi olarak zaman-frekans domeni analiz yöntemlerini kullanarak protez koluna ait dört farklı hareket için EMG işaretlerini daha iyi sınıflandırılması hedef olarak belirlenmiştir. Bunun için boyut azaltma ve bulanık sınıflama yöntemleri de incelenmiştir. Sınıflama problemi öznitelik çıkartma, boyut azaltma ve örüntü sınıflama aşamalarına ayrılmıştır. Dalgacık dönüşümü öznitelik çıkartma yöntemi olarak büyük üstünlük sağladığı bildirilmiştir. Özniteliklerin çıkartma aşamasında yüksek boyuta sahip olmalarından dolayı sınıflama başarısı, Ana Bileşenler Analizi (ABA) ve Bağımsız Bileşenler Analizi (BBA) gibi uygun boyut azaltma yöntemleriyle gerçekleştirilmiştir.

Subasi ve ark. (2006), “Dalgacık sinir ağı kullanarak EMG işaretlerinin sınıflandırılması” üzerine bir çalışma yaparak, makale yazmışlardır. Makalede, EMG işaretinin sınıflandırılması için ileri beslemeli hata geri yayımlı yapay sinir ağları (FEBANN) ve dalgacık sinir ağları (WNN) temelli sınıflandırıcılar geliştirilmiş ve karşılaştırılmıştır. Nörolojik hastalıktan çeken 13 denek, miyopatiden çeken 7 denek ve sağlıklı 7 denekten elde edilen 1200 MUP'lar analiz edilmiş, WNN tekniğinden en başarılı %90.7 FEBANN tekniğinden en başarılı %88 sonuç elde edilmiştir ve WNN temelli sınıflandırıcıların FEBANN temelli sınıflandırıcılara karşı daha iyi sınıflandırma yaptığı gösterilmiştir.

Ahmad ve Chappell (2007), “Değişen yaklaşık entropi kullanılarak yüzey EMG sınıflandırması” üzerine bir çalışma yaparak, makale yazmışlardır. Bu çalışmada, 20 denek bilek hareketleri yaparken izometrik kasılma ve karşı kasılma EMG sinyalleri yüzey elektrotlarla kaydedilmiş ve bu datalar sınıflandırılmıştır.

Oskoei ve Hu (2007), “Miyoelektrik kontrol sistemleri” üzerine bir çalışma yaparak, makale yazmışlardır. Bu çalışmada örüntü tanıma temelli ve örüntü tanıma temelli olmayan miyoelektrik kontrol üzerinde son zamanlarda yapılan araştırma ve geliştirmeleri gözden geçirerek tiplerine, yapılarına ve mevcut uygulamalara bağlı en son başarıları sunmaktadır.

Khezri ve ark. (2007), “Çok fonksiyonlu el protezi kontrolü için nöro-bulanık yüzey EMG örüntü tanıma” üzerine bir çalışma yaparak, makale yazmışlardır. Bu çalışmada el protezinin hareketlerinin modelini tanımlamak için yüzeysel EMG sinyallerinden

yararlanılmıştır. Protez bir elin kontrolü için de hareket komutlarını belirlemeyi amaçlayan uyarlanabilir bir bulanık mantık çıkarım sistemi (ANFIS) kullanmak önerilmiştir. Sınıflandırmada yararlanılan miyoelektrik sinyaller, altı el hareketinden oluşmaktadır. Bu çalışmada tasarlanan ve kullanılan bulanık-mantık sistemleri, bağımsız olarak ve hem zaman hem de zaman-frekans özellikleri için karma bir biçimde test edilmiştir. Bu Birleşik yaklaşım için sistemin ortalama hassasiyetinin %96 olduğu bildirilmiştir.

Lucas ve ark. (2008), “SVM ve işaret temelli dalgacık optimizasyonu kullanarak çok kanallı EMG sınıflandırması” üzerine bir çalışma yaparak, makale yazmışlardır. Bu çalışma miyoelektrik protezleri kontrol amacı ile çok kanallı EMG işaretlerinin danışmanlı sınıflandırılması için bir yöntem öneriyor. Çözüm kümesi, ana dalgacığın serbest parametrelendirilmesi kullanılarak her bir kaydedilen EMG işaretinin ayrık dalgacık dönüşümünün üzerine temellendirilmiştir. Çok kanallı çözüm kümesinde SVM yaklaşımıyla sınıflandırma gerçekleşir. Kolun üzerindeki 8 bölgeden kaydedilen EMG ile 6 el hareketinin sınıflandırılmasında bu metot uygulanmıştır.

3.MATERYAL VE METOT

3.1.Materyal

3.1.1.Kullanılan Veri

Bu çalışmada, kola ait dirsek açma, dirsek kapama, ön kolu içe döndürme ve ön kolu dışa döndürme hareketlerinden oluşan dört farklı sınıfa ait 100'er adet toplam 400 EMG işareti kullanılmıştır. Bu dört sınıfa ait EMG işaretleri, kolun biceps ve triceps kaslarından iki kanallı olarak elde edilmiş ve her kanaldan alınmış işaret 1000 Hz'de örneklenmiş, her kanaldan 256 örnek olmak üzere toplam 512 örnekten oluşmuştur. Şekil.1'de bu dört tür işareten birer örnek görülmektedir. (Englehart, 2001; Günay ve Alkan, 2009; Günay ve Alkan, 2010)

EMG işaretlerinin analizinde öznitelik çıkartma işlemi oldukça büyük bir öneme sahiptir. Bu amaçla literatürde çok değişik özellik çıkarım yöntemleri kullanılmaktadır. Kullanılan her özellik çıkarım yönteminin başarımları da değişik olmaktadır. Bu çalışmada özellik çıkarımı amacıyla işaret, 32 örneklik pencerelere ayrılıp, elde edilen 16 adet penceredeki örneklerin önce mutlak değerleri sonra da her pencerenin ortalaması hesaplanmıştır. Bu şekilde her işaret bu işlem sonunda 16 adet özellik vektörüyle ifade edilmiştir. Elde edilen özellikler kullanılarak dört tür işareten oluşan EMG verisi öbekleştirme işlemine tabi tutulmuştur (Günay ve Alkan, 2009; Günay ve Alkan, 2010).

3.2.Metot

3.2.1.Önişleme Metotları

3.2.1.1.Ortalama Mutlak Değer

Ortalama Mutlak Değer (OMD) yönteminde önişlem, iki şekilde gerçekleştirilebilir. Birincisi, önce veri seti belirli aralıklarla pencerelenir. Daha sonra her pencerenin sırayla mutlak değeri ve ortalaması alınarak bir özellik vektörü oluşturulur. Diğer yöntemde öncelikle veri setinin tamamının mutlak değeri alınır. Daha sonra veri seti belirli aralıklarla pencerelenir. Pencereleme işleminden sonra her pencerenin ortalaması alınarak bir özellik vektörü elde edilir. Her EMG işareti için elde edilen bu özellik vektörleri, daha sonra sınıflandırma algoritmalarının girişine uygulanır. (Özer, 2010)

3.2.1.2.Özbağlanım (AR) Katsayıları

Özbağlanım modeli, $x(n)$ veri dizisinin bir rasyonel sistem tarafından nitelendirilen doğrusal bir sistemin çıkışı olarak modellenmesi ile temsil edilebilir. Güç spektral yoğunluğunun (GSY) parametrik yöntemlerle kestiriminde, veri dizisi ve kestirimi yapılan yönteme ait parametreler kullanılır. Özbağlanım metodunda işarete ait belli bir andaki genliği elde etmek için, o ana kadar örneklenmiş bölümlerin genlikleri farklı oranlarda toplanır ve bu toplama bir tahmin hatası eklenir. AR model parametrelerinin çözümünde doğrusal denklemler kullanılır. Bu yüzden AR yöntemi daha yaygın kullanılır. Özbağlanım modeli, birim karşılıklı beyaz gürültü ile sürülen nedensel, tüm-kutuplu ayrık filtre çıkışı olarak gösterilir. “p” inci dereceden AR yöntemine ait güç spektrumu,

$$P_x(e^{j\omega}) = \frac{|b(0)|^2}{\left|1 + \sum_{k=1}^p a_p(k)e^{-jk\omega}\right|^2} \quad (3.1)$$

ifadesiyle verilir. Eğer $b(0)$ ve $a_p(k)$ verilerden tahmin edilebilirse (kestirilebilirse) güç spektrumunun kestirimi şu formda da yazılabilir:

$$\hat{P}_{AR}(e^{j\omega}) = \frac{|\hat{b}(0)|^2}{\left|1 + \sum_{k=1}^p \hat{a}_p(k)e^{-jk\omega}\right|^2} \quad (3.2)$$

Burada $a(k)$ AR katsayılarını, p model derecesini ve $b(0)$ ise varyansı ifade etmektedir.

Açıkça görülebilir ki, $\hat{P}_{AR}(e^{j\omega})$ ifadesinin kesinliği, model parametrelerinin kestirimindeki kesinliğe ve daha önemlisi AR modelinin üretilen veri ile birbirini tutup tutmadığına bağlıdır. AR spektrum kestirimi, işlem için tüm-kutuplu model kurulmasını gerektirdiğinden, tüm kutup parametrelerinin kestirimi için teknikler vardır. Genlik oranlarını belirleyen AR katsayılarını farklı yöntemlerle hesaplamak mümkündür. Bunlara örnek olarak Levinson - Durbin ve Burg algoritmaları verilebilir. Burg yönteminde AR katsayılarını bulmak için işareten alınan örneklerin ileri - geri hataları kullanılır ve modelin derecesi AR katsayılarının sayısı ile belirlenir. Levinson - Durbin yönteminde AR

katsayılarının bulunması için Otokorolasyon denklemlerinin çözülmesi gerekmektedir. Bunun için özilişki fonksiyonlarından faydalanılır (Bozkurt, 2007).

3.2.1.2.1.Özbağlanım Spektrum Kestirimi için Burg Yöntemi

Burg yöntemi 1975 yılında J.P.Burg tarafından geliştirilmiştir. Burg algoritması, AR model parametreleri kümesini, ileri – geri yöndeki kestirim hatalarının kareleri toplamının minimizasyonu ile bulur. Burg yöntemi diğer AR spektrum kestirim metodları gibi özilişki fonksiyonu hesaplamaz. Bunun yerine direkt yansıma katsayısı tahmini yapılır. Burg algoritmasında “p”inci dereceden model için ileri ve geri kestirim hataları şöyle tanımlanır:

$$\hat{e}_{f,p}(n) = x(n) + \sum_{t=1}^p \hat{a}_{p,t} x(n-t) \quad n = p+1, \dots, N \quad (3.3)$$

$$\hat{e}_{b,p}(n) = x(n-p) + \sum_{t=1}^p \hat{a}_{p,t}^* x(n-p+t) \quad n = p+1, \dots, N \quad (3.4)$$

Yansıma katsayısı $(\hat{k}_p)$ ile ilişkili AR katsayıları (3.5) nolu ifadede verilmiştir.

$$\hat{a}_{p,t} = \begin{cases} \hat{a}_{p-1,t} + \hat{k}_p \hat{a}_{p-1,p-t}^* & t = 1, \dots, p-1 \\ \hat{k}_p & t = p \end{cases} \quad (3.5)$$

Yansıma katsayısı kestirimi için ise

$$\hat{k}_p = \frac{-2 \sum_{n=p+1}^N \hat{e}_{f,p-1}(n) \hat{e}_{b,p-1}^*(n-1)}{\sum_{n=p+1}^N [|\hat{e}_{f,p-1}(n)|^2 + |\hat{e}_{b,p-1}^*(n-1)|^2]} \quad (3.6)$$

ifadesi kullanılır. Daha önce belirtildiği gibi, Burg yönteminde AR katsayılarının bulunmasında kullanılan ileri ve geri yöndeki kestirim hataları ise şu ifadelerle bulunur:

$$\hat{e}_{f,p}(n) = \hat{e}_{f,p-1}(n) + \hat{k}_p \hat{e}_{b,p-1}(n-1). \quad (3.7)$$

$$\hat{e}_{b,p}(n) = \hat{e}_{b,p-1}(n-1) + \hat{k}_p^* \hat{e}_{f,p-1}(n). \quad (3.8)$$

AR parametrelerinin kestirimi yapıldıktan sonra güç spektral yoğunluğunun (GSY) hesaplanması için ise 3.9 nolu ifade kullanılır:

$$\hat{P}_{BURG}(f) = \frac{\hat{e}_p}{\left| 1 + \sum_{k=1}^p \hat{a}_p(k) e^{-j2\pi f k} \right|^2} \quad (3.9)$$

$\hat{e}_p$ ifadesi $\hat{e}_{f,p} + \hat{e}_{b,p}$ toplamı olarak gösterilir ve toplam en küçük karesel hatadır. Parametre kestiriminde Burg yöntemi verimli ve kararlı bir AR yöntemidir (Bozkurt, 2007).

3.2.1.2.2.Özbağlanım Spektrum Kestirimi için Otokorelasyon (Yule-Walker) Yöntemi

Otokorelasyon yöntemi bazı kaynaklarda Yule-Walker yöntemi olarak da geçmektedir. AR işlemleri için kullanılan Yule-Walker denklemlerinin, otokorelasyon denklemleri ile eşdeğer olması sebebiyle her iki ismin de kullanılması uygundur.

Bu yöntemde AR katsayıları $a_p(k)$, normal otokorelasyon denklemleri çözülerek bulunur:

$$\begin{bmatrix} r_x(0) & r_x^*(1) & r_x^*(2) & \cdots & r_x^*(p) \\ r_x(1) & r_x(0) & r_x^*(1) & \cdots & r_x^*(p-1) \\ r_x(2) & r_x(1) & r_x(0) & \cdots & r_x^*(p-2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_x(p) & r_x(p-1) & r_x(p-2) & \cdots & r_x(0) \end{bmatrix} \begin{bmatrix} 1 \\ a_p(1) \\ a_p(2) \\ \vdots \\ a_p(p) \end{bmatrix} = \varepsilon_p \begin{bmatrix} 1 \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (3.10)$$

Burada,

$$r_x(k) = \frac{1}{N} \sum_{n=0}^{N-1-k} x(n+k)x^*(n) \quad ; k = 0,1,\dots,p \quad (3.11)$$

3.10 eşitliği $a_p(k)$ katsayıları için çözülüp, yerine konursa,

$$|b(0)|^2 = \varepsilon_p = r_x(0) + \sum_{k=1}^p a_p(k)r_x^*(k) \quad (3.12)$$

elde edilir.

Bu parametrelerin 3.12 nolu eşitliğe dahil edilmesiyle, güç spektrumu için tahmin üretilmiş olur (Özer, 2010).

3.2.1.2.3.Özbağlanım Spektrum Kestirimi için Kovaryans Yöntemi

AR parametrelerinin kestirimi için bir başka yaklaşım ise Kovaryans yöntemidir. Kovaryans yöntemi AR spektrum kestiriminde ileri kestirim hatalarının kareleri toplamının minimize edilmesi temeli üzerine kuruludur. Bu yöntem, bir dizi doğrusal denklemin çözümünü gerektirir:

$$\begin{bmatrix} r_x(1,1) & r_x(2,1) & \cdots & r_x(p,1) \\ r_x(1,2) & r_x(2,2) & \cdots & r_x(p,2) \\ \vdots & \vdots & \ddots & \vdots \\ r_x(1,p) & r_x(2,p) & \cdots & r_x(p,p) \end{bmatrix} \begin{bmatrix} a_p(1) \\ a_p(2) \\ \vdots \\ a_p(p) \end{bmatrix} = - \begin{bmatrix} r_x(0,1) \\ r_x(1,2) \\ \vdots \\ r_x(1,p) \end{bmatrix} \quad (3.13)$$

Burada

$$r_x(k,l) = \sum_{n=p}^{N-1} x(n-l)x^*(n-k) \quad (3.14)$$

şeklinde verilmektedir.

Otokorelasyon yöntemindeki doğrusal yöntemlerden farklı olarak, burada verilen matrisler, Toeplitz matris değildir. Bununla beraber, kovaryans yönteminin, otokorelasyon yöntemine göre avantajı, otokorelasyon kestiriminde gerekli olan verilerin pencerelemesi işlemini gerektirmemesidir. Bu yüzden, kısa veri kayıtlarında kovaryans yöntemi,

otokorelasyon yöntemine göre daha yüksek çözünürlükte spektrum kestirimi üretir. Ancak veri kayıtları uzadıkça, iki yöntem arasındaki fark da ihmal edilebilir ölçülere gelmektedir (Özer, 2010).

3.2.1.2.4.Özbağlanım Spektrum Kestirimi için İyileştirilmiş Kovaryans Yöntemi

Bu yöntem verilerin pencerenlenmesini gerektirmemesi açısından kovaryans yöntemine benzer. Kovaryans yönteminden farklı olarak, ileri kestirim hatalarının kareleri toplamının minimize edilmesi yerine, iyileştirilmiş kovaryans yöntemi ileri ve geri kestirim hatalarının kareleri toplamını minimize eder. Bu sebeple bazı kaynaklarda bu yöntem “ileri-geri yöntemi” veya “en küçük kareler yöntemi” olarak da geçmektedir (Bozkurt, 2007). Sonuç olarak kovaryans yönteminde kullanılan 3.18 nolu ifade burada da aynen geçerli olmakla birlikte, bu yöntemde 3.19 ifadesi yerine aşağıdaki ifade kullanılır:

$$r_{xx}(k, 1) = \sum_{n=p}^{N-1} [x(n-1)x^*(n-k) + x(n-p+1)x^*(n-p+k)] \quad (3.15)$$

3.2.1.3. Hareketli Averaj Filtre

Hareketli Averaj Filtresi (HAF) yönteminde veri setinin mutlak değeri alınır. Bu işlem EMG işaretinin yansıma etkisinden kurtulmak içindir. Daha sonra belirlenen pencere uzunluğu kadar noktanın ortalaması alınır ve bu oluşturulacak özellik vektörünün ilk değeridir. Daha sonra bu pencere işaret üzerinde belirlenen miktarda kaydırılarak özellik vektörünün diğer değerleri de hesaplanmış olur. OMD’ye göre işlem yükü daha çok olduğundan işlem zamanı da OMD’ye göre uzundur. Fakat OMD’ye kıyasla daha karakteristik sonuçlar verebilmektedir.

3.2.2.Öbekleştirme Yöntemleri

3.2.2.1.K-Ortalama

En eski kümeleme metotlarından biri olan K-means algoritmasının genel mantığı, n adet veri nesnesinden oluşan bir veri setini, giriş parametresi olarak verilen k adet veriye bölümlenektir. Amaç gerçekleştirilen bölümlenme işlemi sonunda elde edilen kümelerin, küme içi benzerliklerinin maksimum ve kümeler arası benzerliklerinin minimum olmasını sağlamaktır. Küme benzerliği, kümenin ağırlık merkezi olarak kabul edilen bir nesne ile kümedeki diğer nesneler arasındaki uzaklıkların ortalama değeri ile ölçülmektedir.

K-means algoritmasının işlem basamakları şöyledir:

1. Adım: Küme merkezleri belirlenir. Bunun için iki farklı yol vardır. Birinci yol nesneler arasından küme sayısı olan k adet rasgele nokta seçilmesidir. İkinci yol ise merkez noktaların tüm nesnelerin ortalaması alınarak belirlenmesidir,

2. Adım: Her nesnenin seçilen merkez noktalara olan uzaklığı hesaplanır. Elde edilen sonuçlara göre tüm nesneler k adet kümeden kendilerine en yakın olan kümeye yerleştirilir

3. Adım: Oluşan kümelerin yeni merkez noktaları o kümedeki tüm nesnelerin ortalama değeri ile değiştirilir,

4. Adım: Merkez noktalar değişmeye kadar 2. ve 3. adımlar tekrarlanır.

K-means algoritmasında her bir nesnenin noktalara uzaklığını hesaplamak için kullanılan dört farklı formül aşağıda açıklanmaktadır. (MacQueen, 1967; Mercer, 2003).

A) Öklit Uzaklığı (Euclidean Distance); Öklit Uzaklığı formülü ile standartlaştırılmış verilerle değil, işlenmemiş verilerle hesaplama yapılır. Öklit uzaklıkları kümeleme analizine sıra dışı olabilecek yeni nesnelerin eklenmesinden etkilenmezler. Ancak boyutlar arasındaki ölçek farklılıkları Öklit uzaklıklarını önemli ölçüde etkilemektedir. Öklit uzaklık formülü en yaygın olarak kullanılan uzaklık hesaplama formülüdür. Formül Denklem 3.16' de görülmektedir. Uzaklık

$$Uzaklık(x, y) = \left\{ \sum_i (x_i - y_i)^2 \right\}^{\frac{1}{2}} \quad (3.16)$$

B) Karesel Öklit Uzaklığı (Squared Euclidean Distance); Boyutlar arasındaki ölçek farklılığı, karesel Öklit uzaklığını önemli ölçüde etkilemektedir. Ancak kolay hesaplama tekniği nedeniyle tercih edilen bir uzaklık hesaplama formülüdür. Formül Denklem 3.17'de görülmektedir.

$$Uzaklık(x, y) = \sum_i (x_i - y_i)^2 \quad (3.17)$$

C) City-Block (Manhattan) Uzaklığı (City-Block (Manhattan) Distance); Manhattan uzaklığı boyutlar arasındaki ortalama farka eşittir. Bu ölçüt kullanıldığında farkın karesi alınmadığı için sıra dışılıkların etkisi azalır. Manhattan uzaklığının formülü Denklem 3.18' de görülmektedir.

$$Uzaklık(x, y) = \sum |x_i - y_i| \quad (3.18)$$

D) Chebychev Uzaklığı (Chebychev Distance): Chebychev uzaklığı iki nesne arasındaki mutlak maksimum uzaklığa eşittir. Chebychev uzaklığının formülü Denklem 3.19’ da görülmektedir.

$$Uzaklık(x, y) = \sum |x_i - y_i| \quad (3.19)$$

$$Uzaklık(x, y) = \max |x_i - y_i| \quad (3.20)$$

x,y; Aralarındaki uzaklık hesaplanan nesneleri uzayda temsil eden noktalar.

K-means algoritmasının en büyük eksikliği k değerini tespit edememesidir. Bu nedenle başarılı bir kümeleme elde etmek için, farklı k değerleri için deneme yanılma yönteminin uygulanması gerekmektedir (Taşan, 2008).

3.2.2.2. Bulanık C Ortalama

Bir nesnenin bir kümeye ait olmasına “doğru” olmamasına “yanlış” denilebilir. Gerçekte, bir nesnenin bir kümeye tam anlamıyla ait olması pek mümkün değildir. Bu durumda, nesnenin bir kümeye ait olma derecesinden söz edilebilir. Nesnenin, bir kümeye ait olma derecesi, bulanık tabanlı algoritmalarla belirlenebilir. Bu ait olma derecesi, 0 ile 1 arasında değerler alır. Daha basit anlamıyla, bir nesnenin bir kümeye ait olması ait olduğu küme ve bu kümeye ait olma derecesi ile gösterilebilir (Koçyiğit ve Korürek, 2005).

Bu ait olma derecesine, bir kümeye olan aitlik değeri de denilir. Bu sebeple bulanık algoritmalar, diğer klasik sınıflama algoritmalarına göre daha fazla bilgi içerirler. Kümeleme yöntemi, eğitici sınıflandırma yöntemlerindendir. Eğitici algoritmalar, kullanacakları veri setini kendileri düzenler. Bu düzenlemeyle, öznelik uzayını diğer eğitilmiş algoritmalarla kıyasla eğitim alanından bağımsız bir şekilde gerçekleştirirler. Kümeleme algoritmalarını, sürekli örnekleme yapılan ölçümlere uygulamak mümkündür. Dolayısıyla hem mevcut kümelerin sürekli farklı kombinasyonun, hem de yeni kümelerin oluşturulması sağlanır. Bu sebeple, aynı sonuçları verecek olan zaman-serisi yeni ölçümler, aynı kümeye dâhil edilecektir. Tam durağan veya tam sürekli denilemeyen biyolojik

işaretlerin sınıflanmasın da uyarlamalı küme oluşturabilmesi açısından bulanık algoritmalar daha etkin kullanılabilir (Koçyiğit ve Korürek, 2005).

Bulanık C-Ortalama Yöntemi: G, küme sayısını; p, veri sayısını; k, veri indisini; i, küme indisini; r, bulanıklığı artıran parametreyi [$r \in (1, \infty)$]; d_{ki} , k. eleman vektörünün i. sınıfa olan öklidyen uzaklığını; μ_i , küme merkezlerini gösterir ;

$$\mu_i = \frac{\sum_{k=1}^p (z_{ki})^r x_k}{\sum_{k=1}^p (z_{ki})^r} \quad (3.21)$$

$$d_{ki}^2 = (x_k - \mu_i)^T (x_k - \mu_i) \quad (3.22)$$

Burada kümelere olan uzaklık değeri z_{ki} aşağıdaki formülle hesaplanır,

$$z_{ki} = \frac{1}{\sum_{j=1}^G \left[\frac{d_{ki}}{d_{kj}} \right]^{\frac{2}{r-1}}} \quad \begin{matrix} k=1,2,\dots,p \\ i=1,2,\dots,G \end{matrix} \quad (3.23)$$

3.2.3.Sınıflandırma Yöntemleri

3.2.3.1. Destek Vektör Makineleri

Temel olarak, istatistiksel öğrenme algoritmalarından biri olan ve Vapnik-Chervonenkis tarafından tanımlanan DVM, birçok gerçek problemde başarılı sonuçlar vermiştir. DVM'nin dayandığı teori, Vladimir Vapnik ve Alexey Chervonenkis tarafından 1960'lı yıllarda başlatılıp 1970'li yıllarda gelişen başarılı bir çalışmanın ürünüdür. Ancak, ilk başarılı uygulamaları 1990'lı yıllarda gerçekleştirilmiş olup, bu uygulamalardan sonra matematikçilerin ve yapay zeka (Artificial Intelligence -AI) bilim adamlarının ilgi odağı olmuştur. DVM'nin temel mantığı doğrusal olarak ayrıştırılabilen veri yapıları için en iyi ayırıcı düzlemin belirlenmesidir. Doğrusal olarak ayrıştırılamayan veri yapıları dönüşüm tekniği ile farklı bir boyuta taşınarak çözülür. Destek vektörü öğrenme, basit fikirler üzerine kurulma ve pratik uygulamalarda yüksek performans göstermesi bakımından oldukça kullanışlıdır. DVM'lerde kullanılacak örnek sayısı önemli değildir. DVM eğitim


esnasında görülmemiş verileri de sorunsuz olarak sınıflandırır. Bu DVM'nin genelleştirebilme yeteneğini gösterir. Genelleştirebilme özelliği DVM'yi diğer tekniklere göre(YSA, karar ağacı vs.) iyi bir alternatif yapmaktadır. Son zamanlarda ise örüntü tanıma, yüz bulma ve tanıma, veri madenciliği, dil yapısını inceleyen mantıksal programlamalarda, uçak alt basınç profillerinin modellenmesi, biyoloji ve diğer biyoinformatik uygulamalarda, gen analizlerinde ve proteinlerin sınıflandırılmasında DVM kullanılmaya başlanmıştır (Karagülle, 2008).

Bu bölümde Destek Vektör Makineleri hakkında genel bilgi verilecek ve öğrenme işleminden bahsedilecektir.

3.2.3.1.1. Destek Vektör Makinelerinde Öğrenme

Destek vektör makineleri, istatistiksel tekniklerin olasılık dağılımının temel alındığı eğitme algoritması olarak bilinir. Birçok pratik durumda, istatistiksel tekniklerin temelini oluşturan dağıtma yasalarının hakkında yeterli bilgi ve dağılım bulunmamaktadır. Bu işlem gerçek dünya uygulamalarında ortak olan çok ciddi bir kısıtlamadır.


Sahip olduğumuz yüksek boyutlu olan desenleri eğitmek günümüze ait uygulamalarda güçlüklerle kaydedilir. Öğrenen makine algoritmaları yüksek boyutlu uzaylarda çalıştırabilmeli ve az sayıda veriden öğrenme işlemini yapabilmelidir. Boyut indirgeme işlemi sağlanırsa veri çiftleri kolay bir şekilde elde edileceğinden daha iyi sonuçlar verilmiş olur. Klasik istatistiksel tekniklerin temel performansı Şekil 3.1'de verilmiştir. Pratik koşullarda rasgele bir veri takımından alınan küçük örnek boyutu güvenilmezdir, genellikle hata ile sonuçlanır.



Şekil 3.1 Modelleme hatasının eğitim veri kümesi boyutu ilişkisi


DVM polinomial modellerde, yapay sinir ağlarında, bulanık mantıkta ve RTF sınıflandırıcılarda sıkça kullanılan yeni bir metottur. DVM'yi, yapısal risk minimizasyonu (YRM) olarak bulunan yeni öğrenim teknikleri ve VC teorisi temsil eder. Geliştirilen Vapnik teorisi düşük seviyeli model VC boyutu, görünmeyen veriler üzerinde iyi bir genelleme yaparak hatanın düşük olasılıkta olduğunu gösterir. Bu özellik, tüm hesaplayan alana özeldir. Veri çiftlerini eğitmede o kadar iyi model olmasa da genelleme işlemini iyi gerçekleştiren modeldir. Bazı kısıtlamalar altında DVM'nin usulüne uydurma teori yapısında, istatistiksel öğrenen teori veya yapısal riskten ziyade minimizasyon türetilmesi vardır. Buradan, DVM'nin istatistiksel öğrenen teori ve yapısal risk teorisinin minimizasyonunu çıkaran, yani, öğrenen bir teknik olduğu söylenebilir. Tümevarım prensibini ve VC sınırının teorisini temel alan verilerle bu yaklaşımlarda öğrenme işlemi gerçekleşir. En basit desen tanıma görevlerinde, vektör makinelerinin azami kenarla bir sınıflandırıcıyı yaratması için doğrusal ayıran bir yüksek düzlemi kullanır. Bunu gerçeklemek için, öğrenen problem, doğrusal olmayan bir optimizasyon problemi olarak alınır. Verilmiş sınıflar uzayının olduğu orijinal girişte doğrusal olarak ayrılamadığı zaman DVM önce doğrusal olarak, daha yüksek boyutlu bir özellik uzayını orijinal giriş uzayına dönüştürür. Bu dönüşüm, çeşitli doğrusal olmayan eşleştirmeleri kullanarak başarılabilir: Polinomial, çok katmalı algılayıcıda olduğu gibi sigmoidal, radyal olarak simetrik görevler Gaussian olduğu esas görevlere sahip olması için RTF

eşleştirmeleri olabilir. Doğrusal olmayan dönüşüm adımı yapıldıktan sonra, doğrusal optimal ayrımı bulmak DVM'nin görevidir. Yani, optimizasyon problemini çözmesi, doğrusal ayrılabilir sınıflar için orijinal giriş uzayında ayırıcı düzlem hesabı olarak aynı türden olur. Özellik uzayında sonuç veren yüksek düzlem, azami bir kenar sınıflandırıcısı olduğunda optimal sonucu verir. Standart öğrenme durumu, Şekil 3.2'de gösterilmektedir (Karagülle, 2008).




Şekil 3.2 Veri görevlerinden öğrenme işleminin standardı

Öğrenme, stokastik bir süreçtir. Şekil 4.3'te rasgele eğitim gösterilmektedir. Eğitim takımı, rasgele değişken takımlarından oluşturularak, giriş değişkeni, rasgele değişken x_i 'dir. Girişten $P(x_i)$ olasılıkla çekilmiş, çıktıya ait olan y_i 'nin, olasılığı $P(y_i | x_i)$ 'dir. Bu özellik eğitim fazı sırasında d_i (istek) tarafından y_i yanıtını gösterir. Bu yüzden $P(d_i | x_i) = P(y_i | x_i)$ olarak ifade edilebilir. y burada, sadece basitlik için kullanılan çıktı değişkeninin yönsüz değeridir. Bütün kökler, temelde aynı vektör çıktısı y 'den türer. Toplanan (x, d) veri noktalarının olasılıkları $P(x, d) = P(x)P(y | x)$ şeklindedir.



Şekil 3.3 Eğiten veri takımını toplarken öğrenmenin rastgele gösterimi


İstatistiksel ayarda, veri öğrenmede üç temel bileşen vardır. Bunlar; x rasgele girişlerin bir üretici, eğitim sisteminin yanıtları y ve x girişleri ile y sistem çıkışlarını kullanarak öğrenmeye çalışan makinedir. Şekil 3.4, çeşitli alanlarda ortak olan öğrenimi gösterir. Özellikle, sistem teşhisini kontrol eder ve işleme tabi tutmaya çalışır. Kullanılan X ve Y verisinin arasındaki ilişkiyi geri dönüşte D başarılı şekilde bulması için eğiten evre esnasında öğrenen bir makine görevleri ya da bir fonksiyonu ile sınıflandırma görevlerinde veriyi ayırır. Öğrenme işleminin yaklaşık fonksiyonel sonucu $f_a(x, w)$ 'dır. Bu fonksiyon, yaklaşık (veya doğru) temeli oluşturmayı, giriş ve gerileme veya karar sınırında çıktının arasında bağımlı durumları tahmin eder (Karagülle, 2008).



Şekil 3.4 Öğrenen makinenin modeli


3.2.3.1.2. Destek Vektör Makine Algoritması

DVM temelinde, öncelik değişkenini bir özelliğe çağırıp, çok boyutlu düzlemde kullanılan niteliğe dönüştürür. En uygun temsili seçmenin amacı, özellik seçimi olarak bilinir. Özellikler doğru seçilirse iyi temsiller elde edilerek doğru sonuçlara ulaşılabilir. Bir olayı tanımlayan özellik takımı bir vektör ile çağırılır. Bundan dolayı DVM modelinin amacı, hedef değişkeninin bir kategorisiyle olayların vektör kümelerini ayıran optimal aşkın düzlemi bulmaktır. Aşırı düzlemin yanındaki vektörler destek vektörleridir. Şekil 3.5'te destek vektör algoritmasının genel yapısı görülmektedir.




Şekil 3.5 Destek Vektör Makine Algoritması

N boyutlu aşırıdüzlemi düşünmeden önce basit 2 boyutlu bir örnek üzerinde algoritmanın çalışmasını inceleyelim. Sınıflandırma için 2 kategorili hedef değişkeni ele alalım. Devamlı değerlerle iki öncelik değişkeni olduğunu varsayalım. X ekseninde öncelik değişkenlerinden birini Y ekseninde diğerini kullanarak veri noktalarını oluşturursak aşağıdaki şekli elde ederiz. Hedef değişkeninin bir kategorisini dikdörtgenler ile, diğer kategorileri ovalar ile temsil ederiz. Şekil 3.6’de sınıflandırma örneği görülmektedir.



Şekil 3.6 Sınıflandırma örneği


Bu örnekte durumlar tamamen farklı köşelerde toplanıp tamamen ayrıştırılmıştır. DVM analizi, olayları ayıran 1-boyutlu aşkın düzlemi hedef kategorilerini temel alarak bulmaya çalışır. Mümkün çizgilerin sınırsız sayısı vardır. İki aday çizgi yukarıdaki gibi gösterilir. Hangi çizginin, daha iyi olduğunu ve optimal çizgiyi nasıl bulacağımız önemlidir. Noktalı gösterilen çizgiler en yakın vektörler arasında mesafeyi ayıran çizgiye paralel olarak çekilir. Noktalı çizgilerin arasındaki mesafe kenarı çağırır. Kenarın genişliğini zorlayan vektörler, destek vektörleridir. Şekil 3.7’de destek vektörleri ve elde edilen maksimum sınırlar gösterilmiştir.



Şekil 3.7. Destek Vektörleri ve Sınırlar


DVM analizi, destek vektörlerinin arasındaki kenarı azami dereceye çıkararak yön verilen çizgileri bulur. Eğer bütün analizler, iki öncelik değişkeniyle iki kategori hedef değişkenine dayansaydı noktalar kümesini düz bir çizgi ile bölmüş olurdu. Yüksek boyutlara geçerse; Yukarıdaki örnekte 2 boyut için iki öncelik değişkeni kullanılıp, düzlem üzerinde çözüm bulunmuştur. Bu işlem 1 boyut için çizgi şeklindedir. 3 boyutlu bir örnek ele alınırsa 3. öncelik değişkeni devreye girerek bir küp elde edilmiş olur.

Ekstra öncelik değişkenleri eklenildiği gibi, veri noktaları N boyutlu uzayda temsil edilebilir ve $(N-1)$ ayırıcı düzlem, onları ayırabilir. iki grubu bölmek için en basit yol, düz bir çizgi veya N -boyutlu bir düzlemdir. Ama noktalar doğrusal çizgiyle ayıramayacak şekilde bulunursa bu işlem yapılamaz. Şekil 3.8'de doğrusal olmayan sınıflandırma örneği görülmektedir.



Şekil 3.8. Doğrusal Olmayan Sınıflandırma


Bu durumda doğrusal olmayan bir çizgiye ihtiyaç duyulur. Veriye doğrusal olmayan eğrilerle uymaktansa DVM'yi başka bir uzaya çekirdek fonksiyonu aracılığıyla taşıyarak daha tutarlı bir şekilde ayırım sağlanmış olunur. Şekil 3.9'de çekirdek fonksiyonlarının üst boyuta taşınması gösterilmektedir.



Şekil 3.9. Çekirdek fonksiyonları ile üst boyuta taşıma işlemi


Çekirdek fonksiyonu, sınıflandırmanın yapılabilmesi için veriyi daha yüksek boyutlara taşıyabilir. Şekil 3.10'de verinin yüksek boyutlara taşınarak yapılan haritalama işlemi gösterilmektedir.

Ayrılma işlemi yüksek boyutlarda daha kolay gerçekleşir.



Şekil 3.10 Haritalama işlemi

Çekirdek fonksiyonunun üst boyuta taşınma işlemi güçlü bir yaklaşımdır. Çok karmaşık sınırlarla ayrılan durumlarda bile Şekil 3.11 resimde görüldüğü gibi DVM modellerine izin verir (Karagülle, 2008).



Şekil 3.11. Örnek DVM modeli

3.2.3.1.3. DVM’de Kullanılan Çekirdek Fonksiyonları


Çekirdek fonksiyonları sınıflandırmanın daha yüksek boyutlarda yapılabilmesi için taşıma işleminde kullanılabilir. Uygulamaların büyük çoğunluğunda birçok çekirdek fonksiyonu iyi sonuçlar verir.

Sık kullanılan çekirdek fonksiyonları Doğrusal, Polinomial, Radyal Tabanlı ve Sigmoid Fonksiyonlarıdır (Karagülle, 2008).

3.2.3.1.3.1. Doğrusal Fonksiyon

Doğrusal sınıflandırma işlemi, doğrular çizilerek yapılr ve dikdörtgen, kare gibi şekillerin sınıflandırılmasında daha etkilidir.

Doğrusal sınıflandırmada kullanılan fonksiyon, (u, v) formülü ile temsil edilir. Şekil 3.12’de gösterildiği gibi doğrusal olarak sınıflandırma yapar (Karagülle, 2008).




Şekil 3.12. İki Boyutlu Örnek Uzayında Doğrusal Fonksiyon Gösterimi


3.2.3.1.3.2. Polinomial Fonksiyon

Polinomial fonksiyon ile sınıflandırma, $(\gamma \cdot u \cdot v + katsayı_0)^{derece}$ formülü kullanılarak yapılmaktadır.

Şekil 3.13’de doğrusal ve doğrusal olmayan sınıflandırma birlikte gösterilmektedir. Şekil 3.14’da ise 2 boyutlu örnek uzayında Polinomial fonksiyonun sınıflandırılması gösterilmektedir (Karagülle, 2008).




Şekil 3.13. Doğrusal ve Doğrusal Olmayan Sınıflandırma Gösterimi




Şekil 3.14. İki Boyutlu Örnek Uzayında Polinomial Fonksiyon Gösterimi

3.2.3.1.3.3. Radyal Tabanlı Fonksiyon

Radyal Tabanlı sınıflandırma işlemi, doğrusal olmadığından örneği daha yüksek boyutlu bir uzaya taşıyarak gerçekleştirir. Bu işlem için $\exp(-\gamma \cdot \|u - v\|^2)$ fonksiyonu kullanılır. Şekil 3.15, Radyal tabanlı fonksiyon kullanılarak farklı bir boyuta taşınma ve sınıflandırma sonucunu göstermektedir. Şekil 3.16'de, 2 boyutlu örnek uzayında sınıflandırma gösterilmektedir (Karagülle, 2008).




Şekil 3.15. RTF ile Sınıflandırılarak Farklı Boyuta Taşınması



Şekil 3.16. İki Boyutlu Örnek Uzayında Radyal Tabanlı Fonksiyon Gösterimi


3.2.3.1.3.4. Sigmoid Fonksiyon

Sigmoid fonksiyon ile sınıflandırma, $\tanh(\gamma \cdot u \cdot v + katsayı_0)$ formülü kullanılarak yapılmaktadır. Şekil 3.17’de sigmoid fonksiyon yapısı gösterilmiştir (Karagülle, 2008).



Şekil 3.17. Sigmoid Fonksiyon

İdeal olarak bir DVM analizi, tamamen iki ayrı sınıflandırma sonucunu ve özellik vektörlerini ayıran çok boyutlu düzlemi üretmelidir. Yine de, mükemmel sınıflandırma mümkün olmayabilir. Modelin veriyi iyi bir şekilde genelleyemediği ve çok fazla özellik vektörleri üreterek sonuca ulaştığı zamanlar olabilir. Şekil 3.18’de hatalı sınıflandırma örneği görülmektedir.



Şekil 3.18. Hatalı Sınıflandırma Örneği

Kategorileri ayırma işleminde esnekliğe izin vermek için C parametresi kullanılır. Bu parametre hataları kontrol altına almak için kullanılır. Örneğin sert kenarlara yumuşaklık kazandırarak daha iyi sınıflandırma yapılmasını sağlar. C'nin değerini artırmak, iyi bir şekilde genellenemeyen kaçan noktaların sınıflandırmasını sağlar (Karagülle, 2008).

3.2.3.2. Diskriminant Analizi

Diskriminant(Ayrırma) analizi, diskriminant fonksiyonları ile bir nesneye ait sınıflar arası ayırma en fazla etki eden özellikleri (değişkenleri) belirlemede ve sınıfı bilinmeyen yeni bir nesnenin hangi sınıfa dâhil olacağına karar vermede kullanılan bir analizdir. Bu analiz genel anlamda bir ayırma işlemi olup p adet özelliğe sahip bir nesnenin, bu

özelliklerinden faydalanılarak, mevcut sınıflardan (grup) birine dâhil olmasını veya mevcut nesneleri birbirinden ayıracak en iyi fonksiyonları bulmada kullanılan çok değişkenli istatistik yöntemlerinden biridir. Diskriminant analizi, birkaç farklı adlandırma ile literatürde geçer. Bunlar; kanonik Diskriminant Analizi, en çok olabilirlik Diskriminant Analizi ve Bayes Diskriminant Analizi şeklindedir (Çamdeviren, 2000).

Fisher (1936) yılında, diskriminant analizinde kullanılan diskriminant fonksiyonlarının ölçütünü ortaya koymuştur. Diskriminant fonksiyonlarındaki bu ölçüt, uzaklık ölçüleri, yanlış sınıflandırma olasılığı ve yanlış sınıflandırma maliyetini içeren optimal yaklaşımdır.

Welch (1939) yılında, en iyi ayırmanın, hatalı sınıflandırma olasılığı ve yanlış sınıflandırma maliyetleri en aza indirgendiğinde gerçekleşeceğini ortaya koymuştur.

Roy (1939) yılında, p değişkenli iki normal dağılım için kovaryans matrislerinin eşitliğini test etmiştir.

Rao (1948) yılında, ikiden çok sınıf olduğunda nesneleri minimum hata ile sınıflandırmaya çalışmıştır.

Anderson ve Bahadur (1962) yılında, ortalaması ve varyans-kovaryans matrisi farklı olan çok değişkenli normal dağılımların sınıflandırılması üzerinde çalışmıştır. Hotelling ve Mahalanobis'de bu ve benzeri çalışmalarda bulunmuşlardır (Emin, 1984)

Nesnelerin sınıflandırılmasında genel olarak bazı matematiksel eşitliklerden yararlanılır. Diskriminant fonksiyonları olarak adlandırılan bu eşitliklerden faydalanılarak birbirine en çok benzeyen sınıfların oluşturulması için sınıfların ortak özellikleri belirlenmeye çalışılır. Ayırma amacı ile kullanılan bu sınıf karakteristikleri diskriminant değişkenleri olarak adlandırılır. Kısaca, iki veya daha fazla sınıfa ait farklılıkların bu diskriminant değişkenleri ile ortaya konulması işlemidir (Klecka, 1987).

Amaç, nesneler arasındaki hatalı sınıflandırma olasılığını en aza indirerek ait oldukları sınıflara ayırmak veya bu nesnelerin rastsal olarak alındığında ait oldukları sınıfları belirlenmektir (Johnson ve Wichern, 2002). Bu durumda belirlenen sınıfların ortalamaları arasındaki farkın maksimum olması sağlanmalıdır.

Diskriminant Analizi, sınıflar arasında çeşitli özellikler göz önüne alınarak farklılıkların ortaya konulmasını sağlar. Nesneler en az hata ile ait oldukları sınıflara ayrılmaktadır. Bu esastan hareketle nesnelerin sınıflarını belirleyecek fonksiyonları

bulmaktır. İki veya daha fazla sınıfın aralarındaki etkileşimin ne seviyede ve nesnelerin özellikleri arasında ne gibi farklılıklar bulunduğunu ortaya koymaktır (Tümer, 2001).

İşlevsel olarak, sınıfların farklılıklarını anlamak ve bir varlığın (birey, nesne) belirli bir sınıfa veya birkaç metrik bağımsız özelliğe dayalı olarak bir sınıfa ait olması olasılığını kestirmektir. Sınıflar arası farklılığa en çok etki eden özelliklerin hangileri olduğunu ortaya çıkarır (Cangül, 2006).

3.2.3.2.1. Çok Boyutlu Ölçekleme Analizi

İstatistiksel olarak kişisel tercihler, tutumlar, eğilimler, inançlar ve beklentiler gibi davranışsal verilerin analizinde kullanılır. Çok boyutlu ölçekleme, n tane nesne (birey, gözlem) arasındaki uzaklık değerlerini kullanarak bu nesnelerin çok boyutlu uzaydaki konumlarını, ilişki yapısını veren resmini ortaya koymayı amaçlamaktadır. Uzaklıklar veya farklılıklar yardımıyla nesnelerin geometrik konumlarının belirlenmesi, şekillendirilmeleri önemli bir konudur. Bu amaçla yapılan çalışmalarda genellikle elde edilen şekillerin çok boyut içermesi sebebiyle bu ölçeklemelere çok boyutlu ölçekleme adı verilmiştir (Tatlıdil 1996).

Bu analiz belli bir dağılım varsayımı gerektirmeyen bir yöntemdir. Buna karşın bu yöntemin sağlaması gereken varsayımların bazıları şunlardır: n tane nesne ya da birim arasındaki uzaklıkları kullanır. Bu uzaklıklar simetrik ve yansımalıdır. Veri tipini doğru olarak belirlemek gerekir (Örneğin; sınıflamalı, sıralı, eşit aralıklı veya orantılı). Analiz edilecek veriler farklılıklar belirtiyor ise, farklılıklar matrisi nicel değerler içermelidir (Cangül, 2006).

3.2.3.2.2. Çok Değişkenli Normal Dağılım

Çan eğrisi şeklindeki normal dağılımın çeşitli boyutlara genelleştirilmesi çok değişkenli istatistikte önemli bir rol oynar. Aslında birçok istatistiksel teknik, verilerin çok değişkenli normal bir dağılımdan üretildiği varsayımına dayanmaktadır. Gerçek veriler hiçbir zaman tam olarak çok değişkenli normal dağılıma sahip olamazlar da normal dağılım çoğunlukla “doğru” ana kütle dağılımına oldukça yaklaşılmaktadır (Cangül, 2006).

Çok değişkenli istatistiksel analiz tekniklerinin çoğunda, örneklemelerin çok değişkenli normal dağılımlı kütlelerden geldiği kabul edilmektedir. Çok değişkenli normal dağılımı kullanmanın avantajları vardır. Bunlardan bazılarını şu şekilde sıralayabiliriz:

Çok değişkenli normal dağılım,

- Matematiksel olarak incelenmesi, çözümlenmesi ve sonuçların yorumlanması açısından kolay olan dağılımdır.

- Doğada sürekli değişken içeren çok değişkenli olaylar normal dağılım gösterir. Birçok uygulamacı, diğer dağılımlarla ilgili yaklaşımlar yaygın kullanıma sahip olmadığından ayrıntılı bilgiye sahip olmayabilir.

- Çok değişkenli istatistiklerin örneklem dağılımları merkezi limit teoremi etkisinden dolayı çok değişkenli normal dağılım gösterir.

- Çoğu problemin incelenmesinde normal dağılım varsayımlarının kullanılması oldukça tutarlı bir yaklaşımdır.

Çok değişkenli normal dağılımın bir avantajı matematiksel olarak anlaşılır olması ve birçok faydalı sonucun elde edilebilmesidir. Bu genellikle diğer veri üreten dağılımlarda rastlanmayan bir özelliktir. Tabii matematiksel çekiciliği pratik uygulama yapan bir araştırmacının çok da işine yaramaz. Bununla birlikte normal dağılımlar uygulamada iki sebepten dolayı faydalıdır. İlk olarak normal dağılım bazı durumlarda doğal bir kütle modeli olarak hizmet vermektedir. İkinci olarak ta birçok çok değişkenli istatistik örneklem dağılımları merkezi-limit teoreminin etkisiyle ana kütleyle bağlı olmaksızın yaklaşık olarak normaldir (Cangül, 2006).

Özet olarak, birçok doğal problem normal dağılım teorisine yaklaşık sonuçlar vermektedir. Esasen normal dağılımın önemi, hem bazı doğal olaylara karşılık gelen bir ana kütle modelinden, hem de birçok istatistik uygulaması için uygun bir örneklem dağılımına sahip olmasından kaynaklanır (Cangül, 2006).

3.2.3.2.3. Tek Değişkenli Normal Dağılım Eşitlikleri

Ortalama değeri μ ve varyansı σ^2 olan tek değişkenli normal dağılımın olasılık yoğunluk fonksiyonu aşağıdaki şekildedir.

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-[(x-\mu)/\sigma]^2/2} \quad \left| \begin{array}{l} -\infty < x < \infty \\ \sigma^2 > 0 \end{array} \right. \quad (3.24)$$

Bu fonksiyonun şekli, Şekil 3.10'de görüldüğü gibi çana benzediği için çan eğrisi olarak ta adlandırılır. Şekilde ayrıca eğri altında kalan ve ortalamadan ± 1 ve ± 2 standart

sapmaya karşılık gelen kısımlar gösterilmiştir. Bu alanlar olasılıkları gösterir. Normal rastsal X değişkeni için,


$$P(\mu - \sigma < X < \mu + \sigma) = 0,68$$

$$P(\mu - 2\sigma < X < \mu + 2\sigma) = 0,95$$

$$P(\mu - 3\sigma < X < \mu + 3\sigma) = 0,9973$$

yazılabilir.

Ortalaması μ ve varyansı σ^2 olan normal yoğunluk fonksiyonu $N(\mu, \sigma^2)$ ile Şekil 3.19'daki gibi gösterilir.



Şekil 3.19.(a),(b) Ortalaması μ ve varyansı σ^2 olan bir normal yoğunluk ve eğri altındaki alanlar.

Tek değişkenli normal yoğunluk fonksiyonunun üssündeki,

$$\left(\frac{x-\mu}{\sigma}\right)^2 = (x-\mu)(\sigma^2)^{-1}(x-\mu) \quad (3.25)$$

terimi x 'ten μ 'ye kadar olan uzaklığın standart sapma birimi cinsinden karesini ölçmektedir. Bu durum çeşitli değişkenlerin gözlemlerinden oluşan $p \times 1$ boyutlu bir x vektörüne şu şekilde genelleştirilebilir:

$$(x-\mu)^T \Sigma^{-1}(x-\mu) \quad (3.26)$$

$p \times 1$ boyutlu bir μ vektörü X rastsal vektörünün beklenen değerini belirtmektedir. $p \times p$ boyutlu Σ matrisi ise X 'in varyans-kovaryans matrisidir. Simetrik Σ matrisinin pozitif tanımlı olduğu varsayıldığında, bu son denklem x 'ten μ 'ye olan genelleştirilmiş uzaklığın karesidir (Cangül, 2006).

3.2.3.2.4. Çok Değişkenli Normal Dağılım Eşitlikleri

Çok değişkenli normal yoğunluk, tek değişkenli normal yoğunluğun çok boyuta ($p \geq 2$) genelleştirilmesi ile elde edilir (Cangül, 2006).

Çok değişkenli normal yoğunluk, (3.24)'deki yoğunluk fonksiyonundaki tek değişkenli uzaklığın (3.25) çok değişkenli genelleştirilmiş uzaklıkla (3.36) değiştirilmesi ile elde edilir. Bu değişiklik yapıldığında tek değişkenli normalleştirme sabiti olan $(2\pi)^{-1/2}(\sigma^2)^{-1/2}$ 'nin, herhangi bir p boyutu için çok değişkenli yoğunluk fonksiyonunun yüzeyi altında kalan hacmi birim değer yapacak şekilde daha genel bir sabitle değiştirilmesi gerekir. Bu çok değişkenli durumda olasılıklar, x_i değerlerinin oluşturduğu bölgeler üzerinde tanımlanan yüzeyler altında kalan hacimler cinsinden ifade ediliyor olmaları sebebiyle gereklidir. Bu sabit şu şekilde, $(2\pi)^{-p/2} |\Sigma|^{-1/2}$ gösterilebilir. Bundan hareketle, sonuç olarak bir $X = [X_1, X_2, \dots, X_p]$ rastsal vektörü için p -boyutlu bir normal yoğunluk, $i = 1, 2, \dots, p$ için $-\infty < x_i < \infty$ olmak üzere,

$$f(x) = \frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}} e^{-\frac{(x-\mu)^T \Sigma^{-1} (x-\mu)}{2}} \quad (3.27)$$

şeklinde ifade edilir. Bu durumda p-boyutlu normal yoğunluk, tek değişkenli durumdan tek farkı p indisi ile $N_p(\mu, \Sigma)$ şeklinde gösterilir (Cangül, 2006).

3.2.3.2.5. Diskriminant Analizinin Varsayımları

Diskriminant Analizi, hangi değişkenlerde daha fazla farklılık oluştuğunun belirlenmesinde de kullanılır. Böylece grupların ayrılmasında etkin olan faktörlerin tespit edilmesini de sağlar. Elde edilen fonksiyonlarla gerçek grupların karşılaştırılması yapılarak fonksiyonların yeterli olup olmadıkları test edilebilir. (Erçetin, 1993).

Diskriminant Analizi, hatalı sınıflandırma olasılığını en aza indirgeyerek birimleri ait oldukları gruplara ayırmak amacına yönelik olan, istatistiksel bir karar verme yöntemidir (Tatlıdil, 1996).

Diskriminant Analizi, X veri setindeki değişkenlerin iki veya daha fazla gerçek gruplara ayrılmasını belirlemek amacıyla yararlanılan bir yöntemdir (Özdamar, 1999).

Ayırt edici değişkenlerin sahip olabilecekleri istatistiksel özelliklerle ilgili bazı kısıtlamalar vardır. Hiç bir değişken diğer ayırt edici değişkenlerin bir lineer bileşimi olmamalıdır. Bir lineer bileşim sabit katsayılar ile çarpılan bir ya da daha çok değişkenin ağırlıklı toplamıdır. Bu yüzden bir araştırmacı bu değişkenlerin yanında bunların toplamını ya da ortalamasını kullanma şansına sahip olmaz. Birbiri ile oldukça uyumlu iki değişkeni de aynı anda kullanamayız. Lineer bileşimlere karşı olan bu kısıtlama sezgisel olarak anlamlı olsa da matematiksel olarak gereklidir. Lineer bileşim olarak elde edilecek bir değişken, bileşenlerin sahip olduğu bilgilerin ötesinde yeni bir bilgi içermediğinden kullanımı gereksizdir (Cangül, 2006).

Birçok uygulamada gerekli olan bir başka varsayım her bir grup için kovaryans matrislerinin eşit olmasıdır. En kolay ve sıkça kullanılan Diskriminant Analizi, türü ayırt edici değişkenlerin basit bir lineer bileşimi şeklinde olan bir lineer diskriminant fonksiyonu kullanmaktadır. Bu yöntem en kolay olanıdır. Çünkü eşit grup kovaryans matrisleri varsayımı diskriminant fonksiyonu ve belli başlı önem testlerini hesaplamada kullanılan formüllerin basitleştirilmesini sağlar. Diskriminant Analizi, grupların kovaryans matrislerinin eşit olup olmamasına göre farklı biçimlerde uygulanabilmektedir. Her ne kadar Diskriminant Analizinin temel varsayımlarından birisi grupların kovaryans

matrislerinin birbirine eşit olduğu biçiminde ise de bu varsayım geçerli olmaması durumlarında da Diskriminant Analizi yapılabilmektedir (Cangül, 2006).


Bir başka varsayım, her bir grubun çok değişkenli normal dağılıma sahip bir kütleden geldiğidir. Bu şekilde bir dağılım da her değişkenin, sabit değerler etrafında normal bir dağılıma sahip olmaları durumunda ortaya çıkar. Bu durum, önem testlerinin ve grup üyeliklerinin olasılıklarının kesin olarak hesaplanabilmesini sağlar. Bu varsayım kaldırılması durumunda hesaplanan olasılıklar doğru değildir (Cangül, 2006).

Diskriminant Analizi aynı zamanda birbirine girmiş ortak özelliklere sahip grupları birbirinden ayırmak için grup ortalama vektörlerini birbirinden ayıracak fonksiyonlar geliştiren bir yöntemdir (Cangül, 2006).

Diskriminant Analizi; Varyans Analizi (ANOVA) ve Çoklu-Değişkenli Varyans Analizi (MANOVA) yöntemleri gibi grupları ortalamalarına (ortalama vektörlerine) göre ortak ortalamadan (ortalama vektöründen) farklı olmalarını sağlayacak bir ayırma kriteri geliştirmeyi amaçlayan bir yöntemdir. Bu nedenle veri setlerine Diskriminant Analizi uygulanabilmesi için veri setlerinin ANOVA ve MANOVA uygulaması için gerekli olan aşağıdaki varsayımları taşıması gerekir.

- 1) X veri matrisi çok değişkenli normal dağılım göstermelidir.
- 2) Değişkenlerin varyans ve kovaryansları homojen olmalıdır. X matrisinde yer alan değişkenler ortak kovaryans matrisine sahip çok değişkenli ana kütleden çekilmiş örnekler olmalıdır.
- 3) Değişkenlerin ortalamaları ve varyansları arasında bir korelasyon bulunmamalıdır.
- 4) Değişkenler arasında çoklu bağımlılık bulunmamalıdır.
- 5) X matrisi grupların birbirinden ayrılmasında rol oynamayacak gereksiz değişken içermemeli, grupların birbirinden ayrılmasını sağlayacak kadar doğru ve gerekli değişkenleri içermelidir.

Bu varsayımlar Diskriminant Analizine genelde yapılan yaklaşımlara dayalı bir matematiksel model ortaya koyar. Eğer belli bir problemin verileri varsayımları sağlamazsa istatistiksel sonuçlar tam olarak gerçeği yansıtmayacaktır.



Şekil 3.20. Ayırt edici değişkenler ve gruplar arasındaki ilişkiler

Grupları bir tek seviye değişkeni yardımı ile tanımlanmış olarak düşünürsek Diskriminant Analizinin bir seviye değişkenini çeşitli aralık seviye değişkenlerine atayan bir teknik olduğunu görürüz (Cangül, 2006).

Diskriminant Analizinin altında yatan matematiksel kavramlar şu şekilde özetlenebilir:

g : grup sayısı

p : ayırt edici değişkenlerin sayısı

n_i : i grubundaki durumların sayısı

n : tüm gruptaki tüm durumların sayısı.

Tüm istatistiksel ve matematiksel modellerde olduğu gibi, Diskriminant Analizi de bazı varsayımlara dayanmaktadır. Analizin ayırım gücü dayandığı varsayımların sağlanmasına ya da bu varsayımlar karşısında sağlam olmasına bağlıdır. Özellikle modelin başarısının, beklenenden düşük çıktığı durumlarda, doğru yorumda bulunabilmek için bu varsayımların test edilmesi gerekmektedir. Diskriminant Analizinin varsayımları şu şekilde ifade edilebilir:

1) Ana kütle belli özelliklere göre gruplanabilir (Tatsuoka, 1976). Birbirinden farklı iki veya daha fazla grup söz konusu olmalıdır (Polat, 1995). Yani $g \geq 2$ 'dir.

2) Her grupta en az iki durum olmalıdır: $n_i \geq 2$.

3) Veriler ana kütlede rastsal olarak seçilmiştir.

4) Toplam durum sayısının 2 eksiğinden az olmak kaydıyla herhangi sayıda ayırt edici değişken olmalıdır: $0 < p < n - 2$.

5) Ayırt edici değişkenler 1. ölçek seviyesinde ölçülürler.

6) Hiçbir ayırt edici değişken diğer ayırt edici değişkenlerin lineer bileşimi olamaz.

7) Özel formüller kullanılmadıkça her bir grup için kovaryans matrisleri (yaklaşık olarak) eşittir. Gruplara ait ortalamalar ve kovaryans matrisi önceden bilinir. Grupların kovaryans (sapma) matrisleri eşittir (Karels ve Prakash, 1987). Bu varsayımın sağlanmadığı durumlarda, Diskriminant Analizinin karesel (kuadratik) formu kullanılabilir.

8) Her bir grup, ayırt edici değişkenler üzerindeki çok değişkenli normal dağılıma sahip bir örnek grubundan alınır. Bağımsız değişkenler çok boyutlu normal dağılıma sahiptirler (Leeuwen, 1985).

9) Grupların eşit sayıda birimden oluşmadığı durumlarda, üyelerin öncelikli olasılıklarının bilindiği varsayılır.

10) Herhangi bir durumun yanlış sınıflandırılmasının maliyeti önceden bellidir.

Bu varsayımlardan bir ya da daha fazlasının sağlanmadığı durumda, Diskriminant Analizi optimum bir sınıflandırma ortaya koyamayacaktır (Cangül, 2006).

Buraya kadar sınıflandırmaya esas olan varsayım her grubun eşit olarak değerlendirilmesine dayalıdır. Uygulamada bu istenen bir durum olmayabilir. Örneğin bir veri setinin %90 bir gruba kalan %10 kısmı bir başka gruba dâhil olsun. Hiçbir hesap yapmaksızın verilen yeni bir ölçümün ilk gruba dâhil olma olasılığının yüksek olduğu aşîkârdır. Yeni ölçümün diğer gruba ait kuvvetli özelliklerinin olmadığı durumda ilk gruba sınıflanması mantıklıdır. Bu durumda, sınıflandırmaya ait sonradan ortaya çıkan olasılıkların öncelikli olasılıklara katılması gerekebilir.

Bir başka olasılıkta, yanlış sınıflandırmanın bedelinin gruplara göre ciddi farklılıklar gösterdiği durumdur. Bunu şu şekilde açıklayalım. Sınıflandırmada yanlışlık yapıldığında hasta, bir tümör kötü huylu olduğu halde iyi huylu diye sınıflandırıldığında, iyi huylu olduğu halde kötü huylu diye sınıflandırılmasına göre daha çok zarar göreceği ihtimali yüksektir. Bu olasılıklar öncelikli olasılıklara benzer bir şekilde kullanılabilir (Cangül, 2006).


3.2.3.2.6. Diskriminant Analizine Geometrik Yaklaşım

Diskriminant analizinin geometrik yorumunu yapmak için pozitif x_1 ve x_2 özelliklerine sahip K_1 ve K_2 sınıflarından N_1 ve N_2 adet nesnenin olduğunu düşünelim. Bu nesnelerin aldığı x_1 ve x_2 özellik değerleri öklidyen uzayda N_1 ve N_2 adet noktaya karşılık gelir. Bu noktaların oluşturduğu normal dağılıma sahip bulutlar ise bir elips olarak çizilebilir (Ünal, 2006).

Örneğin I doğrusu K_1 ve K_2 sınıfına ait iki boyutlu özellik uzayını ayıran J doğrusuna dik bir doğru olsun (Şekil 3.4). K_1 ve K_2 sınıflarına ait nesneleri temsil eden noktaların izdüşümleri I doğrusu üzerine düşürülür. K_1 ve K_2 sınıflarının I doğrusu üzerindeki ortalama vektörlerinin izdüşümü arasındaki varyans, en büyüklenmiş olur.

Nesnelere ait p adet özelliklerinin I doğrusu üzerindeki izdüşümleri, lineer bir dönüşümle bulunur. Bu durumda I eksen, nesnelerin p adet özelliği dikkate alınarak oluşturulan bir ayırma eksenine dönüşmüş olur. Bu doğru aynı zamanda diskriminant fonksiyonlarını temsil eder.

I ve J doğrularının kesiştiği w noktası, bu tek boyutlu ayırma uzayını S_1 ve S_2 olmak üzere iki bölgeye ayırır. Sonuç olarak S_1 bölgesine izdüşümü düşen bir nesne küçük bir hata ile K_1 sınıfına ve S_2 bölgesine düşen ise K_2 sınıfına sınıflandırılmış olur.



Şekil 3.21. Diskriminant analizine geometrik yaklaşım.

Ayırma eksenini I , K_1 ve K_2 sınıflarının çok değişkenli normal dağılıma ve ortak varyans-kovaryans'a sahip olmaları varsayımı üzerine oluşturulmuştur. Bu iki varsayım altında J doğrusu, iki sınıfı birbirinden ayıran en iyi doğru olacaktır. Aksi takdirde bu doğru, en iyi ayırma doğrusu olmayacaktır (Ünsal ve Güler, 2005).

Diskriminant analizinin uygulama adımları şu şekildedir:

- Öncelikli grup üyelikleri belirlenir.
- Analize alınan gruplar arasında fark olup olmadığı, Bartlett'in Ki-kare test istatistiği ile test edilir. Test sonucu gruplar arasında anlamlı bir fark varsa, analize devam edilir.
- Kullanılacak değişkenler seçilir. Değişken seçiminde Öncelikli bilgi ya da istatistikî yöntemler uygulanabilir.
- Değişkenler arasında çoklu bağlantının olup olmadığı incelenir. Bu amaçla birleştirilmiş grup içi korelasyon matrisi incelenir. Bu matristeki korelasyon değerleri mutlak değerce %75'den büyük ise değişkenlerden bir kısmının atılması gerekir. Bu adımın sonunda değişken kümesi belirlenmiş olur.
- $W^{-1}B$ matrisinin özdeğerleri ve bu özdeğerlere ilişkin özvektörler bulunur. Bu özvektörler, diskriminant fonksiyonları için gerekli ağırlıkları verir. Diskriminant fonksiyonlarının anlamlılık testi de bu özdeğerler kullanılarak yapılır. Eğer herhangi bir fonksiyon anlamlı ise yaptığı ayırmanın başarılı olduğu söylenebilir.
- Standartlaştırılmamış diskriminant fonksiyonu kullanılarak her bir birey için diskriminant fonksiyonu değerleri elde edilir. Bu değerler sınıflandırma aşamasında kullanılacaktır.
- Grup üyelikleri için Öncelikli olasılıklar belirlenir. Daha sonra bu olasılıklar ve diskriminant skorları kullanılarak sonsal olasılıklar elde edilir. Bireyin sahip olduğu en büyük sonsal olasılık tespit edilir. Bu olasılığı veren grubun o bireyin ait olduğu grup olduğu tahmin edilir ve birey sınıflandırılmış olur.
- Her bir birey sınıflandırıldıktan sonra, diskriminant fonksiyonunun başarısı, doğru sınıflandırma yüzdesi incelenerek tespit edilebilir (Özdamar, 2002).

3.2.3.2.7. Lineer Diskriminant Analizi (LDA)

Diskriminant analizinde temel amaç, gruplar arası kareler toplamının, gruplar içi kareler toplamına oranını maksimum yapacak p adet özelliği ayıracak doğrusal bileşeni bulmaktır (Ünal, 2006).

$$F = \max \left(\frac{\text{Gruplar arası kareler toplamı}}{\text{Gruplar içi kareler toplamı}} \right) \quad (3.28)$$

Bu problem istatistiksel olarak şu şekilde gösterilir; p adet nesnenin g adet sınıfa ayrıldığını düşünelim. k . sınıfta N_k adet nesne ve toplam nesne sayısı N olsun. Her nesne için p adet özellik $X_1, X_2, \dots, X_p$ verilmiş olsun. Bu durumda grup ortalama vektörü,

$$\mu_k = \frac{1}{N_k} \sum_{i=1}^{N_k} X_{ik} \quad ; k = 1, 2, \dots, g \quad (3.29)$$

ve genel ortalama vektörü ise,

$$\mu = \frac{1}{N} \sum_{k=1}^g \sum_{i=1}^{N_k} X_{ik} \quad (3.30)$$

şeklindedir. Çok-değişkenli varyans analizinden (MANOVA), toplam çarpımlar ve kareler toplamı,

$$T = \sum_{k=1}^g \sum_{i=1}^{N_k} (X_{ik} - \mu)(X_{ik} - \mu)^T \quad (3.31)$$

gruplar arası çarpımlar ve kareler toplamı,

$$B = \sum_{k=1}^g \sum_{i=1}^{N_k} (\mu_k - \mu)(\mu_k - \mu)^T \quad (3.32)$$

grup içi çarpımlar ve kareler toplamı,

$$W = \sum_{k=1}^g W_k = \sum_{k=1}^g \sum_{i=1}^{N_k} (X_{ik} - \mu_k)(X_{ik} - \mu_k)^T \quad (3.33)$$

şeklindedir. Her üç çarpımlar ve kareler toplamı arasında,

$$T = B + W \quad (3.34)$$

şeklinde bir bağıntı vardır. Bu değerler serbestlik dereceleri bölünürse, toplam varyans, gruplar arası varyans ve gruplar içi varyans aşağıdaki gibi olur.

$$S_X = \left(\frac{1}{N-1} \right) T \quad (3.35)$$

$$S_B = \left(\frac{1}{g-1} \right) B \quad (3.36)$$

$$S_W = \left(\frac{1}{N-g} \right) W \quad (3.37)$$

Diskriminant analizinin temel varsayımından aşağıdaki ölçüt ortaya çıkar;

$$\lambda = \frac{u^T B u}{u^T W u} \quad (3.38)$$

Burada,

$$u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_p \end{bmatrix}_{p \times 1} \quad (3.39)$$

$p \times 1$ boyutlu katsayılar vektörüdür. Lagrange yöntemine göre, λ 'nın sütun vektörü olan u^T 'ye göre kısmi türevi alınarak sıfıra eşitlenir.

$$\frac{\partial \lambda}{\partial u} = \frac{2[(Bu)(u^T Wu) - (u^T Bu)(Wu)]}{(u^T Wu)} = 0 \quad (3.40)$$

(3.46)'daki eşitlik, $u^T Wu = 1$ kısıtlaması kullanılarak (3.47)'deki eşitlik halini alır.

$$Bu - \lambda Wu = 0 \quad (3.41)$$

Bu eşitlik, W matrisinin tersi W^{-1} matrisi ile soldan çarpılırsa, aşağıdaki eşitlik (3.42) elde edilir.

$$(W^{-1}B - \lambda I)u = 0 \quad (3.42)$$

Özdeğer olarak adlandırılan λ 'nın köklerini bulan, her λ değeri için (3.49)'daki denklemin çözümü aranan u vektörünü verir.

$$|W^{-1}B - \lambda I| = 0 \quad (3.43)$$

λ 'nın i . kökü için bulunan vektör u_i ile gösterilirse, i . diskriminant fonksiyonu,

$$f_i = u_i^T X_i \quad (3.44)$$

şeklinde ifade edilir. Buna göre, p tane ayırıcı özellik için, k . gruptaki, n . nesne için diskriminant fonksiyonu,

$$f_{kn} = u_1 X_{1kn} + u_2 X_{2kn} + \dots + u_p X_{pkn} \quad (3.45)$$

şeklini alır.

Burada;

X_i : i. nesnelere ait özellikler ($i = 1, 2, \dots, p$), k. gruptaki ($k = 1, 2, \dots, g$), n. nesne ($n = 1, 2, \dots, N_k$) için değeri,

u_i : diskriminant fonksiyonunun i. katsayısı,

g : sınıf sayısı,

Bu u_i değerleri "istenilen diskriminant fonksiyonunun standart olmayan ham katsayıları" olarak tanımlanır (Ünal, 2006).

Diskriminant fonksiyonlarının yorumunu kolaylaştırması açısından ham katsayılar, dönüşüm yapılarak farklı katsayılara dönüştürülebilir. Bu katsayılar, veri seti standartlaştırılmadan aşağıdaki dönüşümler yapılarak bulunur (Ediz, 1997).

$$v_i = u_i \sqrt{N - g} \quad \text{ve} \quad v_0 = -\sum_{i=1}^p u_i \mu_i \quad (3.46)$$

Dönüşüm işleminden sonra diskriminant fonksiyonu,

$$f_{kn} = v_0 + v_1 X_{1kn} + v_2 X_{2kn} + \dots + v_p X_{pkn} \quad (3.47)$$

şeklinde elde edilir.

Katsayılarda yapılan düzeltme işlemi ile diskriminant fonksiyonlarının eksen merkezi, sistemin merkezi olarak kabul edilen diskriminant fonksiyonlarının tümünün sıfır değeri aldığı noktaya kayar. Bu şekilde herhangi bir nesnenin diskriminant fonksiyonu değerine bakılarak sistem merkezinden ne kadar uzakta ve ne yönde olduğu da belirlenebilir (Klecka, 1987).

Standart olmayan katsayılar, her bir özelliğin sınıflandırma işlemine olan etkilerini gösterir (Ediz, 1997). Hangi değişkenin sınıflandırma etkisinin daha fazla olduğunu sorgulamak için katsayıların mutlak değerine bakılır. Mutlak değerce büyük olan katsayıların sınıflandırmaya etkisi de büyük olacaktır (Poulsen ve French, 2003).

3.2.3.2.8. Lineer Diskriminant Fonksiyonunun Katsayıları

p adet özelliğe sahip nesnelerin lineer ayırımında kullanılacak diskriminant fonksiyonu aşağıdaki şekilde verilir,

$$f_{kn} = v_0 + v_1 X_{1kn} + v_2 X_{2kn} + \dots + v_p X_{pkn} \quad ; i = 1, 2, \dots, k \quad (3.48)$$

Burada;

f_i : i. diskriminant fonksiyonu,

$$v_{ij} = \Sigma^{-1}(\mu_i) \quad ; i = 1, 2, \dots, k \quad ; j = 1, 2, \dots, p \quad (3.49)$$

v_{ij} : doğrusal diskriminant fonksiyonun katsayıları,

Σ^{-1} : Ortak (pooled) varyans-kovaryans matrisinin tersi,

μ_i : i. sınıfının ortalama vektörü, $i = 1, 2, \dots, k$

$$v_{i0} = -\left(\frac{1}{2}\right)(\mu_i)^T \Sigma^{-1}(\mu_i) \quad ; i = 1, 2, \dots, k \quad (3.50)$$

v_{i0} : sabit değer,

μ_i^T : i. sınıfın ortalama vektörünün transpozu, $i = 1, 2, \dots, k$

Diskriminant fonksiyonun karar kuralı,

$$f_i(X_i) = \max \{ f_1(X_i), f_2(X_i), \dots, f_m(X_i) \} \quad ; i = 1, 2, \dots, k \quad (3.51)$$

şeklinde olur.

İki sınıf arasında benzerlik olması durumunda, sadece bir diskriminant fonksiyonu oluşturulabilir. bu diskriminant fonksiyonu ortak diskriminant fonksiyonu olarak adlandırılır. Bu durumda ortak doğrusal diskriminant fonksiyonuna ait katsayılar, şu şekilde bulunur (Sangün, 2007).

$$v_{12} = \Sigma^{-1}(\mu_1 - \mu_2) \quad (3.52)$$

Burada;

v_{12} : birinci ve ikinci bileşen katsayılarının ortak vektörünü,

μ_1 : Birinci sınıfa ait ortalama vektörü,

μ_2 : İkinci sınıfa ait ortalama vektörü,

$$v_0 = \frac{v_{10} + v_{20}}{2} \quad (3.53)$$

v_{10} : Birinci fonksiyona ait sabit değer,

v_{20} : İkinci fonksiyona ait sabit değer,

D_{ij}^2 : Mahalanobis uzaklığı,

Mahalanobis uzaklığı, p adet özelliğe sahip iki nokta arasındaki en büyük uzaklığı veren karesel bir ifadedir. Şu şekilde formüle edilir;

$$d(\mu_1, \mu_2) = D_{ij}^2 = (\mu_1 - \mu_2)^T \Sigma^{-1} (\mu_1 - \mu_2) \quad (3.54)$$

Herhangi bir nesnenin veya yeni bir nesnenin k adet sınıftan hangisine sınıflandırılacağına ait karar verme kuralları ;

$$(\mu_1 - \mu_2) \Sigma^{-1} X_0 \geq \left(\frac{1}{2}\right) (\mu_1 - \mu_2)^T \Sigma^{-1} (\mu_1 + \mu_2) \quad ; \text{ ise birinci sınıfa} \quad (3.55)$$

$$(\mu_1 - \mu_2) \Sigma^{-1} X_0 < \left(\frac{1}{2}\right) (\mu_1 - \mu_2)^T \Sigma^{-1} (\mu_1 + \mu_2) \quad ; \text{ ise ikinci sınıfa} \quad (3.56)$$

sınıflandırılır (Sangün, 2007).

Burada;

X_0 : Herhangi bir nesneye ait özellik vektörüdür (Sharma,1996; Rencher, 2002; Timm, 2002; Özdamar 2004; Velilla ve Hernandez, 2005; Sueyoshi, 2006).

3.2.3.3.Yapay Sinir Ağları


Doğrusal ve özellikle doğrusal olmayan süreçlerde, YSA'nın eşleme, paralellik, öğrenme ve uyarlanma gibi özelliklerinden faydalanılmaktadır. YSA; paralellik özelliğine sahip, algoritmik ve sayısal olmayan bir bilgi işleme sistemidir. Basitçe çok sayıda içten birbirine bağlı yapay sinir hücresi olarak isimlendirilen yapılardan oluşmaktadır ((Taşan, 2008)).

YSA'nın bu sayılan özelliklerinden ötürü, son yıllarda ona karşı ilgi büyük bir artış göstermiştir. Havacılık, otomotiv, bankacılık, savunma sanayi, elektronik, eğlence, finans, endüstri, tıp, robotik, ses, güvenlik ve haberleşme gibi değişik konularda uygulamaları bulunmaktadır.

3.2.3.3.1.Yapay Sinir Ağlarının Temel Özellikleri

Yapay sinir ağları, insan sinir hücrelerinin ve sinir ağının biyolojik yapısından esinlenmiştir. YSA, insan sinir sisteminin en küçük birimi olan sinir hücresine (neuron) benzer elemanlar olan işlem birimlerinden oluşmaktadır. İnsan beyninin çalışması ile benzer özellikler göstermektedir. Örneğin; tecrübe ederek öğrenebilirler, önceden öğrenilmiş bilgilerden tümevarım yapabilirler ve yeni sonuçlar çıkarabilirler. Bu benzerliklere rağmen, YSA'nın yakın bir gelecekte insan beyninin yapabildiği her şeyi yapabileceğini söylemek yanlış olur.

İnsan beyninde yaklaşık 1010 sinir hücresi ve hücre başına da bağlantı sayısının 104 civarında olması beynin çok karmaşık bir yapı olduğunu anlamamız için yeterlidir. Her sinir hücresi kendi bağlantılarından ve diğer sinir hücrelerinden veya dış dünyadan bilgi alabilir. Sinir hücreleri birden fazla çıkış işareti verebilir. YSA'nın fiziksel yapısı basitçe Şekil 3.22'te gösterilmiştir (Taşan, 2008).



Şekil 3.22. Yapay Sinir Ağının Fiziksel Yapısı


3.2.3.3.2.Yapay Sinir Hücresi Modeli

Bir yapay sinir hücresi, bir “t” anında yalnızca bir işaret gönderebilir. Bu işlem esnasında yapay sinir hücresinin girişine gelen işaretler ağırlık katsayıları ile çarpılıp, daha sonra da toplanırlar. Bu durum, Denklem 4.1’ de gösterilmiştir.


$$Net = \sum_{i=1}^n x_i w_i \quad (3.57)$$

Denklem 4.1’de “Net” adı verilen ifade ağırlıklı girişlerin cebirsel toplamıdır. “x” ise girişlerin oluşturduğu vektör, “w” ise ağırlıkların oluşturduğu vektördür.

Her girişin kendi ağırlık değeri vardır. Girişler ağırlık değerleriyle çarpıldıktan sonra toplanırlar ve bu değere eşik değeri eklendikten sonra “f” aktivasyon fonksiyonundan geçirilir (Şekil 3.23). Aktivasyon fonksiyonu olarak genellikle Şekil 3.24’de gösterilen tipler kullanılmaktadır.




Şekil 3.23. Temel yapay sinir hücre yapısı.



Şekil 3.24. Aktivasyon fonksiyonları; (a) Log-sigmoid aktivasyon fonksiyonu, (b) Tan-sigmoid aktivasyon fonksiyonu, (c) Doğrusal aktivasyon fonksiyonu.

Ağ, tek katmanlı olabildiği gibi çok katmanlı da olabilir. Bu durumda, giriş ve çıkış katmanları dışındaki katmanlara gizli katman (hidden layer) denmektedir ve Şekil 3.25'te çok katmanlı algılayıcı ağ yapısı görülmektedir.




Şekil 3.25. Çok katmanlı ağ yapısı.

Giriş ile yapay sinir hücresinin aktivasyon fonksiyonunun işleme tabi tutulması sonucunda bir çıkış elde ederiz. Bu fonksiyon, doğrusal olmayan bir fonksiyondur. Aynı zamanda eşik değeri seçimi “b” ile birlikte bu fonksiyon seçimi yapay sinir hücresinin modelini belirler. Genelde sigmoit fonksiyonu tercih edilir.

YSA, katman olarak adlandırılan bölümlerden oluşmaktadır. Katman sayısı tek ise bu yapılar tek katmanlı ağ, katman sayısı birden fazla ise çok katmanlı ağlar denir (Şekil 3.25). Tek katmanlı ağların çeşitli uygulamalarda sınırlı yetenek gösterdikleri ispatlanmıştır. Çok katlı ağlarda her katmandaki yapay sinir hücresi sayısı farklı olabilir. Araştırmacılar çok katmanlı ağların eğitilmesine izin veren algoritmalar geliştirmişlerdir (Zurada, 1992). Eşlenik gradyan yöntemleri, bu algoritmalarından yaygın olanıdır. Bu algoritma her yaklaşımda arama yapmaktadır. Böylece, her araştırma için ağın girişlere verdiği cevabın defalarca hesaplanması gerekmektedir. Bu çalışmada kullanılan ölçekli-eşlenik gradyan (SCG; Scaled-Conjugate Gradient) yöntemi ile zaman gecikmesine sebep olan yol arama algoritması kullanılmamaktadır (Taşan, 2008).

3.2.3.3.3. Tek katmanlı-ileri beslemeli sinir ağları (FFNN)


Yapay Sinir Ağlarında en basit ağ yapısı, tek katmanlı ileri beslemeli yapay sinir ağıdır. Bu tip ağda, temel katmanlardan olan ara katmanlar yoktur. Ağ sadece bir giriş katmanı ve bir çıkış katmanından oluşur. Bu tip ağın yapısına bir örnek Şekil.3.26’da gösterilmiştir. İleri besleme denmesinin sebebi, bilginin girişten çıkışa doğru ilerlemesidir. Giriş katmanı giren bilgi üzerinde hiçbir işlem yapmadan veriyi çıkış katmanına iletir ve bu yüzden Tek katmanlı olarak isimlendirilir (Bozkurt, 2007).



Şekil 3.26. Tek katmanlı yapay sinir ağı

3.2.3.3.4. Çok katmanlı-ileri beslemeli sinir ağları (MLFFNN)

Çok katmanlı yapay sinir ağları, tek katmanlıdan farklı olarak, giriş ve çıkış katmanları arasında bir veya daha fazla gizli katman (ara katman) içerir. Bu ağın yapısına bir örnek Şekil.3.27’da verilmiştir. Gizli katmanlar giriş ve çıkış katmanları arasında yer alır ve bilgiyi işlemek adına işlemler yaparlar. Giriş katmanı geniş olduğunda gizli katmanlar sayesinde yüksek dereceli istatistiksel bilgi elde edilebilir. Çok katmanlı yapılarda bir katmanın çıkış işaretleri bir sonraki katmana giriş işareti olarak verilir. Eğer bir yapay sinir ağında giriş katmanında m adet giriş düğümü, ilk gizli katmanda h_1 adet nöron, ikinci gizli katmanda h_2 adet nöron ve çıkış katmanında ise q adet nöron var ise, bu çok katmanlı ileri besleme ağına $m-h_1-h_2-q$ ağı denir. Eğer her katman için, bir katmanda bulunan nöronlar bir sonraki katmanın tüm nöronlarına bağlıysa bu tip ağa tam bağlantılı ağ denir. Tersisi durumda ise ağa kısmi bağlantılı ağ adı verilir (Bozkurt, 2007).



Şekil 3.27. Çok katmanlı yapay sinir ağı

3.2.3.4.Olasılıklı Sinir Ağları

Olasılıksal sinir ağı (PNN, Probabilistic Neural Network) bir Bayes sınıflandırıcının parametrik olmayan bir gerçekleştirilmesini göz önünde bulundurabilir. Bilinmeyen şart yoğunlukları Parzen pencereleri kullanılarak tahmin edilir ve Bayes karar kuralı en yüksek olasılığın çıkış kategorisini elde etmek için uygulanır. PNN eğitim verisinin temel dağıtımına göre hiç bir varsayımın yapılmadığı serbest model (modelden bağımsız) bir tahmin edici olarak düşünülebilir (Güllüoğlu, 2007).

3.2.3.4.1.Matematiksel Temel


PNN 'nin temelini teşkil eden fikir Parzen pencerelerini kullanarak bilinmeyen şart yoğunluklarını tahmin etmektir. Parzen'in tekniği verilen bir kategorinin her bir eğitim vektörü çevresinde n-boyutlu bir Gauss fonksiyonu merkezlemektir. Verilen kategorinin doğru olasılık yoğunluk fonksiyonlarının (oyf) bir tahmini olarak bu bireysel gauss servislerinin üstüne konan, ölçekleme (bölüntü) ile ayrılır. n artırımlar ile, tahmin edilen oyf yaklaşımları doğru oyf 'yi verir. Matematiksel olarak, tahmin edilen oyf şu şekildedir;

$$f(x) = \frac{1}{N} \sum_{i=0}^{N-1} e^{-\left(\frac{d(x,y_i)}{p^\sigma}\right)^2} \quad (3.57)$$

Burada σ düz sabittir, $(d(x,y_i))$ saklanmış y_i örneği ve x test örneği arasındaki uzaklıktır, p çok değişkenli örnek(model) vektöründeki bileşenlerin sayıdır ve n ise verilen kategorideki eğitilen kategorilerin sayısıdır. Bu formülasyonun avantajı şudur ki, birkaç örnek oyf temelini teşkil eden, esnek bir tahmin yapmak için gereklidir.

PNN bu tahmin etme sürecinin paralel bir uygulamasıdır. Dağıtma (yayılma) katmanı bir bağlantı noktası gibi temel hizmet verir ve örüntü katmanının nöronları arasında giriş vektörünün elemanlarını yayar. Bu ikinci katman kategori tarafından organize edilir, her bir kategoriden her biri için eğitim örneği bir nöron ile gerçekleştirilir. Her bir örüntü katmanı birimi test vektörü ve saklanmış eğitim vektörü arasındaki öklit uzaklığını hesaplar. Gauss doğrusalsızlığı bu uzaklık ölçümü ile uygulanır. Toplama katmanındaki her bir birim, verilen bir sınıfın örüntü katman çıkışlarını içerir ve ölçekleme (bölünteleme) bu kategoride eğitme örneklerinin sayısının tersi ile toplanır. Toplama katmanının çıkışları

tahmin edilen şart yoğunluklarıdır. Son katman maksimum olasılığın kategorisini belirleyen karar katmanıdır (Güllüoğlu, 2007).



Şekil 3.28. Olasılıksal Sinir Ağı Yapısı

3.2.3.4.2.Eğitme

Eğitme, örüntü vektörlerinin örüntü katman birimlerine doğrudan pay edildiği andır. Kodlamanın meydana gelmediği basit durumdur (Güllüoğlu, 2007).

3.2.3.4.3.Test Etme

Bir test vektörü PNN'ye verildiğinde, kararda güvenilir bir tahmin kadar iyi olan kazanan kategori çıkışı oluşturur. Bu güvenilir tahmin Bayes karar kuralı kullanılarak, tahmin edilen şart yoğunluklarından hesaplanan sonrasal olasılık ile verilir. Tekrar belirtelim ki denk önceseller, karar maksimum olabilirlik kriteri temelindedir ki, o da şart yoğunluklarıdır (Güllüoğlu, 2007).


3.2.3.4.3.Uyarlama

KNN sınıflandırıcısı ile benzer kolay bir şekilde PNN’de uyarlanır. Aynı önemli noktalar göz önüne alınır ve bu nedenle uyarlama algoritması da benzerdir. Bununla birlikte, madem PNN test örüntüsü ve en yakın saklanan prototip arasındaki uzaklık çıkış değilse, bazı ilave hesaplamalar bu minimum uzaklığı bulmak için gereklidir. Diğer bir deyişle, algoritma aynıdır (Güllüoğlu, 2007).

4.BULGULAR ve TARTIŞMA

4.1.Önişleme Yöntemlerinin EMG İşaretlerine Uygulanması

Çoğu biyoelektriksel işarete olduğu gibi EMG işaretlerinin analizinde de öznitelik çıkartma işlemi oldukça büyük bir öneme sahiptir. Bu amaçla yapılan çalışmalar incelendiğinde, çok değişik özellik çıkarım yöntemlerinin kullanıldığı görülmektedir. Kullanılan her özellik çıkarım yönteminin başarımları da değişik olmakta, en iyi sonuç verecek öznitelik yöntemleri irdelenmektedir. (Günay ve Alkan, 2009)




Şekil 4.1. Dört Ayrı Hareketten Alınmış İşlenmemiş EMG Verisi (a) Dirsek Açma (b) Dirsek Kapama (c) Ön Kolu İçe Döndürme (d) Ön Kolu Dışa Döndürme

4.1.1.Ortalama Mutlak Değer (OMD) Yönteminin Kullanılması

Bu çalışmada özellik çıkarımı amacıyla, işaret 32 örneklik pencerelere ayrılıp, her penceredeki örneklerin önce mutlak değerleri sonra da bunların ortalaması alınmıştır. Bu şekilde her işaret bu işlem sonunda 16 adet özellik vektörüyle ifade edilmiştir. Elde edilen özellikler kullanılarak dört tür işaret öbekleştirme işlemine tabi tutulmuştur.

Bu işlemler en uygun ve başarılı sonuç verecek pencere uzunluğunu görebilmek amacıyla, değişik pencereleme uzunlukları için işlemler tekrarlanmıştır. Yapılan denemelerden elde edilen sonuçların birbirine yakın değerler vermekle birlikte, en iyi

sonucun 32 örneklilik pencereleme kullanıldığında elde edildiği görülmüştür (Günay ve Alkan, 2009).



Şekil 4.2. Ayrı Hareketten Alınmış, Pencereleme ile Elde Edilen Ortalama Mutlak Değerler. (a) Dirsek Açma (b) Dirsek Kapama (c) Ön Kolu İçe Döndürme (d) Ön Kolu Dışa Döndürme

4.1.2.Hareketli Averaj Filtresi Yönteminin Kullanılması

Öncelikle tüm EMG verisinin mutlak değeri alınmış, böylece ortalama alma işleminde problem olacak yansıma etkisinden arındırılmıştır. 64 örneklilik pencereleme kullanılmış ve bu pencerenin ortalaması bir değer olarak kaydedilmiştir. Pencere birer birim kaydırılarak 512 örnek uzunluğundaki her bir örüntünün sonuna kadar uygulanmıştır. Elde edilen özellik vektörleri $449(512-64+1)$ örnekten oluşmaktadır. 64 örneklilik pencerelemeler dışında 4,8,16,32 ve 128 örneklilik pencereler de uygulanmış fakat en iyi sonuç 64 örnek için elde edilmiştir.

Bu yöntem OMD'ye göre işaret için daha karakteristik bilgiler vermektedir fakat elde edilen özellik vektörü OMD'den elde edilene göre çok uzun olduğu için öbekleştirme ve sınıflandırma yöntemlerinde işlem yükünü arttırmaktadır.

4.1.3.Özbağlanım Yöntemlerinin Kullanılması

Özbağlanım yöntemlerinden Burg, Yule-Walker, Kovaryans ve İyileştirilmiş Kovaryans'ı kıyaslayabilmek için aynı parametreler kullanılmıştır. Parametre olarak literatürde genellikle 10 katsayı tercih edilse de bu çalışmada en iyi sonuçların 10-20

katsayı için elde edildiği gözlemlenmiştir. İşlem yükü açısından OMD ile kıyaslanabilirliği düşünülerek 16 katsayı tercih edilmiştir (Günay ve Alkan, 2010).


4.1.4.Eğri Uydurma Yönteminin Kullanılması

EMG işaretlerinin işlenmesinde literatürde pek yer bulmayan eğri uydurma yöntemi çalışmada iki şekilde kullanılmıştır. EMG'nin yansıma etkisinden kurtulması için yine mutlak değeri alınmıştır. Daha sonra eğri uydurma algoritması uygulanarak uydurulacak polinomal eğri için 4 katsayı elde edilmiştir. Elde edilen bu katsayılar özellik vektörü olarak kullanılmıştır. Bunun yanında bu 4 sayı yardımıyla 512 örnekten oluşan bir polinom uydurulmuş bu polinom da özellik vektörü olarak kullanılmıştır.

4.2.Öbekleştirme ve Sınıflandırma Yöntemlerinin Özellik Vektörlerine Kullanılması

4.2.1.K-Ortalama Metodunun Kullanılması

Önişleme yöntemleri olarak Ortalama Mutlak Değer kullanılmıştır. Küme sayısı 4 olarak belirtilmiş hesaplama parametresi olarak öklid uzaklığı seçilmiştir. Danışmansız bir öbekleştirici için çok başarılı sayılabilecek %97,25'lik bir başarı elde edilmiştir (Günay ve Alkan, 2009). Bu başarıyı gösteren silüet değerleri şöyledir:



Şekil 4.3. Öbekleştirme İşleminin Başarısını Gösteren Silüet Değerleri

4.2.2.Bulanık C Ortalama Metodunun Kullanılması

Önişleme yöntemleri olarak Ortalama Mutlak Değer, Hareketli Averaaj Filtresi ve Eğri Uydurma yöntemleri kullanılmıştır.Eğri uydurma için kullanılan 4 katsayı ve uydurulan polinoma ait 512 örneklik veriler ayrı özellik vektörleri olarak alınmıştır.

Danışmansız bir öbekleştiricidir. Ortalama 20 iterasyonda bu sonuçlara ulaşmıştır (Alkan ve Günay, Yayınlanmamış).

Çizelge 4.1. Bulanık C Ortalama için başarı oranları

Ortalama Mutlak Değer	%97,50
Hareketli Averaaj Filtresi	%95,75
Eğri Uydurma(4)	%75,25
Eğri Uydurma(512)	%96,50

4.2.3.DVM Sınıflandırıcı Metodunun Kullanılması

Önişleme yöntemleri olarak Özbağlanım Katsayıları ve Ortalama Mutlak Değer kullanılmıştır. Danışmanlı bir yöntem olduğu için EMG veri seti 2-kat çapraz doğrulama yöntemiyle eğitim ve test verisi olmak üzere ikiye ayrılmıştır. Bu yöntemde veri setinin yarısı rastgele olarak seçilmekte, seçilen kısmıyla eğitim yaparken kalan kısmı ise test datası olarak kullanılmaktadır. Daha sonra test datası ve eğitim datası yer değiştirerek işlem tekrarlanmaktadır (Alkan ve Günay, 2010).

OMD önişleme olarak seçildiğinde başarı %99 olurken Özbağlanım katsayıları seçildiğinde ise şöyle olmaktadır:

Çizelge 4.2. AR-DVM ikilisi için sınıflandırma başarıları.

		DVM Sınıflandırıcı
Ön İşleme	Burg Özbağlanım	%94,13
	Yule-Walker Özbağlanım	%92,88
	Kovaryans Özbağlanım	%94,25
	Değiştirilmiş Kovaryans Özbağlanım	%92,63

4.2.4.Diskriminant Analizi Metodunun Kullanılması

Önişleme yöntemleri olarak Ortalama Mutlak Değer kullanılmıştır. Danışmanlı bir yöntem olan Diskriminant analizinin eğitim ve test dataları 10-kat çapraz doğrulama kullanılarak elde edilmiştir. 10-kat çapraz doğrulama yönteminde giriş veri seti 10 alt kümeye ayrılmakta, bu kümelerden her biri sırasıyla eğitim için kullanılırken kalan 9 küme test için kullanılmaktadır (Alkan ve Günay, 2010).

Diskriminant Analizinin ise beş farklı sınıflandırma yöntemi için ayrı sonuçlar elde edilmiştir.

Çizelge 4.3. Diskriminant analizi için başarı yüzdeleri.

Diskriminant Analizi Yöntemleri	Başarı Oranları (%)
Linear	97,75
Diaglinear	97,25
Quadratic	97,75
Diagquadratic	98,00
Mahalanobis	96,00

4.2.5.İleri Beslemeli YSA Metodunun Kullanılması

Önişleme yöntemleri olarak Ortalama Mutlak Değer, Hareketli Averaj Filtresi ve Eğri Uydurma yöntemleri kullanılmıştır. Eğri uydurma için kullanılan 4 katsayı ve uydurulan polinoma ait 512 örneklik veriler ayrı özellik vektörleri olarak alınmıştır. EMG veri setinin ilk yarısı eğitim ikinci yarısı test için kullanılmıştır (Alkan ve Günay, Yayınlanmamış). Test datalarının sınıflandırma sonuçları aşağıdaki gibidir:

Çizelge 4.4. İleri Beslemeli YSA için başarı oranları.

Ortalama Mutlak Değer	92,50%
Hareketli Averaj Filtresi	95%
Eğri Uydurma(4)	95,00%
Eğri Uydurma(512)	95,50%

4.2.6.Olasılıksal Sinir Ağları Metodunun Kullanılması

Önişleme yöntemleri olarak Ortalama Mutlak Değer, Hareketli Averaj Filtresi ve Eğri Uydurma yöntemleri kullanılmıştır. Eğri uydurma için kullanılan 4 katsayı ve uydurulan polinoma ait 512 örneklik veriler ayrı özellik vektörleri olarak alınmıştır. EMG veri setinin ilk yarısı eğitim ikinci yarısı test için kullanılmıştır (Alkan ve Günay, Yayınlanmamış). Test datalarının sınıflandırma sonuçları aşağıdaki gibidir:

Çizelge 4.5. Olasılıksal Sinir Ağları için başarı oranları.

Ortalama Mutlak Değer	87%
Hareketli Averaj Filtresi	95,50%
Eğri Uydurma(4)	97%
Eğri Uydurma(512)	76,50%

5. SONUÇ ve ÖNERİLER

Çizelge 4.6.Önişleme yöntemlerine göre sınıflandırma yöntemlerinin yüzde başarı oranları.

%	K-ME	BCO	DVM	LDA	DLDA	QDA	DQDA	MDA	FFNN	PNN	ORT.
OMD	97	97	99,125	98	97,25	97,5	98	96	95,75	96,75	97,238
HAF	95,75	95,75	98,875	---	97	---	97,75	---	85,714	96,75	95,37
EĞ.K	78,698	91,584	98,125	98,25	95,25	97,75	97,75	98	97,5	72,75	92,566
EĞRİ	96	96	97,75	---	97	---	98	---	97,494	96,5	96,963
AR(BURG)	84,091	84,404	92,625	91,75	84	89,75	84,25	81,5	68,354	81,25	84,197
AR(YULE)	83,036	74,766	92,25	92,75	83	89	82,5	81,25	69,27	81	82,882
AR(KOV.)	71,5	68,954	92,375	93,5	82,75	91,75	82,75	82,5	65,404	81,5	81,298
AR(İ.KOV)	77,855	75,478	91,875	93,5	83	91,25	83,75	81,75	74,745	80,75	83,395
ORT.	85,491	85,492	95,375	94,625	89,906	92,833	90,594	86,833	81,779	85,906	88,883

Çizelge 4.7.Önişleme yöntemlerine göre sınıflandırma yöntemlerinin süreleri(saniye).

	Ö.İ.S.	K-M.	BCO	DVM	LDA	DLDA	QDA	DQDA	MDA	FFNN	PNN	ORT.
OMD	0,269	0,054	0,035	5,28	0,328	0,023	0,029	0,03	0,028	10,12	0,59	1,651
HAF	4,406	0,265	0,267	5,802	---	0,132	---	0,12	---	196,1	1,43	29,16
EĞ.K	0,324	0,065	0,036	5,378	0,034	0,022	0,026	0,023	0,022	7,787	0,457	1,385
EĞRİ	0,021	0,255	0,239	6,184	---	0,137	---	0,125	---	463,6	1,541	67,43
AR(BURG)	0,709	0,656	0,054	4,418	0,033	0,02	0,027	0,025	0,028	8,414	0,439	1,412
AR(YULE)	0,933	0,173	0,045	4,551	0,044	0,02	0,027	0,028	0,028	8,216	0,457	1,359
AR(KOV.)	0,424	0,088	0,05	5,144	0,031	0,023	0,033	0,027	0,027	8,252	0,447	1,412
AR(İ.KOV)	0,655	0,101	0,048	4,559	0,042	0,02	0,03	0,025	0,027	8,944	0,436	1,423
ORT.	0,968	0,207	0,097	5,164	0,085	0,05	0,029	0,05	0,027	88,92	0,725	9,536

EMG işaretlerini ham halleriyle sınıflandırmaya çalışmak başarısız sonuçlar verdiği gibi her örüntüdeki örnek sayısının çok fazla olması sınıflandırma yöntemleri için fazladan işlem yükü getirmektedir. Dolayısıyla sınıflandırma için harcanan zaman da artmaktadır. Bu nedenlerle, işarete ait verilerin en az örnekle işareti en belirgin şekilde tanımlayan özellik vektörleri elde etmek oldukça önemlidir.

Bu amaçla ham EMG örüntülerine birçok işlem uygulanmıştır. OMD kullanımında 512 örneklik örüntüden 16 örneklik bir özellik vektörü elde edilmiştir. Bu da işlem hızını yaklaşık 32 kat arttırmak demektir. Benzer şekilde dört farklı AR yöntemi uygulanmış ve onlardan elde edilen 16 katsayı özellik vektörü olarak kullanıldığından bahsedilen

avantajlar sağlanmıştır. Eğri uydurma yöntemiyle ise 512 örneklik örüntü sadece 4 katsayıyla temsil edilebilmiştir. Ayrıca bu 4 katsayıdan elde edilen 512 örneklik polinomal eğri işlem yükü açısından bir avantaj sağlamasa da ham dataya göre çok daha karakteristik bir özellik vektörü elde edilmesini sağlamıştır. İşlem yükü açısından kayda değer bir etkisi olmayan hareketli averaj filtresi de daha karakteristik sonuçlar vermektedir.

Tüm bu özellik vektörlerini sınıflandırma ve öbekleştirme için kullanılan yöntemler ise genel olarak çok başarılı olmuşlardır. Diskriminant analiz sınıflandırma sonuçlarında çok başarılı olmasının yanı sıra işlem zamanının diğer yöntemlerden kısa olmasıyla diğer yöntemlerden bir adım öndedir. Benzer başarı oranlarını elde eden YSA ve SVMt yöntemleri işlem hızı olarak daha yavaştır. Özellikle YSA çok örnekli özellik vektörleri giriş olarak uygulandığında çok ağır kalmaktadır. PNN ise YSA'dan hızlı olmasına rağmen başarı oranı YSA'dan daha düşüktür. Öbekleştirme Yöntemlerinden olan K-Ortalama ve BCO neredeyse aynı başarı oranlarına sahiptir. Bu iki yöntem de danışmansız yöntemler olduğu için danışmanlı yöntemler kadar başarılı sonuçlar elde etmesi beklenmese de neredeyse onlar kadar başarılı olmuşlardır.

Bu çalışmadaki başarı oranı ve işlem hızı göz önüne alındığında önişleme için OMD ve sınıflandırma için Diskriminant Analizi seçmek protez kollar için sınıflandırıcı seçiminde en uygun yöntemlerdir.

KAYNAKLAR

- Ahmad, S.A., Chappell, P.H. 2007. Surface EMG Classification Using Moving Approximate Entropy. International Conference on Intelligent and Advanced Systems 2007, 1163-1167.
- Alkan, A., Günay, M. 2010. Identification of EMG signals using discriminant analysis and SVM classifier. 1. ISCSE, Kusadası, Aydın, Turkey.
- Alkan, A., Günay, M. Classification of EMG signals using PNN, FFANN and Fuzzy C Means. (Yayınlanmamış).
- Altınbaş, A. 2007. EMG Sinyallerinin Kısa Zamanlı Fourier Dönüşümü ve Dalgacık Dönüşümü Kullanarak Analiz Edilmesi. G.Ü. Yüksek Lisans Tezi, Ankara, 73s.
- Anderson, T.W., Bahadur, R.R. 1962. Classification into two Multivariate Normal Distributions with Different Covariance Matrices. Ann. Math. Statist. ,Vol. 33, 2: 420-431.
- Bozkurt, M.R. 2007. EMG İşaretlerinin Modern Yöntemlerle Önişlenmesi ve Sınıflandırılması. S.Ü. Doktora Tezi, Sakarya, 112s.
- Cai, L., Wang, Z., Zhang, H. 1999. An EMG Classification Method Based on Wavelet Transform. Proceedings of The First Joint BMES/EMBS Conference Serving Humanity, Advancing Technology, 565.
- Cangül, O. 2006. Diskriminant Analizi ve Bir Uygulama Denemesi. Yüksek Lisans Tezi, Uludağ Üniversitesi, Bursa, 70s.
- Chan, F.H.Y., Yang, Y.S.Y., Lam, F.K., Zhang, Y.T., Parker, P.A. 2000. Fuzzy EMG Classification for Prosthesis Control. IEEE Transactions On Rehabilitation Engineering, 8(3):305-311.
- Çamdeviren, H. 2000. Lojistik Regresyon ve Diskriminant Analizi. Doktora Tezi, Ankara Üniversitesi, Ankara, 89s.
- Çevikcan, B. 2007. Bel Fıtığı Hastalığı Bulunan Bireylerin Bel ve Karın Kası Fonksiyonlarının Elektromiyografik Analizi. E.Ü. Yüksek Lisans Tezi, Kayseri, 53s.
- Ediz, B. 1997. Lojistik Regresyon-Ayırma Analizi, Ayırmsama Sorunu ve Kalp Hastalarında Lojistik Model Yardımıyla Risk Ölçütlerinin Belirlenmesi. Doktora Tezi, Uludağ Üniversitesi Sağlık Bilimleri Enstitüsü, Bursa, s.5-42.
- Emin, SE. 1984. Çok Boyutlu Verilerin Bazı İstatistiksel Analiz Yöntemleri ve Uygulamaları. Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, s.51-130.

- Englehart, K. 2001. A Wavelet-Based Continuous Classification Scheme for Multifunction Myoelectric Control. IEEE Transactions On Biomedical Engineering, 48(3):302-311.
- Fisher, R.A. 1936. The Use of Multiple Measurements in Taxonomic Problems. Reproduced with permission of Cambridge University Press, Citation: Annals of Eugenics, 7:179-188
- Güllüoğlu, S.S. 2007. Raslantısal Yapay Sinir Ağlarının Veri Madenciliğinde Kullanılması. Haliç Ü. Yüksek Lisans Tezi, İstanbul, 108s.
- Günay, M., Alkan, A. 2009. EMG İşaretlerinin K-Ortalama Algoritması Kullanılarak Öbekleştirilmesi. KSÜ Mühendislik Bilimleri Dergisi, 12(2).
- Günay, M., Alkan, A. 2010. Spektral Yöntemler ve DVM Sınıflandırıcı ile EMG İşaretlerinin Tasnifi. KSÜ Mühendislik Bilimleri Dergisi, (Baskıda).
- Hu, X., Wang, Z., Ren, X. 2005. Classification of Surface EMG Signal Using Relative Wavelet Packet Energy. Computer Methods and Programs in Biomedicine, 79:189-195.
- Huang, H.P., Liu, Y.H., Liu, L.W., Wong, C.S. 2003. EMG Classification for Prehensile Postures Using Cascaded Architecture of Neural Networks with Self-organizing Maps. International Conference on Robotics & Automation, 1497-1502.
- Johnson, R.A., Wichern, D.W. 1998. Applied Multivariate Statistical Analysis. Prentice Hall, USA.
- Karagülle, F. 2008. Destek Vektör Makinelerini Kullanarak Yüz Bulma. T.Ü. Yüksek Lisans Tezi, Edirne, 75s.
- Khezri, M., Jahed, M., Sadati, N. 2007. Neuro-Fuzzy Surface EMG Pattern Recognition for Multifunctional Hand Prosthesis Control. IEEE, 269-274.
- Klecka, W.R. 1987. Discriminant analysis. Sage Publications, London, UK, p.7-56.
- Kocyigit, Y., Korurek, M. 2005. EMG İşaretlerini Dalgacık Dönüşümü ve Bulanık Mantık Sınıflayıcı Kullanarak Sınıflama. Itüdergisi/d Mühendislik, 4(3):25-31.
- Kwon, J., Lee, S., Shin, C., JANG, Y. 1998. Signal Hybrid HMM-GA-MLP Classifier for Continuous EMG Classification Purpose. Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 20(3):1404-1407.
- Leeuwen, H.P. 1985. The Prediction of Business Failure at Robobank. J. of Bank Research, pp.91-98.
- Lucas M.F., Gaufriau, A., Pascual, S., Doncarli, C., Farina, D. 2008. Multi-Channel Surface EMG Classification Using Support Vector Machines and Signal Based

- Wavelet Optimization Machines and Signal-Based Wavelet Optimization. Biomedical Signal Processing and Control, 3:169-174.
- Mohamed, A.S.A. 1989. An Application of Walsh Functions for EMG Classification. IEEE Engineering in Medicine & Biology Society 11th Annual International Conference, 1027-1028.
- Oskoei, M.A., Hu, H. 2007. Myoelectric Control Systems. Biomedical Signal Processing and Control, 2:275-294.
- Özdamar, K. 2002. Paket Programlar İle İstatistiksel Veri Analizi-2. Kaan Kitabevi, Eskişehir, s.341-394.
- Özdamar, K. 2004. Paket Programlar ile İstatistiksel Veri Analizi (Çok Değişkenli Analizler). Kaan Kitabevi, Eskişehir, 502s.
- Özer, O. 2010. EEG İşaretlerinin Diskriminant Analizi ile Sınıflandırılması. K.S.Ü. Yüksek Lisans Tezi, Kahramanmaraş, 77s.
- Polat, E. 1995. Türk Bankacılık Sisteminde Problemlili Kredileri Önceden Belirleyecek Model Geliştirilmesi İçin Bir Uygulama, Pamukbank T. A. Ş. Eğitim Yayınları, İstanbul, 66s.
- Poulsen, J., French, A. 2003. Discriminant function analysis, Statsoft Electronic textbook, StatSoft, Tulsa.
- Rao, C.R., 1948. Large sample tests of statistical hypotheses concerning several parameters with applications to problems of estimation. Proc. Cambridge Philos. Soc. 44: 50–57
- Rencher, A. L., 2002. Methods of Multivariate Analysis. John Wiley and Sons, Inc., USA, ISBN 0-471-41889-7, 708p.
- Roy, S.N. 1939. p-Statistics or some generalisations in analysis of variance appropriate to multivariate problems, Sankhyā 4 , pp. 381–396
- Sangün, L. 2007. Temel Bileşenler Analizi, Ayırma Analizi, Kümeleme Analizleri Ve Ekolojik Verilere Uygulanması Üzerine Bir Araştırma. Doktora Tezi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, 251s.
- Sharma, S. 1996. Applied Multivariate Techniques. John Wiley and Sons, Inc., USA, ISBN 0.471.31064.6, 493p.
- Subaşı, A., Yılmaz, M., Özcalık, H.R. 2006. Classification of EMG Signals Using Wavelet Neural Network. Journal of Neuroscience Methods, 156:360-367.
- Sueyoshi, T. 2006. DEA- Discriminant Analysis: Methodological Comparison Among Eight Discriminant Analysis Approaches. European Journal of Operational Research, Vol:169, 247-272p.

- Taşan, D. 2008. Protez Denetimi için Elektromiyografi(EMG)de Örüntü Tanıma. E.Ü. Yüksek Lisans Tezi, İzmir, 72s.
- Tatlídil, H. 1996. Uygulamalı Çok Değişkenli İstatiksel Analiz. Akademi Matbaası, ISBN 975-94876-0-8, Ankara, 424s.
- Tatsuoka, M.M. 1976. Discriminant Analysis. Data Analysis Strategies and Designs for Substance Abuse Research, s.201-220.
- Tımm, N.H. 2002. Applied Multivariate Analysis. Springer- Verlag, USA, ISBN 0-387-95347-7, 693p.
- Tümer, M. 2001. Kuzey Kıbrıs Türk Cumhuriyeti İmalat Sanayinde Faaliyet Gösteren Kobileri Ayrıştıran Faktörlerin Tespiti, Doğu Akdeniz Üniversitesi, s:296-303.
- Ünal, M. 2006. Ayırma Analizi Ve Bir Uygulama. Yüksek Lisans Tezi, Gazi Üniversitesi, Ankara, 70s.
- Velılla, S., Hernandez, A. 2005. On The Consistency Properties of Linear and Quadratic Discriminant Analyses. Journal of Multivariate Analysis. Vol:96,219-236p.
- Yang, Y.S., Lam, F.K., Chan, F.H.Y., Zhang, Y.T., Parker, P.A. 1996. A New Fuzzy Approach for Pattern Recognition with Application to EMG Classification. IEEE, 1109-1114.
- Yazıcı, İ. 2008. EMG İşaretlerinin İşlenmesi ve Sınıflandırılması. S.Ü. Yüksek Lisans Tezi, Sakarya, 129s.
- Welch, B. L. 1939. Note on Discriminant Functions. Biometrika, 31:218-220.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı, soyadı : Mücahid GÜNAY
Uyruğu : T.C.
Doğum tarihi ve yeri : 29.08.1984 Kahramanmaraş
Medeni hali : Evli
Telefon : 0 (505) 509 17 38
e-posta : mucahidgunay@gmail.com

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Lisans	Erciyes Ü./ Bilgisayar Müh.	2007
Lise	G.Ş.Aktaş Lisesi (Kahramanmaraş)	2002

İş Denevimi

Yıl	Yer	Görev
2007-2007	Yenişehir Dev.Hast.	Bilgi İşlem Sorumlusu
2007-2010	Kahramanmaraş Bld.	Programcı
2010-2011	KSÜ	Araştırma Görevlisi

Yabancı Dil

İngilizce

Yayınlar ve Bildiriler

1. ALKAN, A., GÜNAY, M. 2010. Identification of EMG signals using discriminant analysis and SVM classifier. 1. ISCSE, Kusadası,Aydın,Turkey.
2. GÜNAY, M., ALKAN, A. 2009. EMG İşaretlerinin K-Ortalama Algoritması Kullanılarak Öbekleştirilmesi. KSÜ Mühendislik Bilimleri Dergisi, 12(2).
3. GÜNAY, M., ALKAN, A. 2010. Spektral Yöntemler ve DVM Sınıflandırıcı ile EMG İşaretlerinin Tasnifi. KSÜ Mühendislik Bilimleri Dergisi, 13(2).
4. ÖZER, O., GÜNAY, M., ALKAN, A. 2010. EEG İşaretlerinin Sınıflandırılması ve Kümelendirilmesi. BMYS-2010, Diyarbakır.