

**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

EMG İŞARETLERİNİN TANI DESTEK AMAÇLI SINIFLANDIRILMASI

DOKTORA TEZİ

Hanife KÜÇÜK

Elektrik-Elektronik Mühendisliği Anabilim Dalı

**EKİM 2015
SAMSUN**



**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

EMG İŞARETLERİNİN TANI DESTEK AMAÇLI SINIFLANDIRILMASI

DOKTORA TEZİ

**Hanife KÜÇÜK
(07210536)**

Tezin Savuma Tarihi : 27 Ekim 2015

Tez Danışmanı : Yrd. Doç. Dr. İlyas EMİNOĞLU

Bu Doktora Tez Çalışması Ondokuz Mayıs Üniversitesi
PYO.MUH.1906.10.001-BAL-LAB' nolu Proje ile Desteklenmiştir.

Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Anabilim Dalında

Hanife Küçük Tarafından Hazırlanan

**EMG İŞARETLERİNİN TANI DESTEK AMAÇLI
SINIFLANDIRILMASI**

başlıklı bu çalışma jürimiz tarafından 27/12/15 tarihinde yapılan sınav ile
DOKTORA tezi olarak kabul edilmiştir.

Başkan : Prof. Dr. Temel Kayıkçıoğlu
Karadeniz Teknik Üniversitesi

Jüri Üyeleri : Prof. Dr. Okan Özgönenel
Ondokuz Mayıs Üniversitesi

Prof. Dr. Kemal Balcı
Ondokuz Mayıs Üniversitesi

Yrd.Doç. Dr. Engin Ufuk Ergül
Amasya Üniversitesi

Yrd.Doç. Dr. İlyas Eminoğlu
Ondokuz Mayıs Üniversitesi

•/..../2015

Prof. Dr. Hüseyin DEMİR

Enstitü Müdürü

Eşime ve oğluma,

ÖNSÖZ

Bu çalışmada, danışmanlığımı yürüten değerli hocam Yrd. Doç. Dr. İlyas Eminoğlu'na, her türlü yardımını esirgemeyen Prof. Dr. Okan Özgönenel' e, Prof. Dr. Kemal Balcı' ya, Yrd. Doç. Dr. Nurettin Şenyer' e, Yrd. Doç. Dr. Ömer Şayli' ye ve maddi manevi desteklerini hiçbir zaman esirgemeyen aileme, bu çalışmamda gösterdikleri anlayıştan dolayı, sevgili eşime ve oğluma çok teşekkür ederim.

Bu çalışma, PYO.MUH.1906.10.001-BAL-LAB numaralı Ondokuz Mayıs Üniversitesi BAP projeleri tarafından desteklenmiştir.

Ekim 2015

Hanife Küçük

(Y. Elektrik – Elektronik Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	v
ÇİZELGELER LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	ix
SİMGELER	xiv
KISALTMALAR	xv
EMG İŞARETLERİNİN TANI DESTEK AMAÇLI SINIFLANDIRILMASI	xvi
ÖZET.....	xvi
CLASSIFICATION OF EMG SIGNALS FOR THE PURPOSE OF	
DIAGNOSIS SUPPORT.....	xvii
ABSTRACT	xvii
1. GİRİŞ	18
1.1 Tezin Amacı	23
1.2 Tezin İçeriği.....	26
1.3 Literatür Araştırması.....	27
2. GENEL BİLGİLER.....	46
2.1 Motor Ünit Aksiyon Potansiyeli (MUAP).....	46
2.1.1 MUAP süresi.....	49
2.1.2 MUAP genliği.....	50
2.1.3 MUAP dalga biçimi	50
2.1.4 Yükselme zamanı.....	51
2.1.5 Dönüş	51
2.1.6 Uydu.....	51
2.2 Sinir - Kas (Nöromusküler) Hastalıklarında MUAP	51
3. MATERYAL VE YÖNTEMLER.....	55
3.1 Veri Edinme Ve Ön İşlem	56
3.2 Bölütleme.....	63
3.2.1 MUAP tepeleri bularak bölütleme.....	63
3.2.2 MUAP' ların başlangıç ve bitiş noktaları bulunarak bölütleme	66
3.3 Kümeleme.....	70
3.3.1 Hiyerarşik (Aşamalı) kümeleme.....	70
3.3.1.1 Tek bağlantılı kümeleme yöntemi	73
3.3.1.2 Tam bağlantılı kümeleme yöntemi	76
3.3.1.3 Ortalama bağlantılı kümeleme yöntemi.....	78
3.3.2 Kendini düzenleyen haritalar (kohonen ağı) ile kümeleme.....	81
3.3.3 Bulanık c-ortalamlar (fuzzy c-means) algoritması ile kümeleme.....	85
3.3.3.1 BCO algoritması ile bölüt doğrulama	87
3.3.4 Melez yapı.....	88
3.3.5 EMG verisinin melez algoritma ile kümelendirilmesi.....	91
3.4 EMG Verisinde Öznitelik Çıkarma	95
3.4.1 Zaman uzayında kullanılan öznitelik vektörleri	95

3.4.1.1	Tümleşik EMG (IEMG).....	95
3.4.1.2	Ortalama mutlak değer (MAV).....	96
3.4.1.3	EMG varyans (VAR)	96
3.4.1.4	Etkin değer (RMS)	96
3.4.1.5	Standart sapma (STD).....	97
3.4.1.6	Sıfır geçiş sayısı (SGS)	97
3.4.1.7	Willison genliği (WAMP).....	97
3.4.2	Frekans uzayında kullanılan öznitelik vektörleri	97
3.4.2.1	Ortalama frekans (MF).....	98
3.4.2.2	Ortanca frekans (MDF)	98
3.4.2.3	Tepe frekans (PKF)	98
3.4.2.4	Ortalama güç (MNP).....	98
3.4.2.5	1.,2. ve 3. dereceden spektral hareket	99
3.4.3	Morfolojik (Şekilsel) öznitelik vektörleri.....	99
3.5	Sınıflandırma	104
3.5.1	Destek vektör makinesi ile sınıflandırma	104
3.5.1.1	Doğrusal ayrılabilirlik durumu	105
3.5.1.2	Doğrusal ayrılamayan durum	109
3.5.1.3	Doğrusal olmayan destek vektör makineleri.....	110
3.5.2	K-En yakın komşu algoritması	115
3.5.3	Diskriminant analiz	118
3.6	Yöntemlerin Geçerliğinin Değerlendirilmesi	120
3.6.1	Alıkoyma yöntemi	120
3.6.2	Çapraz geçerlilik.....	120
3.6.3	Tekrarlı örnekleme	121
3.6.4	Basit geçerlilik.....	122
4.	BULGULAR VE TARTIŞMA	123
5.	SONUÇ VE ÖNERİLER	147
	KAYNAKLAR	152
	EKLER	158
	EK A	159
	EK B	171
	EK B1	171
	EK B2	179
	EK B3	187
	EK C	195
	EK D	199
	ÖZGEÇMİŞ	200

ÇİZELGELER LİSTESİ

Sayfa

Çizelge 1.1. Nöromusküler Bozuklukların Tanısı için EMG Sinyallerinin Sınıflandırılması Alanında Yapılan Bazı Çalışmalar (Yousefi ve Hamilton, 2014).....	32
Çizelge 1.2. Sağlıklı Deltoid Kasından Alınan MUAP' lara ait Morfolojik Değerler (Dobrowolski, ve diğ., 2012).....	38
Çizelge 1.3. Dalgacık Analizi (Dobrowolski, ve diğ., 2012).....	38
Çizelge 1.4. Deltoid Kası için Sınıflandırma Sonuçları (Dobrowolski, ve diğ., 2012).....	38
Çizelge 2.1. Sinir-Kas Hastalıklarında sınıflandırma (Ertekin, 2006).....	52
Çizelge 2.2. Nörojenik / Miyojenik EMG Ayrımı (Ertekin, 2006)	54
Çizelge 3.1. İki Boyutlu Veri Setine Ait Öklid Uzaklık Vektörünün Karesel Formu	74
Çizelge 3.2. Öklid Uzaklık Vektörünün Karesel Formu	75
Çizelge 3.3. Öklid Uzaklık Vektörünün Karesel Formu	75
Çizelge 3.4. Öklid Uzaklık Vektörünün Karesel Formu	75
Çizelge 3.5. Şekil 3.22' deki Veri Setine Ait Öklid Uzaklık Vektörünün Karesel Formu (Patil, 2007).....	77
Çizelge 3.6. Öklid Uzaklık Vektörünün Karesel Formu	77
Çizelge 3.7. Öklid Uzaklık Vektörünün Karesel Formu	77
Çizelge 3.8. Şekil.3.22' teki Veri setine Ait Öklid Uzaklık Vektörünün Karesel Formu.....	79
Çizelge 3.9. Öklid Uzaklık Vektörünün Karesel Formu	79
Çizelge 3.10. Öklid Uzaklık Vektörünün Karesel Formu	79
Çizelge 3.11. Kernel Fonksiyonları	112
Çizelge 3.12. İki Boyutlu Veri	116
Çizelge 3.13. İki Boyutlu Verileri Uzaklık Değerlerine Göre Sıralama.....	117
Çizelge 4.1. Aynı Veri Setini Kullanan Çalışmaların Karşılaştırılması	126
Çizelge 4.2. Zaman ve Frekans Uzayında Öznitelik Vektörleri	128
Çizelge 4.3. Başarım Değerlendirme	146

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.1. Miyojenik ve Nörojenik Rahatsızlıklarda MUAP (Dobrowolski, ve diğ., 2012).....	19
Şekil 1.2. Sinir İletim Hızının Ölçümünü Gösteren Temsili Resim	21
Şekil 1.3. (A), (B) EMG Ölçümü Sembolik Gösterimi	21
Şekil 1.4. Normal EKG işareti (URL-2,2015)	22
Şekil 1.5. Ticari (Avrupa, Amerika ve vb.) Firmaların Ürettiği EMG Cihazları	25
Şekil 1.6. Farklı Açılardan “EMG Cihazı Prototipi” Fotoğrafları	26
Şekil 1.7. Ham EMG Verisinin İşlenmesi ile Elde Edilen MUAP’ lar (De Luca, 2011).....	28
Şekil 1.8. MUAP’ ların Nicel Ölçümü İçin Şematik Görünüm (Dorfman ve McGill, 1988).....	29
Şekil 1.9. Ayrıştırılan MUAP’ ların Nümerik Ve Grafiksel Olarak Gösterimi (Dorfman ve diğ.,1988)	30
Şekil 1.10. Üç Aşamalı Ayrıştırma (Nikolic, 2001)	31
Şekil 1.11. Motor Birim Ateşleme Deseni (Nikolic, 2001)	31
Şekil 1.12. ÇKA ve DVM ait ROC eğrisi (Guler & Koçer, 2005)	33
Şekil 1.13. Önerilen Sistemin Blok Diyagramı (Subasi, 2012)	34
Şekil 1.14. Önerilen Sistemin Blok Diyagramı (Subasi, 2013)	34
Şekil 1.15. Sınıflandırıcı Başarımının Grafiksel Gösterimi (Subasi, 2013)	34
Şekil 1.16. EMG Sınıflandırma ve Ayrışma Sisteminin Akış Şeması (Christodoulou, ve Pattichis, , 1999).	35
Şekil 1.17. Bölütleme Sonucunda Elde Edilen 6 ms Süreli EMG Verileri.....	36
Şekil 1.18. Üç Farklı Sınıfa Ayrılmış Benzer Şekilli MUAP’ lar	36
Şekil 1.19. EMG sınıflandırma Akış Şeması (Bhardwaj, ve diğ., 2012).....	36
Şekil 1.20. Aynı Morfolojik Parametreler ile Karakterize Edilen Farklı MUAP Şekilleri (Dobrowolski ve diğ., 2012)	38
Şekil 1.21. Dalgacık Analizi Sonucu Elde Edilen MUAP	39
Şekil 1.22. (a) MUAP’ ların Başlangıç Ve Bitiş Noktaları Bulunarak Bölütleme ve (b) ADD Kullanarak Bölütleme (Kaur ve diğ., 2009).....	39
Şekil 1.23. Sağlıklı, ALS ve Miyopati Kişilere Ait Verilerin Otokorelasyon Değerlerinin Ortalama Değişimi (Fattah, ve diğ., 2012).....	40
Şekil 1.24. İleri Beslemeli Hata Geri yayımlı YSA ve Bileşik Sinir Ağları Topolojisi (Bozkurt, 2007)	41
Şekil 1.25. Melez Sınıflandırıcı (Maboud ve diğ., 2015)	42
Şekil 1.26. yEMG Örüntü Tanıma Öbek Çizgesi (Chu ve diğ., 2006).....	43
Şekil 1.27. Statik El Hareketleri İle Gerçek Zamanlı El Denetimi (Chu ve diğ., 2007)	44
Şekil 1.28. Tekli ve Çoklu Öznitelik Vektörlerinin Başarımları (Oskoei, 2008)	45

Şekil 1.29. Zaman, Frekans ve Çoklu Öznitelik Vektörlerinin Başarımları (Oskoei, 2008).....	45
Şekil 2.1. Motor Birim Aksiyon Potansiyeli.....	47
Şekil 2.2. İğne elektrotlar.....	47
Şekil 2.3. MUAP Parametreleri	48
Şekil 2.4. Klinik Koşullarda Elde Edilen MUAP' lar (Nikolic, 2001).....	49
Şekil 2.5. Faz sayısına göre MUAP' ların Adlandırılması (Ertekin, 2006).....	50
Şekil 2.6. A-Normal, B-Nöron 2'de Dejenerasyon, C-Nöron 1'de Reinnervasyon ve MUAP Alanında Genişleme, Polifazi Artışı (Uludağ, 2002).....	52
Şekil 2.7. Sağlıklı, Nöropati ve Miyopati Hastalığının Şekilsel Gösterimi (Weiss, 2004).....	53
Şekil 2.8. Sağlıklı, Nöropati ve Miyopati Hastalığının MUAP Gösterimi (Weiss, 2004).....	53
Şekil 3.1. Öbek Çizgesi.....	55
Şekil 3.2. EMGLAB internet sayfası (URL-3, 2011)	56
Şekil 3.3. Çeşitli Kas Grupları	57
Şekil 3.4. ALS, Sağlıklı ve Miyopati Hastasına Ait EMG Verileri	58
Şekil 3.5. ALS, Sağlıklı ve Miyopati Hastasına Ait EMG Verileri	59
Şekil 3.6. EMG İşaretinin Frekans Tayfı	61
Şekil 3.7. EMG İşaretinde Dalgalanmaya Neden Olan Düşük Frekanslı Gürültü....	61
Şekil 3.8. İzoelektrik Çizgideki Dalgalanmanın Giderilmesi	62
Şekil 3.9. Butterworth ve Cheybshev Süzgeç ile Süzgeçlenmiş EMG İşareti.....	63
Şekil 3.10. Eşiği Aşan Tepeler.....	64
Şekil 3.11. Eşiği Aşan MUAP Tepeleri	65
Şekil 3.12. EMG İşaretindeki MUAP' lar	65
Şekil 3.13. Bölütleme Sonucunda Elde Edilen 30 ms Süreli MUAP' lar.....	66
Şekil 3.14. Eşiği Aşan MUAP Tepeleri	67
Şekil 3.15. Başlangıç ve Bitiş Noktasına Aday Olacak Nokta	67
Şekil 3.16. MUAP' ın Başlangıç ve Bitiş Noktaları	68
Şekil 3.17. Bölütleme Sonucunda Elde Edilen MUAP' lar	69
Şekil 3.18. Bölütleme Sonucunda Elde Edilen MUAP' ların Üst Üste Getirilmesi ..	69
Şekil 3.19. Ağaç Veri Yapısı	70
Şekil 3.20. Birleştirici ve Ayrıştırıcı Hiyerarşik Kümeleme Algoritmalarının Genel Çalışması (Gan, ve diğ., 2007)	71
Şekil 3.21. Tek Bağlantılı Kümeleme Yöntemi (Patil, 2007).....	74
Şekil 3.22. İki Boyutlu Veri Seti (Gan, ve diğ., 2007)	74
Şekil 3.23. Tek Bağlantılı Kümeleme Yöntemi Kullanılarak Elde Edilmiş Ağaç Veri Yapısı.....	76
Şekil 3.24. Tam Bağlantılı Kümeleme Yöntemi (Patil, 2007).....	76
Şekil 3.25. Tam Bağlantılı Kümeleme Yöntemi Kullanılarak Elde Edilmiş Ağaç Veri Yapısı.....	78
Şekil 3.26. Ortalama Bağlantılı Kümeleme Yöntemi (Patil, 2007)	78
Şekil 3.27. Ortalama Bağlantılı Kümeleme Yöntemi Kullanılarak Elde Edilmiş Ağaç Veri Yapısı.....	80
Şekil 3.28. Belirli Eşik Değerlerine Göre Elde Edilen Kümeler (Winslow, 2008) ..	80
Şekil 3.29. Ağaç Veri Yapısı ve Belirli Eşik Değerlerine Karşılık Elde Edilen Kümeleme Sonuçları	81
Şekil 3.30. Kohonen Ağ Yapısı.....	82

Şekil 3.31. Kendini Düzenleyen Haritalar (Kohonen Ağı) ile Kümeleme Kullanılarak Farklı Yarıçap Değerlerine Karşılık Elde Edilen Merkez (Küme) Sayıları	84
Şekil 3.32. Kendini Düzenleyen Haritalar ile Kümeleme Kullanılarak Belirli Eşik Değerlerine Karşılık Elde Edilen Küme Sayıları	85
Şekil 3.33. BCO Algoritması ile Elde Edilen Küme Merkezleri	87
Şekil 3.34. Melez Algoritmanın Akış Şeması	89
Şekil 3.35. Kohonen Ağı ve BCO Algoritması ile Kümeleme	90
Şekil 3.36. Melez Algoritma ile Kümeleme	90
Şekil 3.37. ALS Hastasına Ait MUAP' ların Melez Algoritma ile Kümelenendirilmesi	92
Şekil 3.38. ALS Hastasına Ait MUAP' ların Melez Algoritma ile Kümelenendirilmesi	93
Şekil 3.39. ALS Hastasına Ait MUAP' ların Melez Algoritma ile Kümelenendirilmesi	94
Şekil 3.40. Normal, Nöropati Ve Miyopati Hastası Kişilere Ait Olan MUAP' lar (Nikolic, 2001)	100
Şekil 3.41. Sağlıklı Kişiye Ait MUAP	101
Şekil 3.42. ALS Hastasına Ait MUAP	102
Şekil 3.43. Miyopati Hastasına Ait MUAP	103
Şekil 3.44. Doğrusal Ayrım Fonksiyonu	104
Şekil 3.45. Doğrusal Sınıflandırma	105
Şekil 3.46. Birden Fazla Hiper-Düzlem	105
Şekil 3.47. En İyi Hiper-düzlem	106
Şekil 3.48. En Geniş Sınıra Sahip Ayrıcı Hiper-Düzlem	107
Şekil 3.49. Doğrusal Ayrılamayan Durum	109
Şekil 3.50. Doğrusal Olmayan Haritalama	111
Şekil 3.51. Verilerin Giriş Uzayından Özellik Uzayına Aktarımı	111
Şekil 3.52. İki Boyutlu Giriş Uzayından Üç Boyutlu Özellik Uzayına Dönüşüm ..	111
Şekil 3.53. Özellik Uzayında Vektörel İç Çarpım	112
Şekil 3.54. DVM Ağ Yapısı	113
Şekil 3.55. XOR Örneği	115
Şekil 3.56. K-En Yakın Komşu Algoritması ile Sınıflandırma	116
Şekil 3.57. (8,4) Noktasına En Yakın 4 Komşu	118
Şekil 3.58. Diskriminat Analizi (Tatlıdil, 1996)	119
Şekil 3.59. Diskriminat Fonksiyonları a)DDF b)KDF	119
Şekil 3.60. Alıkoyma Yöntemi (Gutierrez, 2010)	120
Şekil 3.61. Çapraz Doğrulama (Gutierrez, 2010)	121
Şekil 3.62. Tekrarlı Örnekleme (Gutierrez, 2010)	122
Şekil 3.63. Basit Geçerlilik (Gutierrez, 2010)	122
Şekil 4.1. ALS, Miyopati ve Sağlıklı Kişilere Ait Verilerin RMS Öznitelik Vektörlerinin Ortalama Değer Değişimi	128
Şekil 4.2. ALS- Sağlıklı Sınıflandırmada Zaman Düzlemindeki Öznitelik Vektörlerinin Başarımları	129
Şekil 4.3. ALS- Sağlıklı Sınıflandırmada Frekans Düzlemindeki Öznitelik Vektörlerinin Başarımları	130
Şekil 4.4. ALS- Sağlıklı Sınıflandırmada Nicel MUAP Parametreleri İle Elde Edilen Morfolojik Öznitelik Vektörlerinin Başarımları	131
Şekil 4.5. ALS- Sağlıklı Sınıflandırmada Çoklu Öznitelik Vektörlerinin Başarımları	132

Şekil 4.6. ALS- Miyopati Sınıflandırmada Zaman Düzlemindeki Öznitelik Vektörlerinin Başarımları	133
Şekil 4.7. ALS- Miyopati Sınıflandırmada Frekans Düzlemindeki Öznitelik Vektörlerinin Başarımları	134
Şekil 4.8. ALS- Miyopati Sınıflandırmada Nicel MUAP Parametreleri ile Elde Edilen Morfolojik Öznitelik Vektörlerinin Başarımları	135
Şekil 4.9. ALS- Miyopati Sınıflandırmada Çoklu Öznitelik Vektörlerinin Başarımları	136
Şekil 4.10. Miyopati-Sağlıklı Sınıflandırmada Zaman Düzlemindeki Öznitelik Vektörlerinin Başarımları	137
Şekil 4.11. Miyopati-Sağlıklı Sınıflandırmada Frekans Düzlemindeki Öznitelik Vektörlerinin Başarımları	138
Şekil 4.12. Miyopati-Sağlıklı Sınıflandırmada Nicel MUAP Parametreleri ile Elde Edilen Morfolojik Öznitelik Vektörlerinin Başarımları	139
Şekil 4.13. Miyopati-Sağlıklı Sınıflandırmada Çoklu Öznitelik Vektörlerinin Başarımları	140
Şekil 4.14. ALS-Sağlıklı Sınıflandırmada Zaman, Frekans ve Çoklu Öznitelik Vektörlerinin Başarımları	141
Şekil 4.15. ALS-Miyopati Sınıflandırmada Zaman, Frekans ve Çoklu Öznitelik Vektörlerinin Başarımları	142
Şekil 4.16. Miyopati-Sağlıklı Zaman, Frekans ve Çoklu Öznitelik Vektörlerinin Başarımları	143
Şekil 4.17. İkili Sınıflandırmada Öznitelik Vektörü RMS Olması Durumunda DVM- Doğrusal ve DVM-RTF Algoritmalarının Oluşturduğu Sınır Hatları	144
Şekil 4.18. Çoklu Öznitelik Vektörleri için DVM, K-EYK ve DA Sınıflandırıcılarının Başarımlarının Karşılaştırılması	145
Şekil 5.1. Prototip EMG Cihazı	150
Şekil 5.2. Dört Kanallı EMG Cihazı	150
Şekil 5.3. Anatomik Eğitim Maketi (URL-1, 2015)	151
Şekil B.1. ALS Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri	172
Şekil B.2. ALS Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri	174
Şekil B.3. ALS Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri	176
Şekil B.4. ALS Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri	178
Şekil B.5. Sağlıklı Kişiye Ait EMG Verisinin (a) 8 Sn' lik (b) 1sn' lik Görüntüleri	180
Şekil B.6. Sağlıklı Kişiye Ait EMG Verisinin (a) 8 Sn' lik (b) 1sn' lik Görüntüleri	182
Şekil B.7. Sağlıklı Kişiye Ait EMG Verisinin (a) 8 Sn' lik (b) 1sn' lik Görüntüleri	184
Şekil B.8. Sağlıklı Kişiye Ait EMG Verisinin (a) 8 Sn' lik (b) 1sn' lik Görüntüleri	186
Şekil B.9. Miyopati Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri	188
Şekil B.10. Miyopati Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri	190

Şekil B.11. Miyopati Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri	192
Şekil B.12. Miyopati Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri	194
Şekil C. 1. ALS Hastasına Ait MUAP' ların Melez Algoritma İle Kümelenendirilmesi	195
Şekil C. 2. ALS Hastasına Ait MUAP' ların Melez Algoritma İle Kümelenendirilmesi	196
Şekil C. 3. ALS Hastasına Ait MUAP' ların Melez Algoritma İle Kümelenendirilmesi	197
Şekil C. 4. Miyopati Hastasına Ait MUAP' ların Melez Algoritma İle Kümelenendirilmesi	198
Şekil D. 1. Konsantrik İğne Elektrot.....	199
Şekil D. 2. Yüzey Elektrot	199

SİMGELER

N	: Örnek sayısı
$d(i,j)$	: Uzaklık ölçüsü
C, C'	: Kümeler
$d(x,y)$	: x ve y noktaları arasındaki uzaklık
α	: Öğrenme oranı
w_i	: Ağırlık vektörü
x_i	: i . veri
c_j	: j . kümenin merkezi
u_{ij}	: Üyelik değerleri
c_j	: Küme merkezleri
ε_{CLU}	: Sonlandırma kriteri
M	: Güç spektral yoğunluğunun uzunluğu
f_j	: j . frekanstaki spektrum frekansı
P_j	: j . frekanstaki EMG güç spektrum değeri
H	: BCO için bölüm doğrulama kriteri
ξ	: DVM de gevşek değişkenler
$K(x_i, x_j)$	: Çekirdek işlevi
α_i	: Lagrange çarpanları
w_0	: Eşik vektörü
w	: Ağırlık vektörü
b	: Sapma değeri
M	: Mesafe
$J(w)$	: Amaç Fonksiyonu
C	: Ceza faktörü
Φ	: Dönüşüm fonksiyonu
S	: Ortak kovaryans matrisi
b_j	: DA Algoritmasında katsayılar vektörü
b_{io}	: DA Algoritmasında sabit değer
b_{ij}	: DA Algoritmasında doğrusal bileşenleri
k	: Çapraz geçerlilik yöntemi için grup sayısı
K	: K-EYK algoritması için komşuluk değeri

KISALTMALAR

ALS	: Amyotrofik Lateral Skleroz
AR	: Özbağlanımlı
BDVM	: Bulanık Destek Vektör Makinesi
BCO	: Bulanık C-Ortalamlar
BSA	: Bileşik Sinir Ağları
DA	: Diskriminant Analiz
DVM	: Destek Vektör Makinesi
DTSA	: Dalgacık Tabanlı Sinir Ağı
ADD	: Ayrık Dalgacık Dönüşümü
EMG	: Elektromiyogram
IEMG	: Tümüleşik EMG
K-EYK	: K-En Yakın Komşu
KDA	: Karesel Diskriminant Analiz
MDF	: Ortanca Frekans
ÇKA	: Çok Katmanlı Algılayıcı
MF	: Ortalama Frekans
MAV	: Ortalama Mutlak Değer
MNP	: Ortalama Güç
MUAP	: Motor Ünite Aksiyon Potansiyeli
KKT	: Karush-Kuhn-Tucker
DDA	: Doğrusal Diskriminant Analiz
ÖDH	: Öz Denetleyici Harita
STD	: Standart Sapma
DVM	: Destek Vektör Makinesi
PKF	: Tepe Frekans
PSO-DVM	: Parçacık Sürüsü Optimizasyonu ve DVM
TBA	: Temel Bileşenler Analizi
TTP	: Toplam Güç
RBF	: Radyal Tabanlı Fonksiyon
RTF	: Radyal Tabanlı Fonksiyonu
RTA	: Radyal Tabanlı Ağ
UBKS	: Uyarlamalı Bulanık K-EYK Sınıflandırıcı
UKS	: Uyarlamalı Kesinlik Sınıflandırıcısı
VNÖ	: Vektör Nicemlendirmeli Öğrenme
WAMP	: Willison Genliği
YSA	: Yapay Sinir Ağı
SGS	: Sıfır Geçiş Sayısı

EMG İŞARETLERİNİN TANI DESTEK AMAÇLI SINIFLANDIRILMASI

ÖZET

Bu tezde amaçlanan; EMG işaretlerini nöromüsküler rahatsızlığı olan veya olmayan şeklinde sınıflandıran bir sistemi tasarlamak ve bölümde tasarımı tamamlanan prototip EMG cihazına entegre edilebilecek gerçek zamanlı çalışan bir yazılımın alt yapısı ve ön hazırlığını oluşturmaktır.

Bu çalışmada kas ve sinir (nöromüsküler) hastalıkların en yaygın çeşidi olan ALS (Amyotrofik Lateral Skleroz) ve miyopati hastalıklarının teşhisi için beş işlem aşamasından oluşan bir sınıflandırma yapısı önerilmiştir. EMG (Elektromiyogram) işaretleri, ön işlem, bölütleme, kümeleme, öznitelik çıkarma ve sınıflandırma aşamalarından geçirilmiştir. Kümeleme aşamasında hiyerarşik ve melez kümeleme yöntemleri denenmiştir. Sonrasında zaman, frekans uzayındaki öznitelikler, morfolojik öznitelikler ve bunların farklı birleşimleri ile elde edilen çoklu öznitelik vektörleri olmak üzere 25 adet öznitelik vektörü kullanılmıştır. Sınıflandırma aşamasında ise Destek Vektör Makinesi (DVM), K-En Yakın Komşu (K-EYK) algoritması ve Diskriminant Analiz (DA) algoritmaları denenmiştir. Doğrulama ölçütü olarak çapraz geçerlilik yöntemi kullanılmıştır, çapraz geçerlilikte k değeri 10 seçilmiştir. Deneysel sonuçlar melez kümeleme algoritmasının sınıflandırma doğruluğunu arttırmada hiyerarşik kümelemeye göre daha iyi olduğunu; önerilen öznitelik vektörleri arasında çoklu öznitelik vektörlerinin tekli öznitelik vektörlerine göre daha başarılı olduğunu göstermiştir. Çoklu öznitelik vektörlerinin kullanılması durumunda DVM sınıflandırıcı, K-EYK ve DA sınıflandırıcılarına göre EMG işaretlerini daha yüksek doğrulukla sınıflandırmıştır. Toplam doğruluk ALS için %97.39 iken miyopati olanlar için %86.74' tür. Bu çalışma ile sınıflandırma başarımının öznitelik vektörünün sınıflar arası ayrılabilirliğinin yüksek derecede olmasına bağlı olduğu anlaşılmıştır.

Anahtar Kelimeler: EMG; ALS; DVM; K-EYK; DA

CLASSIFICATION OF EMG SIGNALS FOR THE PURPOSE OF DIAGNOSIS SUPPORT

ABSTRACT

The purpose of this thesis is to design a system which can classify the EMG signals for the diagnosis of neuromuscular disorders and to make preliminary preparations for a real time software system which can be integrated to the prototype EMG system developed in our department.

This study proposes a classification structure consisting of five stages for the automatic diagnosis of the neuromuscular disease of ALS (Amyotrophic Lateral Sclerosis) and myopathy being a muscular disease. EMG (electromyogram) signals are passed through pre-processing, segmentation, clustering, feature extraction and classification stages. Hierarchical and hybrid clustering methods were tested in the clustering stage. Following this, feature vectors containing time domain parameters, frequency domain parameters, morphological parameters as well as feature vectors composed of combination of these parameters (a total of 25 feature vectors) were used. In the classification stage, Support Vector Machines (SVM), K-Nearest Neighbors (K-NN) and Discriminant Analysis (DA) algorithms were employed. Cross-validation method was chosen to be the verification measure. 10 was the used k-value parameter for the cross-validation. Experimental results showed that the pre-processing step of hybrid clustering algorithm was better in terms of the final classification accuracy of the proposed algorithm than the hierarchical clustering; and among the proposed feature vectors, multiple feature vectors proved to be more successful compared to the individual feature vectors. When multiple feature vectors are used; SVM classifier algorithm classified the EMG signals with higher accuracy than the K-NN and DA classifiers. Total accuracy was 97.39% for ALS and 86.74% for the myopathy. It is understood with this study; the classification performance depends highly on separability of feature vectors between different classes.

Key Words: EMG; ALS; SVM; K-NN; DA


1. GİRİŞ

Elektromiyogram (EMG), kasın kasılmasıyla meydana gelen elektrokimyasal olaylar sonucu ortaya çıkan biyopotansiyel işaretlerdir. Elektromiyografi ise, kasların kasılmasını sağlayan elektriksel aktivitenin izlendiği ve yorumlandığı bir kas incelemesidir. Kasların kasılması sinirler aracılığıyla beyinden iletilmiş olan uyarıcı potansiyellerin kaslarda oluşturduğu Motor Ünite Aksiyon Potansiyelleri (MUAP) olarak bilinen elektriksel potansiyeller sayesinde olur. Kasılmanın miktarı MUAP'ların sayısının ve sıklığının artması ile artar. Kasların kasılı olmadığı veya kasılı olduğu durumlarda MUAP'ların incelenmesi, şeklinin, sıklığının normal sınırlar içinde olup olmaması veya normalde karşılaşılmayan elektriksel aktivitelere rastlanması kaslardaki sorunları belirlemek için incelenen değişkenlerdir (Özkaya, 2005).

Tıpta birçok uygulama alanında kendine yer bulan EMG işaretleri özellikle kas ve sinir davranışlarının incelenmesinde aktif rol oynamaktadır. Sinir cerrahisinde, kaza cerrahisinde, sinir ağrısı (nevralji) ve ortopedide elektromiyografi günümüzün tanı metodunu oluşturmaktadır. Doktor bu metotla metabolizma hastalıklarında kas ve sinirlerin uyarılma bozukluklarını görebilir, aynı zamanda çevresel (periferik) sinir ve kasların hastalıklı durumunu kliniksel belirtiler ortaya çıkmadan önce kanıtlayabilir. Bu ölçümlerin doğru olması ve tam değerlendirilmesi için teknik bakımdan çok karmaşık cihazlar gerekmektedir. İğne veya yüzey elektrotlarıyla elde edilen EMG işaretlerinin incelenmesi ile teşhise ve/veya tedavi yöntemine ulaşmaya çalışılır (Özkaya, 2005).

EMG tıbbi ölçüm sistemidir, doktorların işlerini kolaylaştırmak amacı ile kullanılmaktadır. Bazı hastalıkların teşhisinde, EMG ölçümleri gerekmektedir. Bu hastalıkların başında nöropati ve miyopati gelmektedir. EMG işaretindeki MUAP'lar kas ve sinir hastalıkları tanısı için önemli bilgi sunarlar. EMG işaretlerinden gerekli olan bilgileri çıkarmak için; EMG işaretindeki MUAP'lar belirlenir. Belirlenen MUAP'lar arasından benzer olanlar kümelenir. Kümelenmiş MUAP'ların öznitelik vektörleri çıkarılır. Hastalığa göre MUAP'lar sınıflandırılır.

Nörojenik ve miyojenik hastalıklara ait MUAP' ların belirli özellikleri hastalıkların teşhisi için önemli bilgiler sunmaktadır (Şekil 1.1). Örneğin miyojenik durumda kas liflerinin kaybı söz konusu olduğu için MUAP' lar kısa süreli ve düşük genliklidir. Nörojenik rahatsızlıkta ise sinir kaybı olması sebebiyle uzun süreli yüksek genlikli çok fazlı patalojik değişimler görülmektedir (Dobrowolski, ve diğ., 2012).




Şekil 1.1. Miyojenik ve Nörojenik Rahatsızlıklarda MUAP (Dobrowolski, ve diğ., 2012)

EMG testinin tarihi neredeyse 100 yıl öncesine dayanmaktadır. Son 20-30 yılda, eskiden yapılan basit kas ve sinir ölçümlerine modern tıbbın gelişimine paralel olarak çok sayıda yeni test eklenmiştir. Tetkik artık otomatik cihazlar ile eskiye oranla çok daha kısa sürede yapılabilmektedir. EMG cihazı sinir sistemi ve kas hastalıklarının tanısını koymak için kullanılan özel bir cihazdır. EMG sinir iletim incelemeleri ve iğne EMG olmak üzere iki ana incelemeden oluşur. Bu testlerde kendi aralarında farklı testleri içerir. EMG çekimini yapan doktor hangi hastaya hangi testlerin yapılacağına karar verir. İğneli test her hastaya uygulanmamaktadır. Sinir iletimleri incelemesi düşük voltajlı ve çok kısa süreli elektriksel uyarımlar ile gerçekleştirilir. Temel olarak sinirdeki elektriksel akım hızını ölçme işlemlerinin tamamına denir. Bu sayede hareket ve duyu sinirlerinin fonksiyonları test edilir. Şekil 1.2' de Sinir iletim hızının ölçümü sembolik olarak verilmiştir. İğne EMG' si ise kasların ince bir iğne elektrot batırılarak incelediği hem kasın kendisi hem de o kası çalıştıran sinir yapıları hakkında bilgi veren bir testtir (Bahadır, 2015). Şekil 1.3' de EMG ölçümü sembolik gösterimleri verilmiştir.


EMG testi bel ve boyun fıtıklarında, kas hastalıkları (miyopati, musküler distrofiler), sinir hastalıkları, sinir sıkışmaları, sinir kesilmeleri, siyatik sinir zedelenmelerinde, sinir kas geçişi hastalıkları, omurilik hastalıklarında, yüz felci ve diğer bazı sinir felçleri, sebebi bilinmeyen kas güçsüzlüklerinde, el ayak uyuşmalarında, diyabette ortaya çıkan sinir hasarında sıklıkla EMG testi istenir.

EMG testi ile tanısı konabilen hastalıklar (Bahadır, 2015):

- Polinöropatiler (çoklu sinir ucu iltihapları)
- Karpal tünel sendromu (bilekte sinir sıkışması), Ulnar oluk sendromu (dirsekte sinir sıkışması)
- Bel ve boyun fıtıklarına bağlı kök basıları
- Sinir sıkışmaları (tuzak nöropatileri), sinir yaralanması, ezilme ve kopmaları
- Doğum sırasında bebeklerde ortaya çıkan sinir zedelenmeleri
- Şeker hastalığına bağlı sinir tutulumları (polinöropatiler)
- Motor nöron hastalıkları (Ön boynuz, ALS)
- Doğuştan ve sonradan olan kas hastalıkları: Miyopatiler
- Boyunda sinir sıkışmaları
- Beyin omurilik hastalıklar




Şekil 1.2. Sinir İletim Hızının Ölçümünü Gösteren Temsili Resim



Şekil 1.3. (A), (B) EMG Ölçümü Sembolik Gösterimi

EKG işaretleri bilindiği üzere kalp hastalıklarının teşhisinde kullanılır. Teşhis işaretin zaman içindeki değişimlere bakılarak yapılır. EKG işaretine bakan uzman doktorun, işaretteki şekil bozukluklarından birisini yakalayarak hastalık teşhisine karar vermesi EMG işaret incelemesine göre daha kolaydır. Çünkü Şekil 1.4’ te verilen EKG işareti EMG işaretine göre daha belirgindir. Böylece kayıt edilen EKG’lerin normal EKG’ler ile karşılaştırılarak, kalbin çalışması ile ilgili bazı normal dışı durumlar belirlenebilir. EMG işareti; EKG işaretine göre ne periyodik ne de deterministik bir işarettir (Rodriguez ve diğ., 2006). Başka bir deyişle ayrı ayrı

zamanlarda, keyfi olarak seçilecek EMG işaretlerinin istatistiksel davranışı tam olarak aynı değildir. Belirli zaman aralıklarında EMG işaretleri kendilerini tekrar etmezler ve tek bir matematiksel ifade kayıt süresinin tamamı boyunca elde edilen EMG işaretini temsil edemez (Okkesim, 2006). İşaretlerin değerlendirilmesi zaman ve frekans düzleminde yapılabilir. EMG işaretlerini analiz etmedeki temel zorluk bu işaretlerin zayıf, gürültülü, deterministik ve durağan olmayan işaretler olmasıdır. Dahası EMG işaretleri eğitilmiş EMG teknikerlerinin dahi gerçek kas aktivitesinden ayırt edemediği gürültüler barındırır (Kimura, 1983). Buna ilaveten, her bir motor birimlerin ateşleme frekansı, kasılma miktarıyla beraber artmakta ve yeni bir motor ünite ateşleme yapıncaya kadar bu davranışını korumaktadır. Dolayısıyla motor birimlerin ve bunun sonucu olarak EMG işaretlerinin belirli bir frekans davranışından söz edilmesi zordur (Özkaya, 2005).



Şekil 1.4. Normal EKG işareti (URL-2,2015)

EMG verisinde hastalık tanısı MUAP dalga şeklinin bütüne bakılarak verilmelidir. Zamansal parametreler olan MUAP' ın genlik, süre, faz ve dönüş sayısı değerleri tanı koymada hesaplanan değerlerdir. Ancak bu zamansal değerler tanı için yeterli değildir. Bu nedenle EMG verisinin tanısallık değerini arttırmak için yüksek dereceli istatistikler, spektral ve dalgacık analizi, doğrusal ayırım analizi, sayısal

filtreleme, modelleme analizleri ve yapay sinir ağı gibi yeni işaret işleme tekniklerine ihtiyaç duyulmaktadır (Dobrowolski, ve diğ., 2012).

Araştırmacılar kas ve sinir (nöromüsküler) sisteminin davranışını, o bölgeden alınan EMG işaretlerinden anlayabilmek için tümleştirme (integrasyon), kareler ortalamasının kare kökü, sıfır geçişlerini sayma gibi bir çok teknikler uygulamışlardır. (Panagiotacopulos ve diğ., 1998).

Rutin klinik teşhislerde EMG işaretlerinin analizine duyulan ihtiyaç ise otomasyon ve bilgisayar tekniklerinin kullanımını zorunlu kılmıştır. Bu nedenle objektif bir değerlendirme yapabilmek için EMG işaretlerinin farklı yöntemlerle analiz edilmesi yoluna gidilmiştir. Son yıllarda geliştirilen bu yöntemlerin bazıları işaretlerin istatistiksel analizinin yapılmasında, diğerleri ise özel dalga şekillerinin belirlenip, ayrıştırılıp incelenmesinde kullanılmaktadır. Bu yöntemlere örnek olarak; zaman analizi, frekans analizi, zaman-frekans analizi yöntemi ve dalga şekillerinin ayrıştırılması ve sınıflandırılması sayılabilir (Bozkurt, 2007), (Kulikowski, 1979) (Greenes, ve diğ., 1969).

1979 yılında De Luca tarafından yazılan ve bu konuda bir ilk olan EMG içerik bilgisi ile ilgili makalesi EMG işaretlerinin fizyolojisi ve matematiksel metotlarını birleştiren bir klasik sayılmaktadır. Sonrasında birçok araştırmacı bilgisayar tabanlı EMG analiz algoritması geliştirmiştir (Stalberg, ve diğ., 1986).

Son zamanlarda yapılan çalışmalara baktığımızda işaret işleme teknikleri ve yapay zeka tekniklerinin gelişmesine paralel olarak bilgisayar tabanlı EMG analiz algoritmaları gelişmiştir.

Klinik uygulamalarda nöromüsküler hastalıkların teşhisinde kullanılan tekniğin uygulanabilirliği, doğru sonuç alınması ve kullanım kolaylığı açısından önemlidir (Ejderha, 2009).

1.1 Tezin Amacı

Hastalıkların teşhisinde doktorlar, bilgilerine, tecrübelerine ve laboratuvar sonuçlarına bakarak karar verebilmektedirler (Doğan, 2003). Doktor ne kadar konusunda uzman olursa bazen bazı noktalar gözden kaçmakta ve yanlış teşhisler konulabilmektedir. Teşhis problemlerinde insan faktörünü ortadan kaldırmak için bilgisayar ortamında çözüm üretilmesi için bugüne kadar birçok çalışma yapılmıştır.


Hastanelerde verimliliğin yükseltilmesinden söz edildiğinde ele alınabilecek önemli konulardan biri de tıbbi teknolojinin kullanımıdır. Sağlık sektöründe kullanılan biyomedikal cihaz teknolojileri de dünyamızda hızla gelişen ve yaygınlaşan bir sektördür. Bu sektörde çalışan teknik elemanlar ve sağlık çalışanları, çalıştıkları ortamlarda bulunan fizyolojik sinyal izleme takip ve kayıt cihazlarından en yüksek seviyede faydalanmak ister. Teşhis ve tedavide tıbbi hataları, teşhis ve tedavi süresini, hastada oluşabilecek yan etkileri en aza indirmek amaçlarıyla kullanılan tıbbi cihazlar nedeniyle günümüzde hastaneler yoğun teknolojik işletmeler haline gelmiştir.

Şekil 1.5’ de ticari (Avrupa, Amerikalı ve vb. menşeli) firmalar tarafından üretilmiş üç ayrı ticari EMG cihazı gösterilmektedir. Bu ve benzeri EMG cihazlarının çoğunda kullanılan yazılımlar otomatik MUAP yakalama özelliği ile elde edilen MUAP’ ın kaç adet MUAP’ tan oluştuğu, genlik, süre, faz, dönüş bilgilerini tablolama gibi özelliğe sahiptir. Ancak bu sayılan özelliklerin ötesinde mevcut EMG yazılımları, verileri rutin klinik bulguyu destekleyecek şekilde nöromüsküler rahatsızlığı olan veya olmayan şeklinde sınıflandırma özelliğine henüz sahip değildir. Teze başlanılan tarihte, yazarın en iyi bilgisine göre; literatürde mevcut hesapsal yapıları (algoritmaları) ticari EMG cihazlarına eklemek isteyen bir yayına rastlanmamıştır. Dobrowolski, ve diğ.’ leri, (2012) ticari olarak mevcut cihazlara geliştirmiş oldukları algoritmaları entegre etmek amacıyla EMG cihaz imalatçıları ile müzakere içinde olduklarını belirtmişlerdir. Bu eksiklikten yola çıkarak bu tezde amaçlanan; uzman teşhisine yardımcı olmak amacıyla EMG işaretlerini nöromüsküler rahatsızlığı olan veya olmayan şeklinde sınıflandıran bir yazılımı tasarlamak ve gerçek zamanlı çalışan bir uzman sistemin alt yapısı ve ön hazırlığını oluşturmaktır. Bundan sonraki gelecek çalışmasında amaçlanan bu tezde önerilen/denenen yöntemleri Şekil 1.6’ da sunulan prototip EMG cihazına gerçek zamanlı çalışacak şekilde entegre etmektir. (Bu Cihaz, TGSD No: 0229.TGSD.2012 olan “EMG Cihazı Tasarımı” adlı proje; Bilim, Sanayi ve Teknoloji Bakanlığı, Tekno girişim Sermaye Desteği Programı, 2013, (06/06/2012-06/06/2013) kapsamında desteklenmiş ve proje yürütücüsü Elek-Elekt. Y. Müh. Cengiz TEPE, proje danışmanı Yrd. Doç. Dr. İlyas Eminoğlu olan 100.000 TL hibe ile tasarlanmış ve denenmiştir. Dört kanallı bu cihaz yüzey EMG ve sinir ileti hızı ölçümü yapabilecek kapasiteye sahiptir.)



Şekil 1.5. Ticari (Avrupa, Amerika ve vb.) Firmaların Ürettiği EMG Cihazları


EMG CİHAZI PROTOTİPİ




a- EMG Cihazı Prototipi (4 kanallı) Türkçe kullanıcı arayüzü görüntüsü



b-EMG Cihazı Prototipi (4 kanallı) önden görünüş, soldaki ön ve ana yükselteç, programlanabilir akım kaynağı, veri alım kartı, sağdaki prototip için özel tasarlanan besleme kaynağı iç görüntüsü



c-EMG Cihazı Prototipi elektronik devre kartı (soldaki ön ve ana yükselteç, programlanabilir akım kaynağı, veri alım kartı) önden görünüş



d- EMG Cihazı Prototipi elektronik devre kartı (soldaki ön ve ana yükselteç, programlanabilir akım kaynağı, veri alım kartı) arkadan görünüş

Şekil 1.6. Farklı Açılardan “EMG Cihazı Prototipi” Fotoğrafları

1.2 Tezin İçeriği

Bu tez çalışmasında birinci bölüm tezin amacı, içeriği ve kaynak araştırmasından oluşmaktadır. İkinci bölümde MUAP ve parametreleri hakkında genel bilgilere yer verilmiştir. Üçüncü bölüm olan materyal ve yöntem kısmında ise bölütleme, kümeleme yöntemleri, öznitelik vektörlerinin matematiksel tanımı ve sınıflandırma aşamasında kullanılan yöntemler hakkında bilgiler yer almaktadır.

Dördüncü bölümde ALS ve miyopati hastalığının teşhisinde beş işlem aşamasından oluşan bir sınıflandırma yapısı ile veriler işlenerek sınıflandırılmıştır. İlk adımda ham veriler ön işlem aşamasından geçirilip gürültülerden arındırılmıştır. Sonrasında EMG işaretini oluşturan MUAP' ların farklı yöntemler ile ayrıştırılması sağlanmıştır. Üçüncü adımda aşamalı (hiyerarşik) kümeleme ve melez yapı gibi iki farklı kümeleme ile MUAP' ların kümelenmesi sağlanmıştır. Dördüncü adımda öznitelik vektörleri zaman uzayı ve frekans uzayında hesaplanmıştır. Daha sonra öznitelik vektörleri sırasıyla destek vektör makinesi, k-en yakın komşu algoritması ve diskriminant analiz algoritmalarına giriş olarak verilerek verilerin sınıflandırılması sağlanmıştır. Sınıflandırıcının başarımını belirlemek için çapraz geçerlilik yöntemi kullanılmıştır.


Sonrasında her bir aşamada kullanılan yöntemlerin başarımları sonuçları karşılaştırılmış ve yorumlanmıştır. Tezin son bölümünde önerilere yer verilmiştir.

1.3 Literatür Araştırması

Kaynaklarda biyomedikal uygulamalarda yorumlama ve sınıflandırma problemlerinin çözümleri birçok sinyal işleme, yapay zeka (yapay sinir ağları, vb.) metotları ile elde edilmeye çalışılmaktadır. 1970'li yıllarda yapay zeka tekniklerinin biyomedikal alanındaki kullanımı artmış ve o günden sonra gelişimi hızlanmıştır (Xiang, 1993).

Kas gücü arttıkça EMG işaretlerindeki yeni aktif olmuş MUAP' ların da sayısında artış gözlenmekte, bu da nörofizyolojistlerin her bir MUAP dalgacığını ayırt etmesini zorlaştırmaktadır. EMG işaretlerinin ayrıştırılması ve MUAP' lardan benzer şekilli olanlarının gruplandırılarak sınıflandırması nöromusküler patoloji değerlendirmesi açısından önemli bilgiler sunmaktadır (Christodoulou ve Pattichis, 1999).


Şekil 1.7' de ham EMG verisinin ayrıştırılması ile elde edilen motor birim aksiyon potansiyelleri gösterilmiştir.



Şekil 1.7. Ham EMG Verisinin İşlenmesi ile Elde Edilen MUAP' lar (De Luca, 2011)

İlk kez Lee ve White (1973) düşük eşikte ortaya çıkan MUAP' ların bazı özelliklerini, MUAP ayırt edildikten sonra bilgisayarla hesaplamaya çalışmışlardır. Bilgisayar ile yapılan yöntemlerde bilgiler bilgisayardan ya nümerik olarak (ortalama ve standart sapma) ya da grafik olarak (histogram veya skatterogram (scatter-dağılım)) verilmektedir


Daha ileri bir yöntem de otomatik MUAP tanımlama şeklindedir (Şekil 1.8): Araştırılması istenen MUAP seçilir ve ardı ardına diğer dalga şekilleri ile karşılaştırma yapılması istenir, buna “model eşleştirme” denir. Bu şekilde önceden saptanan karşılaştırma kriterlerine göre, 2-10 adet birbirinin aynı olan MUAP' ların bulunması sağlanır. Tekrarlanmayan dalga şekilleri ise ya bir gürültü veya 1-2 MUAP' ın çakışması gibi algılanır ve ekarte (elenir) edilir. Bu işlem tekrar edilir. Bu şekilde toplanan aynı tip MUAP' ların özellikleri sonradan ölçülür (genlik, süre, faz ve tepelerinin histogramları hesaplanır). Bu bilgisayar prototipini Bergmans tanımlamıştır (Bergmans , 1971), (Bergmans , 1973)



Şekil 1.8. MUAP' ların Nicel Ölçümü İçin Şematik Görünüm (Dorfman ve McGill, 1988)


İşlenen EMG işaretini doktor, mevcut örnekler atlasındaki EMG işaretleri ile karşılaştırarak tanıya karar verir. Tanı aşamasında doktora bu işlenmiş EMG işaretleri yardımcı olur. Karşılaştırma işleminin bilgisayara da yaptırılması mümkündür. Buna yorum yapma denir. Bu bir sınıflama işlemidir. Bilgisayar yorumu olsa bile son söz, kendi deneyimleriyle sonuçları gözden geçirecek olan doktordur.

Dorfman ve diğ.' leri (1988) MUAP analizinin ilk adımında 10 sn' lik EMG sürecinde sayısal süzgeç kullanmış sonrasında MUAP' lar ayrılarak sınıflandırılmış ve sonuçlar nümerik ve grafik formatında verilmiştir (Şekil 1.9).



Şekil 1.9. Ayırıştırılan MUAP' ların Nümerik Ve Grafiksel Olarak Gösterimi (Dorfman ve diğ.,1988)

Nikolic (2001) tez çalışmasında klinik EMG işaretini oluşturan MUAP' ları ayırştıran ve bunlara karşılık gelen ateşleme desenlerini (AD) elde eden EMGPAD adında bir otomatik sistem sunmaktadır. Şekil 1.10' da verilen bu sistem ayırştırma, kümeleme ve çözümleme aşamalarından oluşur. AD' yi oluşturmadaki amaç hastalık tanısında EMG işaretinden daha fazla bilgi çıkarmaktır. Bu çalışmada EMG verileri, nicel MUAP analizi için normal klinik şartlarda kaydedilmiştir. Motor birim ateşleme deseni; her MUAP belirlendikten sonra Şekil 1.11' deki gibi motor birimin her bir atışını zamansal ekseninde bir dikey çizgi ile tasvir edilmesidir. Burada Potansiyel Aralık Değeri (PAD) birbirini takip eden iki dikey çizgi arasında geçen süre olarak tanımlanır. Bu çalışmada ortalama (PAD) ve standart sapma değerleri sağlıklı miyopati ve ALS hastaları için karşılaştırılmış ve bu değerlerin yaş ve cinsiyet ile bağlantısı incelenmiştir. Nikolic bu tez çalışmasında AD analizinin tanı koymada kullanılabilir bir özellik olduğunu ancak ayrıştırma sürecinin karmaşıklığı, hesapsal yoğunluğu ve zaman alıcı sinyal işleme teknikleri içermesi gibi dezavantajlarından dolayı günlük klinik kullanım için uygun olmadığını belirtmiştir.



Şekil 1.10. Üç Aşamalı Ayrıştırma (Nikolic, 2001)



Şekil 1.11. Motor Birim Ateşleme Deseni (Nikolic, 2001)

Nöromusküler hastalıkların sınıflandırılmasında literatürde kullanılan en yaygın yöntemler; bayes teknikleri (Pfeiffer, 1999), (Xiang, ve diğ., 1993); sinir ağları (Abel, ve diğ., 1996), (Katsis, ve diğ., 2002); çok katmanlı perseptronlar (Guler ve Koçer, 2005); bulanık yaklaşımlar (Hamilton, ve diğ., 2007); destek vektör makineleridir (Katsis, ve diğ., 2002).


Çizelge 1.1’ de nöromusküler bozuklukların tanısı için EMG sinyalleri sınıflandırma alanında literatürde bulunan bir kısım çalışmaların yayın yılı, kullanılan yöntemler, MUAP sayısı ve başarımları verilerek bir özet sunulmuştur.

Çizelge 1.1. Nöromüsküler Bozuklukların Tanısı için EMG Sinyallerinin Sınıflandırılması Alanında Yapılan Bazı Çalışmalar (Yousefi, ve Hamilton, 2014).

Kullanılan Yöntemler		Denek Sayısı (MUAP Sayısı)	Doğruluk (%)
(Christodoulou ve Pattichis, , 1999)	Öz Denetleyici Harita (ÖDH), Vektör Nicelendirmeli Öğrenme (VNÖ) ve Öklid uzaklığına dayalı istatistiksel yöntemler	(1213)	90
(Subasi, ve diğ., 2006)	Dalgacık Tabanlı Sinir Ağı (DTSA)	(1200)	90.7
(Bhardwaj, ve diğ., 2012)	ÖDH ve VNÖ	11	97.6
(Rasheed, ve diğ., 2006)	Uyarlamalı Bulanık K-EYK Sınıflandırıcı (UBKS)	11	96.6
(Guler ve Koçer, 2005)	DVM	59	92.3
(Kaur, ve diğ., 2010)	İkili DVM	12	100
(Dobrowolski, ve diğ., 2012)	Dalgacık Tekniği ile Öznitelik Çıkarımı ve DVM	300	99.4
(Subasi, 2012)	Ayrık dalgacık dönüşümü ile öznitelik çıkarma ve Bulanık Destek Vektör Makinesi (BDVM)	27	97.67

Nöromüsküler hastalık tanısında EMG sinyallerini sınıflandırmada son derece sağlam sınıflandırma modellerinden biride DVM’ dir (Katsis, ve diğ., 2002), (Kaur, ve diğ., 2009), (Guler ve Koçer, 2005).

Koçer ve Güler (2005); Sağlıklı, miyopati ve nöropatik EMG sinyallerini sınıflandırmak için Çok Katmanlı Algılayıcı (ÇKA) ve DVM algoritmalarını denemişlerdir. ROC eğrisi altında kalan alanın değeri sınıflandırma başarımı değerlendirmede bir ölçüttür. Alan ne kadar büyükse sınıflandırma doğruluğu o kadar yüksektir. Bu çalışma için Şekil 1.12’ de DVM için çizdirilen ROC eğrisi altında kalan alan 0.923 iken; ÇKA de 0,916 ile daha düşük bir alan elde edilmiştir. Ancak DVM’ nin eğitim ve test sırasındaki çekirdek fonksiyonunun seçim karmaşıklığı, hız ve sınıflandırıcılarda boyut sınırlaması gibi bazı sakıncaları mevcuttur.




Şekil 1.12. ÇKA ve DVM ait ROC eğrisi (Guler ve Koçer, 2005)

Subasi ve diğ.'leri (2006), EMG işaretinin sınıflandırılması için ileri beslemeli hata geri yayımlı YSA ve Dalgacık Tabanlı Sinir Ağları (DTSA) temelli sınıflandırıcıları karşılaştırmıştır. Nörojenik 13, miyopati 7 ve sağlıklı 7 denekten elde edilen 1200 MUAP analiz edilmiştir. DTSA tekniği % 90.7; ileri beslemeli hata geri yayımlı YSA tekniği % 88 sonuç vermiştir. DTSA temelli sınıflandırıcıların ileri beslemeli hata geri yayımlı YSA temelli sınıflandırıcılara göre daha iyi sınıflandırma yaptığı gösterilmiştir.

Subasi ve diğ.'lerinin gelecekteki amaçları rutin klinik ortamda kullanılmak üzere; bu çalışmada geliştirilen algoritmaları, nöromusküler hastalıklar için kas biyopsisi, biyokimyasal ve moleküler genetik bulgular ve klinik verileri kullanan melez bir teşhis sistemine entegre etmektir (Subasi, ve diğ., 2006).

Subasi (2012) bir diğer çalışmasında; 7 sağlıklı, 7 miyopati ve 13 nöropatik kişi olmak üzere, 27 denekten aldıkları EMG sinyallerini sınıflandırmada altı adet sınıflandırma algoritmasını karşılaştırmıştır. Kullanılan ana yapının öbek çizgesi Şekil 1.13' de verilmiştir. Sınıflandırma algoritmasının giriş boyutunu azaltmak için öznitelik vektörü olarak Ayrık Dalgacık Dönüşümlerinin (ADD) katsayılarının kümesi üzerinden hesaplanan dört istatistik özellik kullanılmıştır. Sınıflandırma algoritması olarak da bir Bulanık Destek Vektör Makinesi (BDVM) sınıflandırıcı önerilmiştir. Sonuçlar Doğrusal Diskriminant Analizi (DDA), ÇKA, RTA, Karar Ağacı (KA) ve DVM sınıflandırıcıları ile karşılaştırılmıştır. Bu çalışmada ADD özelliklerini kullanarak BDVM ile yapılan sınıflandırma diğer yöntemlere göre % 3 daha iyi başarımlı sağlanmıştır.




Şekil 1.13. Önerilen Sistemin Blok Diyagramı (Subasi, 2012)

Subasi (2013), yeni bir parçacık sürüşü optimizasyonu ve DVM (PSO-DVM) modelini, sağlıklı nöropatik veya miyopati EMG sinyallerini sınıflandırmak için önermiştir. Kullanılan ana yapının öbek çizgesi Şekil 1.14’ de verilmiştir. Bu çalışmada sınıflandırma doğruluğunu geliştirmek için PSO ve DVM’ den oluşan bir melez yapı kullanılmıştır. Başarım sonuçları Radyal Temel Fonksiyonu (RTF) çekirdeği üzerine dayalı, DVM sınıflandırıcı için % 96,75 doğruluk elde ederken, Radyal Tabanlı Ağ (RTA) sınıflandırıcı için % 94,08 ve K-EYK sınıflandırıcı için % 95,17’ dir. Bu çalışmada Şekil 1.15’ da verilen grafikte her bir sınıflandırıcının toplam sınıflandırma doğruluğuna bakıldığında RTF çekirdeği üzerine dayalı DVM’ nin, RTA ve K-EYK sınıflandırıcılara göre daha iyi olduğu görülmüştür.



Şekil 1.14. Önerilen Sistemin Blok Diyagramı (Subasi, 2013)




Şekil 1.15. Sınıflandırıcı Başarımının Grafikselsel Gösterimi (Subasi, 2013)

Kaur ve diğ.’ leri (2010) nöromüsküler bozuklukların teşhisinde EMG sinyallerini sınıflandırmak için bir ikili DVM sınıflandırıcı geliştirmiştir. İlk olarak, bir ikili DVM sınıflandırıcı sağlıklı ve hastalığı olan bireylere ait verileri sınıflandırmak için kullanılmıştır. İşaret hastalıklı olarak sınıflandırıldı ise, o zaman


başka bir ikili sınıflandırıcı miyopati ve nöropati sinyallerini sınıflandırmak için kullanılmıştır. Analiz 3 sağlıklı, 5 miyopati ve 4 motor nöron hastalıklı bireylerden alınan 12 EMG sinyalleri kullanılarak tamamlanmıştır. Bu modelin başarımlı değeri % 100 olarak sunulmuştur. % 100 doğruluk, bu çalışmada bildirilmiş olmasına rağmen çalışma küçük veri seti için denenmiştir.

Rasheed ve diğ.' leri (2006) nöromusküler tanı için EMG sinyallerinin sınıflandırılmasında bir Uyarlamalı Bulanık K-EYK Sınıflandırıcı (UBKS) önermiştir. UBKS sınıflandırıcı için sonuçlar; Uyarlamalı Kesinlik Sınıflandırıcısı (UKS) ile karşılaştırılmıştır. UBKS sınıflandırıcı her bir girişe ait üyelik fonksiyonunu tahmin etmek için bulanık K-EYK algoritmasını kullanmıştır. UBKS için ortalama başarımlı % 96.6 iken; UKS için % 86.9 dir. Deneysel sonuçlar K-EYK modelinin sınıflandırma doğruluğunu artırmada iyi bir başarımlı sergilediğini göstermiştir.


Christodoulou ve Pattichis' in (1999), yapmış oldukları çalışmanın öbek çizgesi Şekil 1.16' da verilmiştir. Bu çalışmada EMG verileri ön işlem aşamasında 3-10 kHz' lik bant geçiren süzgeçten geçirilmiş; bölütleme aşamasında ise 6 ms süreli sabit pencere ile MUAP' lar ayrıştırılmıştır. Bölütleme Sonucunda Elde Edilen 6 ms süreli EMG verileri Şekil 1.17' de verilmiştir. Nöromusküler hastalıkların teşhisinde EMG sinyallerinin sınıflandırılması için iki farklı örüntü tanıma tekniği denemişlerdir. Bu yöntemlerden ilki ÖDH ve VNÖ algoritmalarının değiştirilmiş bir versiyonuyla ile eğitilmiş bir denetimsiz YSA, ikincisi öklid mesafe tabanlı istatistiksel sınıflandırıcıdır. Sınıflandırma sonucunda üç farklı sınıfa ayrılmış benzer şekilli MUAP' lar Şekil 1.18' de verilmiştir. Deneyler sonucunda istatistiksel yaklaşım % 95.3 doğruluk elde ederken YSA % 97.6 doğruluk ile verileri sınıflandırmıştır. Bu çalışmada VNÖ algoritmasının ek kullanımı sınıflandırma başarımlı artırılmıştır.



Şekil 1.16. EMG Sınıflandırma ve Ayrıştırma Sisteminin Akış Şeması (Christodoulou, ve Pattichis, , 1999).




Şekil 1.17. Bölütleme Sonucunda Elde Edilen 6 ms Süreli EMG Verileri



Şekil 1.18. Üç Farklı Sınıfa Ayrılmış Benzer Şekli MUAP' lar

Bhardwaj ve diğ.' leri (2012), nöromusküler hastalıkların teşhisi için Şekil 1.19' de gösterildiği gibi MUAP' ları VNÖ ile ÖDH algoritmasına dayalı bir YSA tekniği ile sınıflandırmıştır. Bu yöntem, üç aşamada gerçekleştirilmiştir. İlk aşamasında ÖDH kullanılırken, ikinci aşamasında VNÖ; YSA' nın başarımını artırmak için uygulanmıştır. Gerçek sınıflandırma üçüncü aşamada yer alır. Deneyler (2 sağlıklı, 4 miyopati, 5 nöropatik) 11 denekten oluşan bir veri kümesi üzerinde gerçekleştirilmiştir. Bu teknik için başarı oranı % 97.6' dir.



Şekil 1.19. EMG sınıflandırma Akış Şeması (Bhardwaj, ve diğ., 2012)

Dobrowolski ve diğ.' leri (2012), nöromusküler bozuklukların sınıflandırılması için morfolojik parametreleri (süre, genlik ve alan) ve dalgacık dönüşüm parametrelerini giriş olarak kullanan DVM algoritmasını denemişlerdir. Bu

çalışmada kullanılan EMG verileri 16-78 yaş aralığındaki 300 denekten (her bir denekte en az 20 adet MUAP kaydedilmiştir) alınmıştır. Bu verilerin 30' u miyojenik, 70' i nörojenik ve 200 tanesi ise sağlıklı verilerden oluşmaktadır. Çizelge 1.2' de Bischoff ve diğ.' lerinin (1994) çalışmasından alınan ve yazarlar tarafından hesaplanan sağlıklı 200 kişinin deltoid kasına ait MUAP' ların morfolojik parametre değerleri referans değerler olarak sunulmuştur.

Şekil 1.20' de 3 farklı biçimdeki MUAP aynı süre, genlik ve alan parametrelerine sahiptir. Bu nedenle klasik analizde kullanılan bu parametreler ile MUAP tam olarak temsil edilemediğinden bu çalışmada morfolojik parametrelere göre daha iyi ayırım sağlayacak dalgacık dönüşümü ile MUAP' ların öznitelik vektörleri çıkartılmıştır. Bu çalışmada 4. ve 5. dereceden Daubechies, 4. ve 6. dereceden Symlet ve 2. dereceden Coiflet dalgacıklar analiz için seçilmiştir. Her bir MUAP bu dalgacıklar ile ayrıştırılmış ve seçilen beş karakteristik katsayı ile MUAP yeniden elde edilmiştir. Dalgacık analizi sonucunda hesaplanan ortalama karesel hata değerlerinden en az hataya sahip 4. dereceden Symlet dalgacığı olmuştur (Çizelge 1.3). Şekil 1.21' te kalın çizgi ile gösterilen orijinal MUAP dalga şekline en yakın dalga şekli, ince çizgi ile gösterilen (% 5.06 hata değeri ile) 4. dereceden Symlet dalgacığı ile elde edilen dalga şekli olmuştur.

Çizelge 1.4 deltoid kası için sonuçlar karışıklık matrisi (confusion matrix) olarak verilmiştir. Burada dalgacık dönüşümüne ait özniteliklerin morfolojik parametrelere göre daha az hata ile verileri sınıflandırmıştır. Her üç kas için % 99.4 doğruluk elde edilirken; özgüllük % 100, duyarlılık miyojenik durumlar için % 98.4 ve nörojenik olanlar için % 98.7 düzeyindedir. Sonuçlar önerilen yöntemin patolojik ve patolojik olmayan olgular arasında yüksek ayırım sağladığını göstermiştir. Bu çalışmada her bir morfolojik parametreler tek tek denenmiş ancak birden fazla katsayı ile temsil edilen dalgacık tabanlı öznitelik vektörleri ile kıyas yapılmıştır. Bu çalışmanın eksik olan yanı ise süre, genlik ve alan parametrelerinin tamamını içeren çoklu morfolojik öznitelik vektörleri ile bu karşılaştırmanın yapılmamış olmasıdır.

Yukarıdaki çalışmalarında Dobrowolski ve diğ.' leri ticari olarak mevcut cihazlar üzerinde bu yöntemleri kullanılabilir hale getirmek için EMG cihaz imalatçıları ile müzakere içinde olduklarını bu makalede belirtmişlerdir.

Çizelge 1.2. Sağlıklı Deltoid Kasından Alınan MUAP' lara ait Morfolojik Değerler (Dobrowolski, ve diğ., 2012)


Parametre	(Bischoff,1994)	(Dobrowolski, ve diğ., 2012)
Genlik [uV]	550±110	529±88
Süre [ms]	10.4±1.3	10.91±0.96
Alan[uv ms]	858±210	731±112

Çizelge 1.3. Dalgacık Analizi (Dobrowolski, ve diğ., 2012)


Dalgacık Tipi	Modele Ait Hata	
	Ortalama	Standart Sapma
4. Dereceden Daubechies	%7.42	%0.94
5. Dereceden Daubechies	%7.70	%1.02
4. dereceden Symlet	%6.46	%0.85
6. dereceden Symlet	%6.70	%0.88
2. dereceden Coiflet	%6.55	%0.86

Çizelge 1.4. Deltoid Kası için Sınıflandırma Sonuçları (Dobrowolski, ve diğ., 2012)

Sınıflar	Genlik			Süre			Alan			Dalgacık Analizi		
	M	H	N	M	H	N	M	H	N	M	H	N
Doğru Tanı	23	200	67	16	195	34	30	198	57	30	200	68
Yanlış Tanı	7	0	3	14	5	36	0	2	13	0	0	2




Şekil 1.20. Aynı Morfolojik Parametreler ile Karakterize Edilen Farklı MUAP Şekilleri (Dobrowolski ve diğ., 2012)



Şekil 1.21. Dalgacık Analizi Sonucu Elde Edilen MUAP

Kaur ve diğ. (2009), EMG işaretlerinden MUAP' ların belirlenmesi için üç bölütleme yöntemi önermişlerdir. Bu yöntemler MUAP tepeleri bularak bölütleme, MUAP' ların başlangıç ve bitiş noktaları bulunarak bölütleme ve ADD kullanarak bölütlemedir. Şekil 1.22' de farklı bölütleme yöntemleri ile elde edilen MUAP' lar gösterilmiştir. Sonrasında veriler istatistiksel örüntü tanıma tekniği ile kümelenecek ve özbağlanımlı (AR) yöntemi ile özellik vektörü çıkarılarak DVM ile sınıflandırılmıştır. Toplam başarı oranlarına bakıldığında MUAP tepeleri bularak bölütleme yöntemi ile en iyi sonucun elde edildiği görülmüştür.




Şekil 1.22. (a) MUAP' ların Başlangıç ve Bitiş Noktaları Bulunarak Bölütleme ve (b) ADD Kullanarak Bölütleme (Kaur ve diğ., 2009)

Katsis ve diğ. (2006), çalışmalarında Bulanık K-Ortalamlar yöntemi ile MUAP' ların kümelenecek sağlanmış. Öne sürdükleri bu yöntemde, küme sayıları otomatik olarak belirlenmektedir. Otomatik küme sayıları belirlenerek

kümelenmiş MUAP' lar DVM sınıflandırıcısıyla sağlıklı, miyopati ve nöropati sınıflarını sırasıyla % 93, 95 ve 92 doğrulukta sınıflandırmıştır.


Xie ve diğ.' leri (2003), öznitelik vektörü olarak MUAP işaretlerinin zaman düzlemindeki özniteliklerini kullanarak her bir kişiye ait parametrelerin ortalaması ve standart sapma değerlerini destek vektör makinesi ve ikinci bir sınıflandırıcı olarak geriye yayılım sinir ağına giriş olacak şekilde vermiştir. DVM sınıflandırıcısı geriye yayılım sinir ağına göre daha iyi başarımlar sergilemiştir.

Fattah ve diğ.' leri (2012); ALS, miyopati ve sağlıklı verileri ayırt etmek için zaman ve frekans düzlemindeki işlemlere dayalı (otokorelasyon, sıfır geçiş sayısı ve fourier dönüşümü) bir sınıflandırma geliştirmişlerdir. Sınıflandırıcı olarak K-EYK algoritması kullanılmıştır. Önerilen spektral tepe ve otokorelasyon tabanlı özelliklerinin başarımlarının iyi olması, basit bir K-EYK sınıflandırıcı kullanılmasıyla yüksek sınıflandırma doğruluğu sağlanmıştır. Ancak bu çalışma ALS-Sağlıklı ve ALS-Miyopati ikili sınıfları otokorelasyon öznitelik vektörü kullanılması durumunda % 100 doğrulukla sınıflandırırken; Miyopati-Sağlıklı sınıfları % 86 doğrulukla sınıflandırmıştır. Miyopati-Sağlıklı sınıf için önerilen öznitelik vektörünün ayırma derecesi önceki iki sınıftan farklı olarak çok tatmin edici değildir. Bu durumu Şekil 1.23' daki grafikte de görmek mümkündür. ALS verilerine ait ortalama değerleri diğer iki sınıftan ayırmak mümkün iken; sağlıklı ve miyopati verileri iç içe girmiştir. Bunun sonucu olarak Miyopati-Sağlıklı sınıflandırma başarımında düşüş yaşanmıştır.



Şekil 1.23. Sağlıklı, ALS ve Miyopati Kişilere Ait Verilerin Otokorelasyon Değerlerinin Ortalama Değişimi (Fattah, ve diğ., 2012)


Bozkurt (2007), tez çalışmasında MUAP' ların şablon kümelerinin sayısını bulmakta ve bunları sağlıklı, nörojenik veya miyopati olarak sınıflandırmaktadır. Bu çalışmada, 7' si sağlıklı, 7' si miyopati ve 13'ü de nörojenik rahatsızlığı olan kişilerden elde edilen 1200 MUAP' lık EMG verileri kullanılmıştır. Ancak bu tez çalışmasında verilerin nereden ve nasıl temin edildiği, verilerin hangi kas gruplarından alındığı, deneklerin yaşı, cinsiyeti, vs. hakkında herhangi bilgi verilmemiştir. EMG işaretlerinden öznitelik vektörü çıkartmak için farklı AR parametrik metotları ve alternatif olarak işaretin belirleyici özellikleri kullanılırken; MUAP sınıflandırmada Şekil 1.24' de gösterilen Bileşik Sinir Ağları (BSA) ve İleri Beslemeli Hata Geri yayımlı YSA kullanılmıştır. BSA, ileri beslemeli hata geri yayımlı YSA' ya kıyasla tüm gruplarda başarı oranını ya korumuş veya arttırmıştır. Belirleyici özelliklerin kullanımı, özellikle başarı oranının düşük olduğu nörojenik denekler grubu için başarı oranını arttırmıştır.



Şekil 1.24. İleri Beslemeli Hata Geri yayımlı YSA ve Bileşik Sinir Ağları Topolojisi (Bozkurt, 2007)

Maboud ve diğ.' leri (2015) ALS, miyopati ve normal EMG verilerini sınıflandırmak amacıyla DVM ve YSA' ya dayalı yeni bir melez sınıflandırma sistemi önermiştir. Veriler (<http://www.EMGlab.net>, 2011) internet adresindeki veritabanından alınmıştır. EMG işaretlerinin özniteliklerini çıkartmak için, dalgacık dönüşümü kullanılmıştır. Sonrasında istatistiksel özellikler hesaplanmış ve sınıflandırıcılara girdi olarak verilmiştir. Bu çalışmada önerilen sınıflandırma sistemi Şekil 1.25' de verilmiştir. İlk adımda her bir sınıfın performansı ölçülmüş ve

yüksek doğruluklu iki sınıflandırıcı melez sınıflandırıcı oluşturmak için seçilmiştir. Sonrasında iki farklı sınıflandırıcı kullanılmıştır. İlki RTF fonksiyonunu kullanan DVM' dir. İkinci sınıflandırıcı ALS ve sağlıklı olanlara karşı miyopati verilerin sınıflandırılması amacıyla inşa edilmiş; bu amaçla bir ileri beslemeli geri yayılım tabanlı çok katmanlı sinir ağı kullanılmıştır. Sonuçlar ALS grubu için DVM sınıflandırıcı % 98 doğruluk sağlarken; MYO grubu için YSA sınıflandırıcı % 86.6 verileri sınıflandırmıştır.




Şekil 1.25. Melez Sınıflandırıcı (Maboud ve diğ., 2015)

Krishna ve Thomas (2015) MUAP' ları sınıflandırmadan önce gereksiz özellikleri eleyerek sınıflandırma için önemli spektral özellikleri çıkarmayı amaçlamışlardır. Spektral özellik çıkarımı için doğrudan ADD tabanlı yöntem kullanılmıştır. K-EYK verilerin sınıflandırılması amacıyla kullanılmıştır. Sonuçların değerlendirilmesinde özgüllük, hassasiyet ve doğruluk değerlerine bakılmıştır. Veriler (<http://www.EMGlab.net>, 2011) internet adresindeki klinik EMG veritabanından alınmıştır. Bu çalışmadaki veri kümesi 8 ALS hastasına ait 50 veri, 7 Miyopati hastasına ait 50 veri ve 10 normal denekten alınan 150 EMG verisinden


oluşmaktadır. Bu çalışmada sınıflandırıcının girişine baskın değere sahip MUAP'ların öznitelik değerleri verilerek özellik boyutu son derece düşürülmüş ve hesap karmaşıklığı azaltılmıştır. Sonuç olarak ALS-Sağlıklı veri seti için başarımlar % 96.5 iken, Miyopati-Sağlıklı için % 83.5' tir.

EMG sinyallerinin bir diğer kullanım alanı ise elektromekanik yapıları protezlerin denetimidir. Chu ve diğ.'leri (2006) çalışmalarında dört kanallı yEMG işaretini 21 denekten alarak 4 serbestlik derecesi olan sanal protez eli denetlenmiştir. Dalgacık paket dönüşümü ile öznitelik vektörü çıkartılmıştır. Dalgacık katsayılarının boyut azaltımı için Temel Bileşenler Analizi (TBA) işleminden yararlanılmıştır. TBA işleminin sınıf ayrılabilirliğini arttırmak için ise Öz Düzenleyici Haritalar (ÖDH) yöntemi kullanılmıştır. Sonrasında çok katmanlı algılama sınıflandırıcısı ile hareketler sınıflandırılmıştır (Şekil 1.26). Kullanılan yöntemlerde TBA+ÖDH = % 97,024 (5ms), ÖDH= % 97,785 (180 ms), TBA = %95.759 (2ms) doğrulukta başarımlar sağlamıştır.

Chu ve diğ. (2007)'de ise Şekil 1.27'de verilen hareketler için 4 kanallı alınan EMG işaretlerinin dalgacık dönüşümü ile öznitelik vektörleri hesaplanmıştır. Sınıf ayrılabilirliğinin artırılması için dalgacık katsayılarının ortalama mutlak değerleri hesaplandıktan sonra DDA yöntemi uygulanmış ve DDA çıkışları sınıflandırılması için bir YSA'ya verilmiştir. % 97.2 gibi bir doğruluk oranı ile sınıflandırma işlemi tamamlanmıştır.




Şekil 1.26. yEMG Örüntü Tanıma Öbek Çizgesi (Chu ve diğ., 2006)




Şekil 1.27. Statik El Hareketleri İle Gerçek Zamanlı El Denetimi (Chu ve diğ., 2007)

Oskoei (2008) çalışmasında üst kola ait myoelektrik sinyallerini gerçek zamanlı sınıflandırmada yaygın olarak kullanılan DVM algoritmasını denemiştir. DVM; DDA ve ÇKA yöntemleri ile karşılaştırılmıştır. Sonuç olarak DVM diğerlerine göre düşük hesaplama yükü ile verileri yüksek doğrulukta sınıflandırmıştır. Oskoei bu çalışmasında yüksek sınıflandırma başarımının etkili öznelik vektörü ve sınıflandırma metodu seçimine bağlı olduğunu belirtmiştir. Sınıflandırma başarımını arttırmak için zaman ve frekans düzlemindeki öznelik vektörlerinin birleşiminden oluşan çoklu öznelik vektörleri kullanmıştır. Şekil 1.28’ de tekli ve çoklu öznelik vektörleri karşılaştırıldığında çoklu öznelik vektörlerinin daha iyi başarımlar sağladığı; Şekil 1.29’ de ise zaman ve çoklu öznelik vektörlerinin frekans düzlemindeki öznelik vektörlerine göre daha iyi olduğu görülmektedir.



Şekil 1.28. Tekli ve Çoklu Öznitelik Vektörlerinin Başarımları (Oskoei, 2008)



Şekil 1.29. Zaman, Frekans ve Çoklu Öznitelik Vektörlerinin Başarımları (Oskoei, 2008)

2. GENEL BİLGİLER

2.1 Motor Ünit Aksiyon Potansiyeli (MUAP)

Motor ünit terimini Sherington 20. yüzyıl başlarında nöroloji terminolojisi içine katmıştır. Omurilik ön boynuzunda yerleşik tek bir alfa motor nöron, bu nöronun aksonu ve onun innerve ettiği (uyardığı) kas liflerinden oluşan fonksiyonel birim motor ünit olarak isimlendirmiştir.

Bir iğne elektrot ile kas içine girilip hafif kasılma sırasında kayıtlama alındığında bu aktivitenin, belli bir süresi, genliği olan ve genellikle trifazik yapıda birimlerden oluştuğu görülür. Bu birimler tek bir alfa motor nöronun ateşlenmesi sonucu kas liflerinin hepsinde aynı anda meydana gelen kasılma toplam elektriksel aktivitesinin bir sonucudur.

Bir alfa motor nöronun gövde büyüklüğü, aksonunun çapı ve uyardığı kas lifi sayısı arasında pozitif bir paralellik vardır. Büyük gövdeye sahip bir alfa motor nöron daha fazla sayıda lifi uyuracak ve iğne EMG ile elde edilen MUAP daha büyük olacaktır (Uludağ, 2002).


Kas motor siniri akson ayaklarının kas lifleriyle olan bağlantılarına motor uç plakaları, bir motor siniri lifiyle birlikte bu plakaların oluşturduğu gruba ise motor birimi adı verilir. Şekil 2.1' de gösterildiği gibi, ölçme elektrotları (A ve B) kas liflerinin arasına yerleştirilmiş ise de bir motor birimindeki motor plakalarına, uyarı geldiğinde aynı anda aksiyon potansiyeli oluşacak, bunların elektrot çiftlerindeki yansımaları, motor plakalarının elektrotlardan olan uzaklığına göre, çeşitli genlikteki bifazik değişimler şeklinde olacaktır. Bu değişimlerin fazları ise motor uç plağının elektrotların sağ veya sol tarafında oluşuna göre değişecektir. MUAP iğne elektrotlarla kaydedilen, bir motor ünite ait kas liflerinden gelen aksiyon potansiyellerinin toplamını veren elektro fizyolojik dalgalardır (Ertekin, 2006).

EMG işaretlerinin alınmasında EK D' de gösterilen iğne ve yüzey elektrotları olmak üzere iki tip elektrot kullanılmakla birlikte, kaslardaki sorunların tanısı için daha çok iğne elektrotlar tercih edilir. İğne elektrotlar ile yapılan EMG ölçümüne


iğne EMG' si de denilmektedir. Bu ölçümlerde genellikle konsantrik iğneler kullanılır (Carr ve Brown , 2000).

İğne elektrotlar konsantrik, bipolar konsantrik ve monopolar iğne elektrotlar olmak üzere üçe ayrılır (Şekil 2.2):

1. Konsantrik İğne Elektrotlar: Klinik EMG’ de en çok kullanılan elektrotlardır. Elektrotun ortasında uzanan bir tel ile bunu saran bir izolator içerir ve içteki telin ucu çıplaktır.
2. Bipolar İğne Elektrotlar: Temelde konsantrik iğne elektrot yapısındadır. En önemli farkı, iğne elektrotun merkezinde iki iletken tel bulunmasıdır.
3. Monopolar İğne Elektrotlar: Tek bir hipodermik iğne elektrot ve deriye yerleştirilmiş bir referans elektrot şeklindedir.



Şekil 2.1. Motor Birim Aksiyon Potansiyeli




Şekil 2.2. İğne elektrotlar

MUAP' ların bazı özellikleri EMG tanısı için önemlidir. Bu özellikler: süre, genlik, faz sayısı, yükselme zamanı, dönüş ve uydudur (Şekil 2.3)



Şekil 2.3. MUAP Parametreleri

Klinik koşullarda elde edilen MUAP' ları Şekil 2.4' de gösterilmektedir. Şekil 2.4' de A,B: Basit MUAP (faz sayısı ≤ 4), C: Polifazik (faz sayısı ≥ 5), D: Düzensiz MUAP; dörtten fazla dönüşe sahip MUAP' lar düzensiz olarak tanımlanır, E: Uydu Potansiyeli, F: Çift Deşarj; kas kasılmasının başlangıcı ve bitiminde görülebilir, G: Titreşim veya artan jitter (Jitter; Aynı motor birime ait iki kas lifinden gelen aksiyon potansiyellerine ait değişikliktir), H: Küçük Genlikli Potansiyel; İğne elektrotun uzağında bulunan kas liflerinden gelen düşük genlikli aktivasyonlardır, I: Pozitif Keskin Dalga; denerve (sinirin kesilmesi) olmuş herhangi bir kas lifinde ortaya çıkan tek kas lifi aktivitesini temsil etmektedir (Nikolic, 2001).



Şekil 2.4. Klinik Koşullarda Elde Edilen MUAP' lar (Nikolic, 2001)

2.1.1 MUAP süresi

Her bir potansiyelin süresi, izoelektrik çizgiden ilk sapma (defleksiyon) başlangıcı ile son sapmanın izoelektrik çizgiye dönüşü arasında kalan mesafedir. Genellikle ortalama MUAP süresini saptarken polifazik MUAP' ları bu hesaba katmamak gerekir. 20 basit şekilli potansiyelin süresi toplanarak 20' ye bölünür ve çıkan rakam o kastaki ortalama MUAP süresini verir. 4'ten fazla sapma varsa bu potansiyel polifazik demektir. Her EMG laboratuvarı için yaşa ve incelenen kaslara göre normal kontrol değerleri belirlenmelidir. Bununla beraber, bu birçok yılları içine alan bir çalışmayı gerektirir. Örneğin Buchthal'in Rigs Hospitalet EMG laboratuvar değerleri 20 yıl içinde tamamlanabilmiştir. Eğer sapma normal standart ortalamaya göre %20' den fazla geniş ise bu nörojenik, %20 den daha dar ise miyopati olduğunu gösterir.


%20 den daha az sapmalar, normal limitler içinde kabul edilir. MUAP süresini saptamak hayli zaman alan bir laboratuvar yöntemidir (Ertekin, 2006).

2.1.2 MUAP genliđi

MUAP genliđi tepeden tepeye ölçülen, iki nokta arasındaki en yüksek potansiyel farktır. Motor biriminin genliđi büyük oranda kaydedici elektroda en yakın olan kas liflerinin aktivetisinden oluşur. Bu nedenle EMG elektrotunun çok hafif yer deđiştirmesi, örneđin 1 mm civarında bir deđişme veya iğne ucunun döndürölmesi MUAP genliđinde önemli oranda deđişmelere neden olur (Ertekin, 2006).

2.1.3 MUAP dalga biçimi

Bir çizgili kastan konsantrik iğne elektrot ile çeşitli şekillerde MUAP' lar elde edilir. Bunlar monofazik, bifazik, trifazik ya da polifazik olarak adlandırılır (Şekil 2.5). Monofazik MUAP izoelektrik çizginin üstü veya altında kalan tek yönlü aksiyon potansiyelidir. Bifazik MUAP ise izoelektrik çizgiyi bir kez kesen ve bir pozitif, bir de negatif bileşeni olan bir potansiyeldir. Trifazik MUAP' lar ise çizgiyi iki kez kesen, üç bileşenli olan ve bir polaritesi diğerlerinden farklı olan potansiyellerdir. Polifazik MUAP' lar ise izoelektrik çizgiyi üçten fazla kesen, dörtten fazla tepe yapmış potansiyellerdir (Şekil 2.5). Normal bir çizgili kasta çoğunluğu bifazik ve trifazik aksiyon potansiyelleri oluşturur. Polifazik potansiyeller incelenen kaslara göre %5-15 oranında görölabilir (Ertekin, 2006).



Şekil 2.5. Faz Sayısına Göre MUAP' ların Adlandırılması (Ertekin, 2006)

2.1.4 Yükselme zamanı

Tepe-tepe süresi olarak da adlandırılan yükselme zamanı ilk pozitif (veya negatif) tepeden sonraki negatif (veya pozitif) tepeye denk ölçülen değerdir. Kas lifleri ile kayıt elektrotu arasındaki mesafenin artışı ile artar. Yükselme zamanı kısa olan bir Motor ünit mikrofonda yüksek frekanslı bir ses verir. Eğer MUAP donuk bir sesle ortaya çıkıyorsa iğne pozisyonu değiştirilmelidir (Ertekin, 2006).

2.1.5 Dönüş

Pozitiften negatife (veya tersi) yön değiştiren ancak izoelektrik çizgiyi aşmayan değişimlerdir. Böyle potansiyellere testere dişli potansiyeller denir. Genellikle dönüşlerin 100 μV tan daha büyük genlikli olması koşulu aranır. Dönüşlerin sayımı ile miyopati hastalık nöropatik hastalıktan ayırt edilebilir (Ertekin, 2006).

2.1.6 Uydu

MUAP'ın esas bileşeninden uzakta ortaya çıkan potansiyeldir. Uydu potansiyeller motor birim içindeki bir kas lifinden köken alırlar. Uydu potansiyellere normal kaslarda çok seyrek rastlanır ancak kronik nörojenik hastalıklarda sık görülen bir EMG özelliğidir. Tek bir MUAP'a bağlı birden fazla uydu potansiyel olabilir.

2.2 Sinir - Kas (Nöromüsküler) Hastalıklarında MUAP


Motor üniten yapısı, sayısı ve bireysel ateşlenme frekansının incelenmesi ile kasın kasılması sırasında iğne elektrot ile elde edilen MUAP'ları değerlendirirken başlıca üç tür ayırım yapılmaktadır. İncelenen kas miyopati özellikler taşıyabilir veya nörojenik motor birim değişimleri söz konusudur. Üçüncü olasılık ise kasın normal olması, veya muayene eden kişinin anlamlı bir sonuca varamamasıdır. Sinir-Kas hastalıklarında iğne EMG'si ve diğer elektrofizyolojik testler dikkate alınarak (sinir iletimi gibi) Çizelge 2.1'deki gibi pratik sınıflama yapılabilir.

Nörojenik tutulusta konstantrik iğne EMG'de MUAP süresinde uzama, polifazi artışı, motor ünit sayısında azalma görülür. Motor aksonlar veya alfa motor nöronlarda dejenerasyonla seyreden bir hastalık sürecinde ilk beklenen değişiklik motor ünit kaybıdır. Motor ünit kaybına ikincil gelişen süreç ise sağlam veya görece olarak sağlam kalmış aksonlarda, komşu hasar görmüş motor ünit alanındaki kas

liflerine aksonal filizlenmenin başlamasıdır. Sağlam motor üniten yakınında bir başka motor ünit alanındaki kas liflerini innervasyon alanına alması ile motor üniten süresinde ve yapısında değişiklikler olacaktır (Şekil 2.6). Bu değişiklikler motor üniten süresinde uzama, polifazi artışı şeklinde gerçekleşecektir.

Çizelge 2.1. Sinir-Kas Hastalıklarında Sınıflandırma (Ertekin, 2006)

NÖROMÜSKÜLER HASTALIK		
Miyojenik (Miyopati)	Nörojenik	
I- Çizgili kas lifi hastalığı	I-Periferik (Çevresel) sinir hastalığı	II- Ön Boynuz hastalığı
A)Hereditör (Kalıtsal)	A)Lokelize	A)Lokelize
B)Akkiz (Edinsel) Hastalık	(Radikülopati (Sinir Kökü) Mononöropati vb.)	B)Yaygın (ALS ve Juvenil spinal kas atrofileri; Genç yaşta ortaya çıkan spinal kas kaybı, vb)
(Polimiyozit;iltihaplı kas hastalığı vb.)		
C)Miyotonik sendromlar ve Periyodik paraliziler (Felç).	B)Yaygın (Polinöropati)	
II- Motor son plak hastalığı		




Şekil 2.6. A-Normal, B-Nöron 2'de Dejenerasyon, C-Nöron 1'de Reinnervasyon ve MUAP Alanında Genişleme, Polifazi Artışı (Uludağ, 2002)


EMG ölçümü sırasında hareket bozukluğu olan kasa iki uçtan elektrik akımı verilir. Bu akım sonrasında kasta kasılma oluşuyorsa, kasın kasılması için gerekli işareti taşıyan sinirler arızalıdır (nöropati), eğer bu akıma rağmen bir kasılma olmuyorsa, problem kastadır (miyopati) (Bozkurt, 2007). Şekil 2.7' de normal kas,

nöropati ve miyopati olmuş kas-sinirlerin şekilsel gösterimi, Şekil 2.8’ de ise MUAP’ ları gösterilmektedir. Nöropati olmuş kasın MUAP genliği normal kasa göre oldukça büyüktür. Miyopati olmuş kasın MUAP genliği ise normal kasa göre oldukça küçüktür.

EMG’ si kaydedilen sağlıklı bir kişide kasın kasılma şiddeti istemli olarak arttırıldıkça MUAP’ da artar. Bir MUAP’ ın sıklığı, dalga şekli, frekans spektrumu, genliği klinik açıdan tanı koydurucu faktörlerdir (Stashuk , 2001).



Şekil 2.7. Sağlıklı, Nöropati ve Miyopati Hastalığının Şekilsel Gösterimi (Weiss, 2004)



Şekil 2.8. Sağlıklı, Nöropati ve Miyopati Hastalığının MUAP Gösterimi (Weiss, 2004)

Nörojenik hastalıklarda görülen en tipik bulgu bireysel ve ortalama sürelerinde artış olması, potansiyel genliklerinin artması ve polifazik potansiyel oranının artmasıdır. Ön boynuz motor nöron hastalığı olan ALS (Amyotrofik Lateral

Sklerozis)’ de motor nöron hastalığı olarak da bilinmektedir. Hastalığın adının anlamı omurilikte kaslara giden yan (lateral) taraftaki sinir hücrelerinin etkilenmesiyle kasların beslenememesi ve katılaşmasıdır. ALS hastalığında MUAP’ ların ortalama süreleri ileri derecede uzamıştır. Polifazik geniş süreli MUAP sayısı artmıştır, MUAP’ ların genlikleri ileri derecede artmıştır. Eski EMG literatüründe bunlara “Dev” MUAP denmektedir.


Miyojenik hastalıklarda MUAP’ ların normale göre sürelerinin çok kısaldığı ve genliklerinin çok küçüldüğü kolaylıkla izlenir. İncelenen kasa göre değişmekle beraber bu potansiyellerin süresi genellikle 5 msn’ den daha kısadır. Hatta 1-3 msn süreli MUAP’ lara oldukça sık rastlanır. Hatırı sayılır sıklıkla polifazik potansiyel artışı görülür. Polifazik MUAP’ ların süresi bifazik, trifazik olanlara göre kuşkusuz daha uzun, normal kasta görülen polifazik potansiyellere göre daha kısadır. Çizelge 2.2’ de Nörojenik/ Miyojenik EMG ayrımı verilmiştir.

Çizelge 2.2. Nörojenik / Miyojenik EMG Ayrımı (Ertekin, 2006)

	Nörojenik	Miyojenik
1. Spontan fibrilasyon (titreşim) ve pozitif keskin dalgalar	Oldukça sık ve genellikle distallerde (merkezden uzak)	Oldukça seyrek ve genellikle proksimallerde (merkeze yakın)
2.Fasikülasyon (istemsiz kasılma) potansiyelleri	Sık (ALS gibi)	Çok seyrek
3. MUAP süresi	Artar (% 20 üzeri)	Azalır (% 20 altı)
4. MUAP genliği	Artar veya normal	Azalır
5. Polifazik MUAP tipi	Geniş süreli gruplaşmış dikenler	Kısa süreli küçük genlikli dikenler

3. MATERYAL VE YÖNTEMLER

Bu bölümde EMG verilerinden özellik çıkarılması, anlamlandırılması sınıflandırılması için kullanılan algoritmalar açıklanacaktır. Kullanılan ana yapının öbek çizgesi Şekil 3.1’ de verilmiştir.



Şekil 3.1. Öbek Çizgesi

3.1 Veri Edinme Ve Ön İşlem


Bu çalışmada kullanılan veriler EMGLAB internet sitesinden alınmıştır (Şekil 3.2). Veriler 8 saniye boyunca Şekil 3.3’ deki biceps brachial, vastus medialis, abductor pollicis brevis, tibialis anterior, vastus lateralis, triceps brachii, deltoid kaslarından iğne elektrot ile alınmıştır. Bu EMG işaretleri 10 normal (21-37 yaş aralığı), 7 miyopati (19-63 yaş aralığı) ve 8 ALS (37-67 yaş aralığı) olan kişilerden alınmıştır. EMG işaretlerine analog band geçiren filtre (2 Hz-10 KHz) uygulanmıştır. İşaretler 23.438 KHz’ de örneklenmiştir.

Şekil 3.4, Şekil 3.5’ de ALS, miyopati ve sağlıklı kişilerden alınan EMG kayıtlarının ilk 2 saniyesi gösterilmektedir. Bu kayıtlar EMG işaretlerinin periyodik olmadığının ve zamanda değişkenlik gösterdiğinin bir ispatıdır. EK B’ de farklı tip EMG kayıtlarına yer verilmiştir.

EMGLAB[Home](#)[Software](#)[Signals](#)[Presentations](#)[Publications](#)

EMGLAB

A forum for sharing software, data, and information related to EMG decomposition.



EMG decomposition provides information about the coordinated activity of the motoneuron pool and the architectural organization of the muscle. This information is of interest in muscle physiology, motor control, kinesiology, and clinical neurophysiology.


The goals of this project are to promote

- * decomposition as a research tool
- * exchange and discussion of EMG data
- * attention to accuracy and precision
- * algorithm innovation


Projects	Software	News	Tutorials
* Standards for data files * EMG signal database * Assessing accuracy * EMG analysis software	* EMGlab version 1.0  New features include continuous scrolling, force display, exporting plots and data, printing.	* ISEK Decomposition Workshop 2008 * R010: 20-min contraction, cut-end fine wire.	Please Contribute Discussion EMGLab RSS  FAQ

sponsors: Veterans Affairs Palo Alto Rehabilitation Research and Development Center | National Institute of Neurological Disorders and Stroke


Şekil 3.2. EMGLAB internet sayfası (URL-3, 2011)



Şekil 3.3. Çeşitli Kas Grupları



Şekil 3.4. ALS, Sağlıklı ve Miyopati Hastasına Ait EMG Verileri




Şekil 3.5. ALS, Sağlıklı ve Miyopati Hastasına Ait EMG Verileri

EMG ölçümü sırasında elektrotların vücutla etkileşimi ve hareketleri nedeniyle EMG işaretinin izoelektrik çizgide kayma/dalgalanmalar (Baseline drift/Baseline wander) meydana gelmektedir. Bu kaymalar EMG’ den elde edilen bazı önemli bilgilerin bozulmasına neden olmaktadır. EMG işaretini doğru yorumlamak için bu kaymaları yok etmek gerekmektedir. EMG işaretindeki yüksek frekans bileşenli gürültüyü ve düşük frekanslı kaymaları gidermek için bu çalışmada “Butterworth” ve “Chebyshev” bant geçiren süzgeçler kullanılmıştır.


Butterworth süzgecin geçiş bandında ve durdurma bandında dalgalanma yoktur. Fonksiyon tek düze olarak azalır. Butterworth süzgeç diğer süzgeçlerden farklı olarak, derecesi arttığında durma bandındaki sert düşüş yaşanır.

Chebyshev süzgecin geçirme bandı Butterworth süzgece göre daha dardır ve geçirme (veya durdurma) bandında dalgacıklar vardır. Chebyshev süzgeci mevcut dalgacıklar dışında bu özelliği sayesinde ideal süzgece daha yakındır. Eğer süzgeçte dalgacıklar geçirme bandında ise bu Chebyshev 1. tipi süzgeçtir. Eğer dalgacıklar durdurma bandında ise Chebyshev 2. tip süzgeç olarak isimlendirilir.


Gürültüden etkilenmemek için Şekil 3.6’ da verilen EMG işaretinin güç spektrumuna bakılarak her iki süzgeç için frekans aralığı için 10-1500 Hz seçilmiştir. Şekil 3.7’ de EMG işaretinin izoelektrik çizgideki dalgalanma gösterilmiştir. Bu dalgalanmayı gidermek için yüksek geçiren süzgeç kullanılması durumunda elde edilen EMG işareti görülmektedir.



Şekil 3.6. EMG İşaretinin Frekans Tayfı




Şekil 3.7. EMG İşaretinde Dalgalanmaya Neden Olan Düşük Frekanslı Gürültü



Şekil 3.8. İzoelektrik Çizgideki Dalgalanmanın Giderilmesi

EMG işaretindeki gürültülerin giderilmesi sırasında EMG işaretinde hastalık tanı ve teşhiste gerekli olan bilgileri yok etmeyecek şekilde süzgeç kullanılmalıdır. EMG tanısında önemli olan bilgilerden biride dönüş sayısıdır. Bir MUAP içinde genliği 100 uV aşan her bir yukarı – aşağı veya aşağı – yukarı sapma bir dönüş olarak adlandırılır (Şekil 2.3). Şekil 3.9’da EMG işaretine Butterworth ve Cheybshev alçak geçiren süzgeç kullanılmış ve süzgecin kesim frekansı 1500 Hz seçilmesi durumunda Chebyshev’de Butterworth’ a göre daha az gecikme vardır. Süzgeçlenmiş işarete Chebyshev süzgeçte genlik kaybının daha az olduğu, Butterworth süzgeç kullanıldığında dönüş genliğinin 100 uV’ un altına düştüğü görülmüştür.



Şekil 3.9. Butterworth ve Cheybshev Süzgeç ile Süzgeçlenmiş EMG İşareti

3.2 Bölütleme

Kas ve sinir kontrolü ile ilgili mekanizmaları anlamak için bölütleme gereklidir. Bu bölümde EMG işaretlerinden MUAP' ların belirlenmesi için MUAP tepeleri bularak bölütleme yöntemi ve MUAP' ların başlangıç ve bitiş noktaları bulunarak bölütleme yöntemleri denenmiştir.

3.2.1 MUAP tepeleri bularak bölütleme

MUAP tepeleri bularak bölütleme yöntemi dört adımda gerçekleşir (Kaur, ve diğ., 2009):

Adım 1: Eşik Hesaplama

Literatürde yapılan çalışmalarda MUAP genliği için standart bir eşik seviyesi kullanılmamaktadır. (Dorfman LJ ve McGill, 1988), eşik genliğini 20–50 uV (Stalberg, ve diğ., 1995), 30 uV ve (Andreassen, 1987) çalışmasında eşik genliğini, 50 uV olarak seçmiştir. Bu çalışma da eşik değeri 50 uV olarak seçilmiştir.


Adım 2: EMG işaretinde eşiği aşan tepeler belirlenir.

Eşiği aşan tüm tepeler matlab programının işaret işleme kısmında yer alan yerel maksimum algoritması kullanılarak bulunmuştur (Version 6.8 Signal Processing


Toolbox-findpeaks.m). Ancak en büyük genlikli tepelerin yanında bu noktalara yakın olan genliklerde tepe olarak sayılmıştır (Şekil 3.10).

Adım 3: Bu adımda önceden belirlenmiş tepelere yerleştirilecek olan pencerenin boyutu EMG işaretindeki MUAP' ların süresine bağlıdır. MUAP süresi kişinin yaşına ve sağlıklı olup olmamasına, hastalık çeşidine, işaretin alındığı kas çeşidine göre değişkenlik göstermektedir. Örneğin genç bir erişkinde Tibialis anterior kasında ortalama MUAP süresi 10-12 ms iken, yüz mimik kaslarında 4-5 ms' dir. ALS' de MUAP' ların süresi normale göre iki kat uzamaktadır. Süreleri brachial biceps, el kasları ve tibialis anterior kaslarında 20-30 ms bulabilir (Ertekin, 2006). Bu durumları içine alacak şekilde sabit olan pencere genişliği; 30 ms sürecek şekilde belirlenmiştir.


Adım 4: Tepeler elde edildikten sonra 30 ms süren pencere ilk tepeye yerleştirilir, pencere içerisinde daha büyük genlikli tepe varsa pencere o tepenin tam ortasına gelecek şekilde yerleştirilir (pencere içerisinde kalan en büyük MUAP tepeleri Şekil 3.11' de verilmiştir). Son olarak pencere içerisinde kalan motor birim saklanır. Bir sonraki bölütlemeye pencere, bir önceki pencere dışında kalan tepeye kaydırılarak gerçekleştirilir. Bu işlem adımları ile yapılan bölütleme sonuçları Şekil 3.12, Şekil 3.13' de verilmiştir.




Şekil 3.10. Eşiği Aşan Tepeler



Şekil 3.11. Eşiği Aşan MUAP Tepeleri



Şekil 3.12. EMG İşaretindeki MUAP' lar



Şekil 3.13. Bölütleme Sonucunda Elde Edilen 30 ms Süreli MUAP’ lar

Bu yöntemin eksik yanı kişinin yaşına, hastalık ve kas çeşidine göre değişkenlik gösteren MUAP’ ları sabit bir pencere ile bölütlemesidir. Bunun sonucu olarak MUAP’ ları süresi bitmeden kırpabilir veya farklı MUAP’ ları tek bir MUAP gibi alarak hatalı bir ayırtırmaya sebep olabilir.

3.2.2 MUAP’ ların başlangıç ve bitiş noktaları bulunarak bölütleme

Adım 1: EMG işaretinde eşiği aşan tepeler belirlenir.

Eşik değeri 50 uV olarak seçilmesi durumunda elde edilen tepeler Şekil 3.14’ de verilmiştir.

Adım 2: MUAP’ ların başlangıç ve bitiş noktalarını bulmak için EMG işareti üzerinde kayan 1 ms süren pencerenin alt ve üst eşik değerinin belirlenmesi.

İşaret üzerinde kayan pencerenin dalga biçimine göre tolerans aralığı bu çalışmada 1ms süren pencere içerisinde kalan noktalardan genlik olarak ortanca genliğin $\pm 40\text{uV}$ değeri alt ve üst eşik değeri olarak belirlenmiştir.


Adım 3: Başlangıç ve bitiş noktasına aday olacak noktaların belirlenmesi (Şekil 3.15):

eğer Adım 2’de belirlenen pencere içerisinde alt ve üst eşiği aşan tepe yoksa bu noktalardan ortancası başlangıç veya bitiş noktası olmaya adaydır.


değilse (pencere içerisinde en az bir nokta eşik değerini aşarsa)
pencere içerisindeki noktalar dikkate alınmaz.

Adım 4: Adım 1’de EMG işaretinde eşiği aşan her bir MUAP tepesinin solunda kalan Adım 2’de bulunan ilk aday nokta MUAP’ ın başlangıç noktası olurken; sağında kalan ilk aday nokta MUAP’ ın bitiş noktasıdır (Şekil 3.16).


Bu işlem adımları ile yapılan bölütleme sonuçları Şekil 3.17’ de verilmiştir. Bu yöntem sonucunda elde edilen aynı MUAP’ lar arasında faz kayması olduğu görülmektedir. Bu durum kümeleme sırasında MUAP’ ların hatalı kümelenmesine neden olacaktır. Bunu ortadan kaldırmak için Şekil 3.18’ de bölütleme sonucunda elde edilen her bir MUAP tepe noktalarında üst üste gelecek şekilde çakıştırılmıştır.




Şekil 3.14. Eşiği Aşan MUAP Tepeleri




Şekil 3.15. Başlangıç ve Bitiş Noktasına Aday Olacak Nokta



Şekil 3.16. MUAP' ın Başlangıç ve Bitiş Noktaları



Şekil 3.17. Bölütleme Sonucunda Elde Edilen MUAP' lar



Şekil 3.18. Bölütleme Sonucunda Elde Edilen MUAP' ların Üst Üste Getirilmesi


3.3 Kümeleme

Bu adımda aynı ya da benzer şekilli MUAP' ların aynı kümede toplanması amaçlanmıştır. MUAP' ların kümelenmesi bundan sonraki aşamada küçük boyutlu veri seti ile işlem yapılmasına imkan sağlayacaktır.

Bu bölümde kendini düzenleyen haritalar ile BCO (Bulanık C- Ortalamalar) algoritmaların birleşiminden oluşan melez kümeleme yöntemi ve hiyerarşik kümeleme yöntemi denenmiştir.

3.3.1 Hiyerarşik (Aşamalı) kümeleme

Hiyerarşik kümeleme metotları, veri setinin birimlerinin birbirlerine olan uzaklık değerlerini kullanarak, veri setindeki birimlerin hiyerarşik ayrıştırmasını yapar. Hiyerarşik ayrıştırma sırasında, “ağaç veri yapısı” olarak da bilinen dendogram kullanılır. Dendogram, hiyerarşik kümeleme tekniğiyle elde edilen kümelerin görselleştirilmesini sağlar. Şekil 3.19' da gösterilen bir dendogramın yapısı kökler, iç düğüm ve yapraklardan oluşur.



Şekil 3.19. Ağaç Veri Yapısı

Hiyerarşik kümeleme yaklaşımında, veri noktaları en iyi kümeleme yapısı elde edilene kadar belirli düzeylerde birleştirilir ya da ayrıştırılır. Bu algoritmalar için küme sayısının önceden bilinmesine gerek yoktur.

Hiyerarşik kümelemenin avantajları aşağıdaki gibi sıralanabilir:

- Düzümlerin seviyesine ilişkin esneklik özelliğinin olması
- Benzerlik ve uzaklık biçimlerini ele almanın kolaylığı
- Çeşitli niteliklere uygulanabilme özelliğinin olması

Hiyerarşik kümelemenin dezavantajları ise şu şekildedir:


- Bitirme kriterinin belirsizliği
- Gerçekte çoğu hiyerarşik kümeleme algoritması, geliştirilme amaçlarına

göre arada bulunan kümelere (dendogramda) tekrar ulaşılmasına izin vermez.

Analiz etmeden önce nesneler, hiyerarşik bir yapıya göre düzenlenir. Veriyi hiyerarşik bir yapıya çevirmek için değişik yöntemler kullanılır. Bu yöntemler aşağıdaki gibi iki tipte sınıflandırılabilir:

1. Birleştirme yaklaşımı: Her bir nesne ayrı bir grup oluşturur. Birbirine yakın nesneler veya gruplar birleştirilir.
2. Bölme yaklaşımı: Bütün nesneler başlangıçta aynı kümededir. Her ötelemede küme daha küçük kümelere ayrıştırılır.

Birleştirici ve ayrıştırıcı hiyerarşik kümeleme algoritmalarının genel çalışması Şekil 3.20' de verilmiştir.



Şekil 3.20. Birleştirici ve Ayrıştırıcı Hiyerarşik Kümeleme Algoritmalarının Genel Çalışması (Gan, ve diğ., 2007)

Birleştirme yaklaşımı için hangi kümelerin birleştirileceğine, bölme yaklaşımı içinse kümenin nereden bölüneceğine karar verebilmek için gözlemlerin oluşturduğu gruplar arasındaki farklılıkların ölçülebilmesine ihtiyaç duyulmaktadır. Çoğu hiyerarşik kümeleme yöntemlerinde, bu durum uygun bir uzaklık ölçüsü ve gözlemlerin ikili mesafelerinden oluşan bir fonksiyon gibi gruplardaki farklılıkları belirten bir bağlantı kriteri kullanarak elde edilir. Bulunan birimleri kümelerken,

değişik uzaklık ölçüleri kullanılır. Bu ölçülerden bazıları: Öklid, Manhattan, Minkowski uzaklık ölçüleridir. Uzaklık formülleri p boyuta sahip 2 birim arasındaki uzaklığa göre verilmiştir.

Öklid Uzaklık Ölçüsü:

Öklid uzaklık ölçüsü kullanılarak iki birim arasındaki uzaklık denklem (3.1)' deki gibi hesaplanır.

$$d(i, j) = \sqrt{(x_{i1} - x_{j1})^2 + (x_{i2} - x_{j2})^2 + \dots + (x_{ip} - x_{jp})^2} \quad (3.1)$$

En çok kullanılan ölçü birimidir. Kümeleme analizinde kullanılacak olan değişkenler belirli bir önem derecesinde ağırlıklandırılmış ise, öklid uzaklık ölçüsü denklem (3.2)' deki gibi olur.

$$d(i, j) = \sqrt{w_1 (x_{i1} - x_{j1})^2 + w_2 (x_{i2} - x_{j2})^2 + \dots + w_p (x_{ip} - x_{jp})^2} \quad (3.2)$$

Pearson Uzaklık Ölçüsü:

Pearson uzaklık ölçüsü kullanılarak iki birim arasındaki uzaklık denklem (3.3)' deki gibi hesaplanır.

$$d(i, j) = \sqrt{(x_{i1} - x_{j1})^2 / S_1^2 + (x_{i2} - x_{j2})^2 / S_2^2 + \dots + (x_{ip} - x_{jp})^2 / S_p^2} \quad (3.3)$$

Denklem (3.3)' de kullanılan S_p , uzaklığın hesaplandığı değişkene ait varyanstır. Bununla birlikte farklı gruplar hakkında önceden bilgi sahibi olunmadığı için, uzaklık hesaplanmasında S değerinin kullanılması doğru olmaz. Bu nedenle Pearson uzaklık ölçüsü yerine genellikle Öklid uzaklık ölçüsü tercih edilir. Kümeleme analizinde kullanılacak olan değişkenler belirli önem derecelerine göre ağırlıklandırılmış ise, Pearson uzaklık ölçüsü denklem (3.4)' deki gibi olur.

$$d(i, j) = \sqrt{w_1 (x_{i1} - x_{j1})^2 / S_1^2 + w_2 (x_{i2} - x_{j2})^2 / S_2^2 + \dots + w_p (x_{ip} - x_{jp})^2 / S_p^2} \quad (3.4)$$

Pearson uzaklık ölçüsüne, “karesel Pearson uzaklık” ya da “standart Öklid uzaklığı” adı da verilir.

Manhattan Uzaklık Ölçüsü:

Manhattan uzaklık ölçüsü kullanılarak iki birim arasındaki uzaklık denklem (3.5)' deki gibi hesaplanır.

$$d(i, j) = (|x_{i1} - x_{j1}| + |x_{i2} - x_{j2}| + \dots + |x_{ip} - x_{jp}|) \quad (3.5)$$

Bu ölçü de birimler arasındaki mutlak uzaklık kullanılır. Kümeleme analizinde kullanılacak olan değişkenler eğer belirli bir önem derecesinde ağırlıklandırılmış ise, Manhattan uzaklık ölçüsü formülü denklem (3.6)'daki gibidir.

$$d(i, j) = (w_1|x_{i1} - x_{j1}| + w_2|x_{i2} - x_{j2}| + \dots + w_p|x_{ip} - x_{jp}|) \quad (3.6)$$

Manhattan uzaklık ölçüsüne, “city block uzaklık ölçüsü” adıda verilir.

Minkowski Uzaklık Ölçüsü:

Minkowski uzaklık ölçüsü genel bir formüldür. Formülde yer alan m değerinin alacağı farklı değerlere göre yeni formüller türetilir. Minkowski uzaklık ölçüsü kullanılarak iki birim arasındaki uzaklık denklem (3.7)'deki gibi hesaplanır.

$$d(i, j) = \left[|x_{i1} - x_{j1}|^m + |x_{i2} - x_{j2}|^m + \dots + |x_{ip} - x_{jp}|^m \right]^{1/m} \quad (3.7)$$

Kümeleme analizinde kullanılacak olan değişkenler belirli önem derecelerine göre ağırlıklandırılmış ise, Minkowski uzaklık ölçüsü formülü denklem (3.8) gibidir.

$$d(i, j) = \left[w_1|x_{i1} - x_{j1}|^m + w_2|x_{i2} - x_{j2}|^m + \dots + w_p|x_{ip} - x_{jp}|^m \right]^{1/m} \quad (3.8)$$

Minkowski uzaklık ölçüsündeki m değeri büyük ve küçük farklara verilen ağırlığı değiştirir. m = 1 değerini alırsa, formül, Manhattan uzaklık ölçüsünün formülüne, m = 2 değerini alırsak, formül Öklid uzaklık ölçüsü formülüne dönüşür.

Yaygın olarak kullanılan bazı bağlantı kriterleri: tek bağlantımlı kümeleme yöntemi, tam bağlantımlı kümeleme yöntemi ve ortalama bağlantılı kümeleme yöntemidir.


3.3.1.1 Tek bağlantılı kümeleme yöntemi

İki küme elemanları arasındaki en kısa uzaklık değeri ile ölçülür (Şekil 3.21). En yakın komşu metodu olarak ta adlandırılan tek bağlantımlı kümeleme metodunun uzaklık formülü denklem (3.9)'da verilmiştir.

$$D(C, C') = \min_{x \in C, y \in C'} d(x, y) \quad (3.9)$$


C, C' : kümeler

$d(x, y)$: x ve y noktaları arasındaki uzaklık.



Şekil 3.21. Tek Bağlantılı Kümeleme Yöntemi (Patil, 2007)

Şekil 3.22’ deki veri setine ait Öklid uzaklık vektörünün karesel formu Çizelge 3.1’ de verilmiştir.



Şekil 3.22. İki Boyutlu Veri Seti (Gan, ve diğ., 2007)

Çizelge 3.1. İki Boyutlu Veri Setine Ait Öklid Uzaklık Vektörünün Karesel Formu

	x_1	x_2	x_3	x_4	x_5
x_1	0	0,5	2,24	3,35	3
x_2	0,5	0	2,5	3,61	3,04
x_3	2,24	2,5	0	1,12	1,41
x_4	3,35	3,61	1,12	0	1,5
x_5	3	3,04	1,41	1,5	0

Çizelge 3.1’ de en az mesafeye sahip noktalar $\{x_1, x_2\}$ olarak belirlenir. Bu adımdan sonra uzaklık hesabı denklem (3.10)’ da; $\{x_1, x_2\}$, x_3 , x_4 ve x_5 arasında yapılır. Bu durumda Öklid uzaklık vektörünün karesel formu Çizelge 3.2’ deki gibi hesaplanır.

$$\begin{aligned}
D(\{x_1, x_2\}, x_3) &= \min \{d(x_1, x_3), d(x_2, x_3)\} = 2.24 \\
D(\{x_1, x_2\}, x_4) &= \min \{d(x_1, x_4), d(x_2, x_4)\} = 3.35 \\
D(\{x_1, x_2\}, x_5) &= \min \{d(x_1, x_5), d(x_2, x_5)\} = 3
\end{aligned} \tag{3.10}$$

Çizelge 3.2. Öklid Uzaklık Vektörünün Karesel Formu

	$\{x_1, x_2\}$	x_3	x_4	x_5
$\{x_1, x_2\}$	0	2.24	3.35	3
x_3	2.24	0	1.12	1.41
x_4	3.35	1.12	0	1.5
x_5	3	1.41	1.5	0

Çizelge 3.2’ de en az mesafeye sahip noktalar x_3, x_4 tür. Bu adımdan sonra mesafe hesabı denklem (3.11)’ deki dibi $\{x_3, x_4\}$ grubu ile diğer gruplar arasında yapılır.

$$\begin{aligned}
D(\{x_3, x_4\}, \{x_1, x_2\}) &= \min \{d(x_1, x_3), d(x_2, x_3), d(x_1, x_4), d(x_2, x_4)\} \\
&= \min \{D(\{x_1, x_2\}, x_3), D(\{x_1, x_2\}, x_4)\} = 2.24 \\
D(\{x_3, x_4\}, x_5) &= \min \{d(x_3, x_5), d(x_4, x_5)\} = 1.41
\end{aligned} \tag{3.11}$$


Çizelge 3.3. Öklid Uzaklık Vektörünün Karesel Formu

	$\{x_1, x_2\}$	$\{x_3, x_4\}$	x_5
$\{x_1, x_2\}$	0	2.24	3
$\{x_3, x_4\}$	2.24	0	1.41
x_5	3	1.41	0

Çizelge 3.3’ de en az mesafeye sahip noktalar $\{x_3, x_4\}$ ve x_5 tür. Bu adımdan sonra mesafe hesabı $\{x_3, x_4, x_5\}$ grubu ile $\{x_1, x_2\}$ grubu arasında yapılır (Çizelge 3.4). Bu sınıflama için ağaç veri yapısı Şekil 3.23’ de verilmiştir.

Çizelge 3.4. Öklid Uzaklık Vektörünün Karesel Formu

	$\{x_1, x_2\}$	$\{x_3, x_4, x_5\}$
$\{x_1, x_2\}$	0	2.24
$\{x_3, x_4, x_5\}$	2.24	0



Şekil 3.23. Tek Bağlantılı Kümeleme Yöntemi Kullanılarak Elde Edilmiş Ağaç Veri Yapısı


3.3.1.2 Tam bağlantılı kümeleme yöntemi

İki küme elemanları arasındaki en uzak mesafe değeri ile ölçülür (Şekil 3.24). Tam Bağlantılı kümeleme metodunun uzaklık formülü denklem (3.12)' de verilmiştir.

$$D(C, C') = \max_{x \in C, y \in C'} d(x, y) \quad (3.12)$$

C, C' : kümeler

$d(x, y)$: x ve y noktaları arasındaki uzaklık



Şekil 3.24. Tam Bağlantılı Kümeleme Yöntemi (Patil, 2007)

Çizelge 3.1' de en az mesafeye sahip noktalar $\{x_1, x_2\}$ idi. Bu adımdan sonra uzaklık hesabı denklem (3.13)' de; $\{x_1, x_2\}$, x_3 , x_4 ve x_5 arasında yapılır. Bu durumda öklid uzaklık vektörünün karesel formu Çizelge 3.5' de verilmiştir.

$$\begin{aligned} D(\{x_1, x_2\}, x_3) &= \max \{d(x_1, x_3), d(x_2, x_3)\} = 2.5 \\ D(\{x_1, x_2\}, x_4) &= \max \{d(x_1, x_4), d(x_2, x_4)\} = 3.16 \\ D(\{x_1, x_2\}, x_5) &= \max \{d(x_1, x_5), d(x_2, x_5)\} = 3.04 \end{aligned} \quad (3.13)$$

Çizelge 3.5. Şekil 3.22’ deki Veri Setine Ait Öklid Uzaklık Vektörünün Karesel Formu (Patil, 2007)

	$\{x_1, x_2\}$	x_3	x_4	x_5
$\{x_1, x_2\}$	0	2,5	3,61	3,04
x_3	2,5	0	1,12	1,41
x_4	3,61	1,12	0	1,5
x_5	3,04	1,41	1,5	0

İkinci adımda Çizelge 3.5’ de aralarında en az mesafe olan x_3, x_4 birleştirilir. Mesafe hesabı $\{x_3, x_4\}$ grubu diğer kalan gruplar denklem arasında güncellenir (denklem (3.14)).

$$\begin{aligned}
 D(\{x_1, x_2\}, \{x_3, x_4\}) &= \max\{d(x_1, x_3), d(x_2, x_3), d(x_1, x_4), d(x_2, x_4)\} \\
 &= \max\{D(\{x_1, x_2\}, x_3), D(\{x_1, x_2\}, x_4)\} = 3,61 \\
 D(\{x_3, x_4\}, x_5) &= \max\{d(x_3, x_5), d(x_4, x_5)\} = 1,5
 \end{aligned} \tag{3.14}$$

Çizelge 3.6. Öklid Uzaklık Vektörünün Karesel Formu


	$\{x_1, x_2\}$	$\{x_3, x_4\}$	x_5
$\{x_1, x_2\}$	0	3,61	3,04
$\{x_3, x_4\}$	3,61	0	1,5
x_5	3,04	1,5	0

Üçüncü adımda Çizelge 3.6’ ya göre $\{x_3, x_4\}$ ve x_5 birleştirilir. Mesafe hesabı denklem (3.15)’ deki gibi hesaplanır (Çizelge 3.7). Bu sınıflama için ağaç veri yapısı (dendogram) Şekil 3.25’ de verilmiştir.

$$\begin{aligned}
 D(\{x_1, x_2\}, \{x_3, x_4, x_5\}) &= \max\{d_{13}, d_{14}, d_{15}, d_{23}, d_{24}, d_{25}\} \\
 &= \max\{D(\{x_1, x_2\}, \{x_3, x_4\}), D(\{x_1, x_2\}, x_5)\} = 3,61
 \end{aligned} \tag{3.15}$$

Çizelge 3.7. Öklid Uzaklık Vektörünün Karesel Formu

	$\{x_1, x_2\}$	$\{x_3, x_4, x_5\}$
$\{x_1, x_2\}$	0	3,61
$\{x_3, x_4, x_5\}$	3,61	0



Şekil 3.25. Tam Bağlantılı Kümeleme Yöntemi Kullanılarak Elde Edilmiş Ağaç Veri Yapısı


3.3.1.3 Ortalama bağlantılı kümeleme yöntemi

İki kümedeki noktaların birbirine uzaklığının ortalaması alınarak bulunan mesafe değeri ile ölçülür (Şekil 3.26). Ortalama Bağlantılı kümeleme metodunun uzaklık formülü denklem (3.16)' de verilmiştir.

$$D(C, C') = \text{avg}_{x \in C, y \in C'} d(x, y) \quad (3.16)$$

C, C' : kümeler

$d(x, y)$: x ve y noktaları arasındaki uzaklık



Şekil 3.26. Ortalama Bağlantılı Kümeleme Yöntemi (Patil, 2007)

Ortalama bağlantılı kümeleme yönteminde Şekil.3.22' deki veri seti kullanılması durumunda ilk adımda x_1, x_2 birleştirilir. Sonrasında $\{x_1, x_2\}$ ve diğer üç veri arasındaki mesafe denklem (3.17)' deki gibi hesaplanır. Bu durumda Öklid uzaklık vektörünün karesel formu Çizelge 3.8' de verilmiştir.

$$\begin{aligned}
D(\{x_1, x_2\}, x_3) &= \frac{1}{2}d(x_1, x_3) + \frac{1}{2}d(x_2, x_3) = 2.37 \\
D(\{x_1, x_2\}, x_4) &= \frac{1}{2}d(x_1, x_4) + \frac{1}{2}d(x_2, x_4) = 3.48 \\
D(\{x_1, x_2\}, x_5) &= \frac{1}{2}d(x_1, x_5) + \frac{1}{2}d(x_2, x_5) = 3.02
\end{aligned} \tag{3.17}$$

Çizelge 3.8. Şekil.3.22’ teki Veri Setine Ait Öklid Uzaklık Vektörünün Karesel Formu

	$\{x_1, x_2\}$	x_3	x_4	x_5
$\{x_1, x_2\}$	0	2.37	3.48	3.02
x_3	2.37	0	1.12	1.41
x_4	3.48	1.12	0	1.5
x_5	3.02	1.41	1.5	0

İkinci adımda Çizelge 3.8’ de aralarında en az mesafe olan x_3, x_4 birleştirilir. Mesafe hesabı $\{x_3, x_4\}$ grubu diğer kalan gruplar arasında denklem (3.18)’ deki gibi güncellenir.

$$\begin{aligned}
D(\{x_1, x_2\}, \{x_3, x_4\}) &= \frac{1}{2}D(\{x_1, x_2\}, x_4) + \frac{1}{2}D(\{x_1, x_2\}, x_3) = 2.93 \\
D(\{x_3, x_4\}, x_5) &= \frac{1}{2}d.(x_3, x_5) + \frac{1}{2}d.(x_4, x_5) = 1.46
\end{aligned} \tag{3.18}$$

Çizelge 3.9. Öklid Uzaklık Vektörünün Karesel Formu

	$\{x_1, x_2\}$	$\{x_3, x_4\}$	x_5
$\{x_1, x_2\}$	0	2.93	3.02
$\{x_3, x_4\}$	2.93	0	1.46
x_5	3.02	1.46	0

Üçüncü adımda Çizelge 3.9’ ya göre $\{x_3, x_4\}$ ve x_5 birleştirilir.


$$D(\{x_1, x_2\}, \{x_3, x_4, x_5\}) = \frac{2}{3}D(\{x_1, x_2\}, \{x_3, x_4\}) + \frac{1}{3}D(\{x_1, x_2\}, x_5) = 2.96 \tag{3.19}$$

Çizelge 3.10. Öklid Uzaklık Vektörünün Karesel Formu

	$\{x_1, x_2\}$	$\{x_3, x_4, x_5\}$
$\{x_1, x_2\}$	0	2.96
$\{x_3, x_4, x_5\}$	2.96	0


En son adımda $\{x_1, x_2\}$ ve $\{x_3, x_4, x_5\}$ arasındaki mesafe denklem (3.20)' deki gibi hesaplanır. Bu sınıflama için ağaç veri yapısı Şekil 3.27' de verilmiştir.

$$D(\{x_1, x_2\}, \{x_3, x_4, x_5\}) = \frac{1}{6}(d_{13} + d_{14} + d_{15} + d_{23} + d_{24} + d_{25}) = 2.96 \quad (3.20)$$




Şekil 3.27. Ortalama Bağlantılı Kümeleme Yöntemi Kullanılarak Elde Edilmiş Ağaç Veri Yapısı

Dendrogram istenilen seviyede kesilerek, veri parçalarının ayrı gruplarla bir kümelemesi elde edilebilir. Örneğin Şekil 3.28' de eşik değeri sırasıyla a' da 3.0, b' de 2.0 ve c' de 0.8 seçildiğinde bulunan küme sayıları 2,3 ve 4' tür.



Şekil 3.28. Belirli Eşik Değerlerine Göre Elde Edilen Kümeler (Winslow, 2008)

Şekil 3.29’ da bölütleme sonucu elde edilen MUAP’ lar (Şekil 3.29-b), Tam Bağlantılı Kümeleme Yöntemi ile kümelendirildiğinde elde edilen ağaç veri yapısı (Şekil 3.29-a), ve belirli eşik değerine karşılık elde edilen kümeleme sonuçları (Şekil 3.29-c), verilmiştir. Burada eşik değeri kullanıcı girişlidir bu uygulamada eşik değeri her bir eşleştirme sonucunda elde edilen Öklid mesafesinin en büyük değeri belirli bir katsayı ile çarpılarak elde edilmiştir. Denemeler sonucunda en iyi sonucu veren katsayı 0.66 olarak belirlenmiştir.



Şekil 3.29. Ağaç Veri Yapısı ve Belirli Eşik Değerlerine Karşılık Elde Edilen Kümeleme Sonuçları

3.3.2 Kendini düzenleyen haritalar (kohonen ağı) ile kümeleme


Kohonen, beyindekine benzer, kendi kendini düzenleme öznelik haritası adını verdiği bir ağ modeli sunmuştur (Türkoğlu, 1996). Kohonen ağları, başlangıçta grupları belli olmayan verileri kümelemeyi amaçlamaktadır. Kohonen ağı, bir tür

eğiticiyiz yarışmacı öğrenme kuralıdır (Kohonen, 1984). Çünkü Kohonen ağlarında kestirim yapacak bir çıktı değişken bulunmamaktadır. Kohonen algoritması, yarışmacı öğrenme algoritması olarak da adlandırılır.

Bu öğrenme yönteminde aşağıdaki ön koşullar kabul edilir :

1. Bütün hücreler birbirlerine bağlıdır.
2. Aynı anda sadece 1 hücre aktif olabilir.
3. Bir hücre içindeki bütün ağırlıkların toplamı 1 dir.

Basit işlem elemanlarından oluşan Kohonen yapay sinir ağı, Şekil 3.30' da gösterildiği gibidir.



Şekil 3.30. Kohonen Ağ Yapısı

Şekil 3.30' da N çıkış işlem elemanı ($z_1, z_2, \dots, z_N$) sayısı, $x_i = (x_1, x_2, \dots, x_n)$ n boyutlu giriş örüntü vektörü, $w_i = (w_{11}, w_{12}, \dots, w_{Nn})$ her çıkış işlem elemanının ağırlık vektörü olup, w_{ij} ise x_j girişi ile i. işlem elemanı arasındaki ağırlıktır. Her bir giriş veri dizisi P olarak adlandırılırsa $P_1, P_2, P_3, \dots, P_m$ biçimli bir veri setimiz olmaktadır.

Kohonen Ağının İşlem Adımları:

Adım 1: Başlangıç değerleri atanır

Başlangıçta 1 adet düğümün olduğu ($j=1$) ve o düğümün aktivasyonunun 1 olduğu ($Ns(j)=1$) kabul edilir.

$l=1$ (veri indisi) ve yarıçap d olarak belirlenir.

İlk veri dizisi (p_l) başlangıç ağırlıkları (w_l) olarak seçilir.

$$w_1 = p_1 \quad (3.21)$$

Adım 2:

Bu durumda ilk olarak her bir p_1 örneğinin w_1 ' ye olan uzaklıkları hesaplanır ve en minimum uzaklık seçilir. (Başlangıç durumunda tek bir değer vardır. $p_1-w_1=0$)

$$D = \min \| w_1 - p_1 \| \quad (3.22)$$

Adım 3:

Aşağıdaki kural uygulanarak kazanan belirlenir.

eğer $D \leq d$ bu birim kazanan birimdir.

Yani veri bu yarıçapın belirttiği küme içindedir.

değilse yeni bir birim yaratılır.

Kazanan birim için ağırlıklar yeniden düzenlenir. $\zeta(j)=1$; Kazanan birim çıkışı 1, diğer çıkışlar 0 olur.

Ağırlık güncellenir:

$$w_j(t) = w_j(t-1) + \alpha (p_1 - w_j(t-1)) \zeta(j) \quad (3.23)$$

Kazanan birimin aktivasyonu artırılır.

$$Ns(j) = Ns(j) + 1$$

$$\alpha = \alpha_0 / Ns(j) \quad : \text{öğrenme oranıdır. } \alpha_0 \in [0,1]$$

Veri dizisinin indisi artırılır.

$$l = l + 1$$

Yeni birim yaratılmışsa:

$$j = j + 1$$


Yeni birimin ağırlıkları o birimin yaratılmasına neden olan veri olarak atanır:

$$w(j) = p(l)$$

Yeni birimin aktivasyonu: $Ns(j)=1$


Bu adımlar veri dizinin adeti kadar yinelenir.

Şekil 3.31' de sentetik olarak üretilen verilerin kendini düzenleyen haritalar (Kohonen ağı) ile kümeleme kullanılarak kümelendirilmiştir. Şekil 3.31 a,b,c ve d' de yarıçap: 2,1,0.5 ve 0.1 seçildiğinde merkez (küme) sayıları şu şekildedir: 1, 3,5 ve 32 dir. Örnekte de görüldüğü üzere Kohonen ağı ile yapılan kümelemede küme sayısını girilen yarıçap belirlemektedir. Yarıçap küçüldükçe küme sayısı artmaktadır. Yarıçap daha fazla küçültülürse her bir veriyi temsil eden veri adeti kadar küme merkezi elde edilir.



Şekil 3.31. Kendini Düzenleyen Haritalar (Kohonen Ağı) ile Kümeleme Kullanılarak Farklı Yarıçap Değerlerine Karşılık Elde Edilen Merkez (Küme) Sayıları

Şekil 3.18’ de bölütleme sonucu elde edilen MUAP’ lar kendini düzenleyen haritalar ile kümeleme kullanılarak ile kümelendirilmiştir. Şekil 3.32 a,b,c’ de yarıçap: 0.1,0.5 ve 1 seçildiğinde küme sayıları şu şekildedir: 8, 3 ve 2’ dir.



Şekil 3.32. Kendini Düzenleyen Haritalar ile Kümeleme Kullanılarak Belirli Eşik Değerlerine Karşılık Elde Edilen Küme Sayıları

3.3.3 Bulanık c-ortalamalar (fuzzy c-means) algoritması ile kümeleme

Literatürde en iyi bilinen ve yaygın olarak kullanılan Bulanık C-Ortalamlar algoritması (BCO), ilk kez 1973 yılında Dunn tarafından ortaya atılmış ve 1981’ de Bezdek tarafından geliştirilmiş bir kümeleme algoritmasıdır (Höppner, 2000), (Bezdek, 1984). Bulanık C- Ortalamalar algoritması da amaç fonksiyonu temelli bir metottur. BCO’ da her bir veri birden fazla kümeye ait olabilir. Üyelik katsayısı, verilerin her bir kümeye ne oranda ait olduğunu gösterip veri ile küme merkezleri arasındaki uzaklık kullanılarak hesaplanır. Orijinal veri küme merkezine yaklaştıkça üyelik katsayısı da o oranda artış gösterir. Orijinal her bir verinin küme sayısı kadar, 0 ile 1 arasında bir değerde üyelik katsayısı olup toplamı bire eşittir. Veri hangi küme merkezine yakın ise o kümeye ait olma üyeliği diğer kümelere ait olma

üyeliğinden daha büyük olacaktır. Küme merkezleri, o kümeye ait tüm verilerin ortalaması alınarak bulunur. BCO yinelemeli bir yöntem olup her bir yinelemede tüm verilere ait üyelik katsayıları ve küme merkezleri güncellenir. Amaç fonksiyonun belirlenen minimum ilerleme değerine yakınsamasıyla kümeleme işlemi tamamlanır.

BCO algoritması 5 basit adım ile özetlenebilir (Pangborn, 2010):

- Rastgele M adet noktayı küme merkezi olarak seç.
- Her veri noktasının her küme için üyeliğini hesapla.
- Her küme için, üyeliği bu kümede ağırlıklandırılmış noktalarını toplama.
- Her küme merkezini demetin toplam üyeliğine bölerek yeniden hesapla.
- Durdurma kriterini kontrol et, sağlamadıysa adım 2'ye git.

Algoritma en küçük kareler yönteminin genellemesi olan aşağıdaki amaç fonksiyonunu öteleyerek minimize etmek için çalışır (Höppner, 2000).


$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2, \quad 1 \leq m < \infty \quad (3.24)$$

BCO'da amaç, denklem (3.24)'daki hedef fonksiyonu minimize etmektir. Burada m; birden büyük gerçek bir sayı, u_{ij} ; j. sınıfa ait x_i elemanının üyelik katsayısı, x_i ; i. veri, c_j ; j. kümenin merkezi, $\|*\|$ ise herhangi bir veri ile kümenin merkezi arasındaki uzaklığı ifade eder. Bulanık kümeleme algoritması yinelemeli olup küme merkezleri ile üyelik fonksiyonların ardı ardına güncellenmesi ile hedef fonksiyonunun minimize edilmesi esasına dayanır. Üyelik değerleri (u_{ij}) ve küme merkezleri (c_j), denklem (3.25)'deki fonksiyonlar ile bulunmaktadır.

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad C_i = \frac{\sum_{j=1}^C u_{ij}^m x_j}{\sum_{j=1}^C u_{ij}^m} \quad (3.25)$$

BCO algoritması, $0 < \varepsilon < 1$ olmak üzere, $|J(t) - J(t-1)| < \varepsilon$ kriteri sağlandığında durmaktadır.

Şekil 3.33' de görülen yapay veri seti için BCO algoritması ile elde edilen kümeleme sonuçları verilmiştir. BCO algoritmasında küme sayısının bilinmesi gereklidir. Algoritma veri içerisinde başlangıçta belirlenen küme sayısı kadar küme merkezi saptaması bu algoritmanın eksik yanlarından biridir.



Şekil 3.33. BCO Algoritması ile Elde Edilen Küme Merkezleri

3.3.3.1 BCO algoritması ile bölüt doğrulama

Literatürde çok sayıda kümeleme algoritması geliştirilmiştir. Bunlardan en yaygın kullanılan sadelik ve etkinliği ile Bulanık C-Ortalamlar Algoritması olmuştur. Bulanık C-Ortalamlar Algoritmasının eksik yanlarından biri küme sayısının önceden tespit edilmesi gerekmektedir. Bölüm doğrulamada amaç, J amaç işlevini minimize edecek en iyi küme değerini bulmaktır (Linkens ve Chen, 1997). Çeşitli küme geçerlilik kriterleri; bölüm katsayısı (Bezdek, 1974), bölüm entropi (Bezdek, 1981), bölüm yoğunluğu ve diğer bazı doğrulama ölçütleri (Yasukavva, 1993), (Windham, 1982), (Beni, 1991) önerilmiştir. Bu kriterlerin her biri başarılı doğrulama için geliştirilmiş ve kümelemede faydalı sonuçlar sağlamıştır (Linkens ve Chen, 1997). Denklem (3.26) Bezdek tarafından önerilmiştir (Yasukavva, 1993).

BCO algoritmalarıyla ilişkili küme doğrulama kriteri; basit ve yaygın olarak kullanılmaktadır.

$$H(U, c) = -\frac{1}{n} \sum_{k=1}^n \sum_{i=1}^c U_{ik} \log(U_{ik}) \quad (3.26)$$

Denklem (3.26)' de ki U_{ik} ' nin değeri çok küçük olması durumunda logaritmik fonksiyonun işlem hatası çok büyük olacaktır ve bu durum geçerlilik güvenilirliğini etkiler. Bu eksikliği gidermek için denklem (3.27)' de değiştirilmiş basit ve daha verimli küme doğrulama kriteri verilmiştir.

$$H(U, c) = -\frac{1}{n} \sum_{k=1}^n \max_i(U_{ik}) \log(\max_i(U_{ik})), \quad i = 1, 2, \dots, c \quad (3.27)$$

Denklem (3.27)' de verilen ölçüte göre ile bölüm doğrulama algoritması şu biçimde gerçekleştirilir (Linkens ve Chen, 1997):

Adım 1: Maksimum küme sayısı $c_{\max}$, yinleme sınırı T , ağırlıklandırma üsteli m ve sonlandırma kriteri $\varepsilon_{CLU} > 0$ seçilir.

Adım 2: $c = 2, 3, \dots, c_{\max}$ ve küme merkezlerinin başlangıç konumları $V_0 = (v_{10}, v_{20}, \dots, v_{c0})$ alınır.

Adım 3: $t=1, 2, \dots, T$ alınır. U üyelik matrisi ve V küme merkezleri hesaplanır (Denklem (3.28)).

$$U_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{D_{ij}}{D_{kj}} \right)^{2/(m-1)}} \quad V_i = \frac{\sum_{j=1}^c U_{ij}^m x^j}{\sum_{j=1}^c U_{ij}^m}, \quad i = 1 \dots c \quad (3.28)$$

Eğer $\|V_t - V_{t-1}\| < \varepsilon$ ise bir sonraki adıma geçilir aksi halde adım 3 yinlenir.

Adım 4: Denklem (3.27)' den $H(u, c)$ hesaplanır.


Eğer $H(c-1) < H(c)$ ve $H(c-1) < H(c-2)$ ise işlem sonlandırılır. Optimal küme sayısı $c=c-1$ olur. Aksi takdirde Adım 2 ye dönlür.

3.3.4 Melez yapı


Kohonen ağı ile kümeleme kullanıcının girdiği yarıçapa göre verileri kabaca kümelendirir. Bulduğu küme sayısı en iyi olmamasına rağmen kullanıcıya bir başlangıç değeri sunar. Bu tez çalışmasında, (Kayhan, ve diğ., 2012)' de yayınlanan makaledeki melez yapıya benzer bir yapı denenmiştir. Kohonen ağı ile BCO algoritması birlikte kullanılması yukarıda belirtilen BCO algoritmasının eksik yönünü ortadan kaldırmış olur. Ancak bu melez yapının sonucunda bulunan küme sayısı optimal değildir. Bu bölümde Şekil 3.34' te küme sayılarını optimize etmek için melez algoritma bölüm doğrulama algoritması ile tümleşik bir yapıya dönüştürülmüştür.

Şekil 3.35’ de görülen yapay veri setinde; önce Kohonen ağı farklı yarıçap değerleri ile BCO algoritması için gerekli merkez sayılarını başlangıç değer olarak elde etmiştir. Sonrasında Bulanık C-Ortalamlar algoritması ile veriler kümelendirilmiştir. Sonuçlara baktığımızda Şekil 3.35-c’ de girilen yarıçap değeri: 0.3 olması durumunda optimal küme sayısı 5 elde edilmiştir. Şekil 3.36’ de ise beş kümeden oluşan yapay veri seti melez algoritma ile kümelendirilmiştir. İlk aşamada yarıçap 0.15 için Kohonen Ağı+BCO algoritması ile küme sayısı 18 olarak bulunmuştur; sonrasında bu değer bölüm doğrulama algoritması ile optimal küme sayısına düşürülmüştür.


Sonuç olarak yarıçap değeri BCO algoritmasının doğruluğunu etkilemektedir ve BCO algoritması ancak bölüm doğrulama algoritması ile denetlenerek en iyi küme sayısı elde edilebilir.



Şekil 3.34. Melez Algoritmanın Akış Şeması




Şekil 3.35. Kohonen Ağı ve BCO Algoritması ile Kümeleme




Şekil 3.36. Melez Algoritma ile Kümeleme

3.3.5 EMG verisinin melez algoritma ile kümelendirilmesi


Şekil 3.37’ de bir ALS hastasına ait EMG verisi melez algoritma ile kümelendirilmiştir. Kohonen ağı+BCO algoritması ile bulunan 7 adet küme sayısı; bölüm doğrulama algoritması ile 4’ e düşmüştür. Şekil 3.38’ deki kümelendirmede Kohonen ağı+BCO algoritmasının bulduğu 6 adet küme sayısı bölüm doğrulama algoritması ile 3’ e düşmüştür Ancak Şekil 3.38 (c)’ de kümelendirilmiş MUAP içinde kesikli çizgi ile belirtilmiş farklı bir kümenin olduğu görülmektedir. Ayrıca her bir kümeyi temsil edecek MUAP; o kümenin ortalaması alınarak bulunur. Şekil 3.38 (c)’ de içinde kesikli çizgi ile belirtilmiş farklı MUAP’ ların adet olarak az olması ortalama alındığında o kümeyi temsil eden ortalama MUAP’ a yansımamasına neden olmuştur. Bunun sonucunda veriyi temsil eden farklı tip MUAP’ ların aynı kümeye dahil edilmesi; o veriye ait bilginin saklanmasına sebep olmuştur. Bu durum sınıflandırma için önem arz eden belirleyici özelliklerin yok olması anlamına gelir. Şekil 3.39’ da ise d, e ve f’ deki aynı küme içinde olması gereken MUAP’ ların melez algoritma ile ayrı ayrı kümelendirilmiş olduğu görülmektedir. Burada ise sınıflandırma sonucunu etkileyebilecek bir durum söz konusu değildir. Sadece işlem süresini uzatır. EK C’ de MUAP’ ların melez algoritma ile kümelendirilmesi ile ilgili örnekler yer almaktadır.



Şekil 3.37. ALS Hastasına Ait MUAP' ların Melez Algoritma ile Kümelenilmesi



Şekil 3.38. ALS Hastasına Ait MUAP' ların Melez Algoritma ile Kümelenirilmesi



Şekil 3.39. ALS Hastasına Ait MUAP' ların Melez Algoritma ile Kümelenilmesi

3.4 EMG Verisinde Öznitelik Çıkarma

EMG verisinden gizlenmiş faydalı bilgileri çıkarmak ve verinin içinden istenmeyen bölümleri, girişimleri kaldırmak adına EMG verilerinde özellik çıkarımı önemli bir aşamadır (Boostani ve Moradi, 2003), (Zardoshti, ve diğ., 1995). EMG verisinin sınıflandırılmasıyla ilgili birçok çalışmaya bakıldığında gereksiz özellik vektörlerinin kullanıldığı görülmektedir. EMG verilerinin başarılı sınıflandırması, özellik vektörünün doğru seçilmesine bağlıdır (Phinyomark ve diğ., 2012). Veriye uygun özellik seçimi sınıflandırıcının yüksek doğruluğa yaklaşması açısından doğrudan ilgilidir (Oskoei ve Hu, 2006).

Zecca, ve diğ.' lerine (2002) göre EMG verilerinde öznitelik çıkarımı üç farklı uzayda gerçekleştirilir: i) zaman uzayı, ii) frekans uzayı, iii) zaman –frekans uzayı.

3.4.1 Zaman uzayında kullanılan öznitelik vektörleri

Herhangi bir dönüşüm gerektirmeyen zaman bölgesinde özellik çıkarma hızlı ve kolay hesaplanır, bu nedenle yaygın kullanım alanına sahiptir. Zaman uzayındaki özellikler medikal ve mühendislik alanındaki çalışmalarda geniş bir kullanım alanına sahiptir (Phinyomark, ve diğ., 2012). Zaman düzleminde özellik çıkarma; işaretin genliğine, dalga biçiminin süresi ve frekansına dayanarak hesaplanır. Zaman uzayındaki özelliklerin en büyük sakıncası durağan olmayan EMG işaretinin zaman içinde istatistiksel özelliklerinin değişmesi ancak zamansal özelliklerin verileri durağan saymasıdır (Li ve diğ., 2011).

3.4.1.1 Tümüleşik EMG (IEMG)

İşaretlerin sınıflandırılması için gerekli olan öznitelik vektörlerinin elde edilmesinde en çok kullanılan yöntemlerden biri tümleştirmedir (Arslan, 2005). Bir işaretin tümleştirilmesi, işaretin altında kalan alanın hesaplanması şeklindedir. Bir EMG işaretinin ortalaması sıfırsa tümleşik değeri sıfır olacaktır. Bu nedenle tümleştirme EMG işaretinin denklem (3.29)' daki gibi mutlak değerinin toplanmasıyla elde edilir.

$$IEMG = \sum_{i=1}^N |x_i| \quad (3.29)$$

3.4.1.2 Ortalama mutlak değer (MAV)

Ortalama mutlak değer EMG işaret işlemede en çok kullanılan özneliklerden biridir (Hudgins, ve diğ., 1993; Zardoshti, ve diğ., 1995). Ortalama mutlak değer, literatürde, doğrultulmuş ortalama, mutlak değerlerin ortalaması, mutlak değerinin tümlevi (integrali) gibi değişik şekilde tanımlanmaktadır (Phinyomark, ve diğ., 2012) Ortalama mutlak değer denklem (3.30)' da verildiği gibidir.

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (3.30)$$

3.4.1.3 EMG varyans (VAR)

Varyans verilerin aritmetik ortalamadan sapmalarının karelerinin aritmetik ortalamasıdır (Denklem (3.31)). Bu özellik EMG işaretinin gücünü temsil eder (Tenore, ve diğ., 2009).

$$VAR = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (3.31)$$

3.4.1.4 Etkin değer (RMS)

EMG işareti analizinde etkin değer yaygın kullanılan özelliklerden biridir (Boostani, ve diğ., 2003). Etkin değer, değerlerin kareleri toplamının, değer sayısına bölümünün karekökünün alınması ile elde edilir (Denklem (3.32)). Sıfır eksenine göre simetrik giden işaretlerin aritmetik ortalaması, değerlerin işareti sebebiyle sıfıra yakın bir değer alır. Ayrıca genlik sıfır ekseninin iki tarafında birden büyük tepeler yapsa da, bunu ortalama değerden anlayabilmek mümkün değildir. Karesel ortalama ise veriyi oluşturan değerlerin kareleri alındığından, bir nevi tüm işaret pozitif alternansa taşınmış olur. Etkin değer bize veriyi oluşturan değerlerin hangi seviyede seyrettiğini vermesi açısından önemlidir (Bozkurt, 2007).

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3.32)$$

3.4.1.5 Standart sapma (STD)

Standart sapma, veriyi oluşturan değerler dizisindeki değerlerin, o diziye ait ortalama yoğunluklarını gösterir. Her değer ayrı ayrı aritmetik ortalama ile farkları alınır. Bu farkların kareleri alınarak toplanır ve dizideki eleman sayısına bölünür. Çıkan bu değer varyanstır. Bu değerın karekökü ise standart sapmayı verir (Denklem (3.33)).

$$SD = \sqrt{VAR} \quad (3.33)$$

3.4.1.6 Sıfır geçiş sayısı (SGS)

Sıfır geçiş sayısı, işaretin sıfır ekseninden geçişlerinin sayılması ile elde edilir. Sıfır geçiş sayısı EMG işaretinin zaman düzleminde frekans bilgisini ölçer (Hudgins, ve diğ., 1993), (Philipson, 1987). Bu öznelik daha büyük olan işaret artı – eksi yönde daha fazla değişim göstermiş demektir. Sıfır geçişleri sayılırken teorik olarak veriyi oluşturan değer dizisinde değerlerin her polarite değiştirmesi +1 sayılarak sıfır geçiş sayısı bulunur. Ancak bu şekilde yapılan bir hesapta, sıfır noktası civarında oluşan bir parazit sıfır geçiş sayısını anormal büyüttüğünden bir hassasiyet ayarı yapmak gerekmektedir. Bu ayar, işaretin değiştiği noktada, iki değer arasındaki fark belli bir büyüklüğe ulaşmadan tekrar işaret değişiyorsa, bu değişimi saymamak şeklinde özetlenebilir (Bozkurt, 2007).

3.4.1.7 Willison genliği (WAMP)

Bu özellik işaretin frekans bilgisini ölçmesi yönünden sıfır geçiş sayısı özelliğine benzemektedir (Philipson, 1987), (Zardoshti, ve diğ., 1995). EMG işaretindeki değişim önceden belirlenmiş eşik değeri olarak bulunur (denklem (3.34)).

$$WAMP = \sum_{i=1}^{N-1} [f(|x_n - x_{n+1}|)] \quad (3.34)$$
$$f(x) = \begin{cases} 1, & x \geq \text{esik} \\ 0, & \text{aksi takdirde} \end{cases}$$

3.4.2 Frekans uzayında kullanılan öznelik vektörleri

EMG işaretlerinin frekans uzayındaki analizi işaretin güç spektrum yoğunluğu tahminine dayanmaktadır ve zamansal özelliklerle karşılaştırıldığında zaman ve hesapsal yükü fazladır (Oskoei ve Hu, 2006). Frekans bölgesinde güç spektral

yoğunluğunun parametreleri; ortalama frekans, ortanca frekans, tepe frekans, ortalama güç ve toplam güçtür.

3.4.2.1 Ortalama frekans (MF)

Ortalama frekans güç spektral yoğunluğunun ve frekansın çarpımlarının toplamı, güç spektral yoğunluğun toplamına bölünmesi ile elde edilir (Denklem (3.35)).

$$MF = \frac{\sum_{j=1}^M f_j P_j}{\sum_{j=1}^M P_j} \quad (3.35)$$

M: güç spektral yoğunluğunun uzunluğu

f_j : j. frekanstaki spektrum frekansı

P_j : j. frekanstaki EMG güç spektrum değeri

3.4.2.2 Ortanca frekans (MDF)

Ortanca frekans güç spektral yoğunluğunu iki eşit parçaya böler ve ortalama frekansa kıyasla gürültüye daha az duyarlıdır (Kilby, 2005). Ortalama ve ortanca frekans işaretin zamana karşı değişimleri ve spektrumu hakkında temel bilgiler sunar (Merletti ve Parker, 2004).

$$\sum_{j=1}^{MDF} P_j = \sum_{j=MDF}^M P_j = \frac{1}{2} \sum_{j=1}^M P_j \quad (3.36)$$

3.4.2.3 Tepe frekans (PKF)

Maksimum gücün olduğu andaki frekans değeridir (Phinyomark, ve diğ., 2012).

$$PKF = \max(P_j), j = 1, \dots, M \quad (3.37)$$

3.4.2.4 Ortalama güç (MNP)

Güç spektral yoğunluğunun ortalama güç değeridir.

$$MNP = \sum_{j=1}^{MDF} P_j / M \quad (3.38)$$

3.4.2.5 1.,2. ve 3. dereceden spektral hareket

Spektral hareket EMG işaretinin güç spektral yoğunluğundan özellik çıkarmada alternatif istatistiksel bir analizdir.


$$\begin{aligned} SM1 &= \sum_{j=1}^M P_j f_j \\ SM2 &= \sum_{j=1}^M P_j f_j^2 \\ SM3 &= \sum_{j=1}^M P_j f_j^3 \end{aligned} \tag{3.39}$$

3.4.3 Morfolojik (Şekilsel) öznitelik vektörleri


Morfolojik öznitelik vektörü olarak klinik koşullarda uzmanların dikkate aldığı MUAP'ın süre, genlik ve faz sayısı bu tez çalışmasında öznitelik vektörü olarak hesaplanmıştır.

Şekil 3.40' da kas liflerinin şematik gösteriminde siyah çubuklar aktif motor birim kas liflerini, koyu gri çubuklar aktif olmayan motor birimi temsil ederken; açık gri barlar ise etkin ancak sağlam olmayan kas liflerini göstermektedir. Sonuçlara baktığımızda nöropati hasta için normal değerlere göre ortalama süre, genlik ve faz değerlerinde artış görülmektedir. Miyopati hastası için ise ortalama süre ve genlikte azalma görülürken, polifazik sayıda artış olmuştur.


Şekil 3.41' de MUAP'ın süresi, izoelektrik çizgiden ilk sapma başlangıcı ile son sapmanın arasında kalan mesafe olarak ölçülürken; genlik; tepeden tepeye iki nokta arasındaki en yüksek potansiyel fark alınarak hesaplanmıştır. Faz sayısı ise izoelektrik çizginin üstü veya altında kalan aksiyon potansiyellerinden $\pm 25\mu V$ aşan potansiyeller belirlenerek elde edilmiştir (Xie ve diğ., 2003), (Pattichis ve diğ.,1995). Bu tanımlar doğrultusunda, Şekil 3.41' de sağlıklı kişiye ait MUAP' da süre: 11.96 ms, genlik: 446 μV ve faz sayısı: 3 olarak hesaplanırken; Şekil 3.42 ALS hastasına ait MUAP' da süre: 36.22 ms, genlik: 2806 μV , faz sayısı: 6; Şekil 3.43' de miyopati hastasına ait MUAP' da; süre: 6.15 ms, genlik: 173.5 μV ve faz sayısı: 4 olarak hesaplanmıştır.



Şekil 3.40. Normal, Nöropati Ve Miyopati Hastası Kişilere Ait Olan MUAP' lar (Nikolic, 2001)




-a-




-b-

Şekil 3.41. Sağlıklı Kişiye Ait MUAP




-a-




-b-

Şekil 3.42. ALS Hastasına Ait MUAP



-a-



-b-

Şekil 3.43. Miyopati Hastasına Ait MUAP

3.5 Sınıflandırma


3.5.1 Destek vektör makinesi ile sınıflandırma

Destek vektör makineleri (DVM), Vladimir N. Vapnik tarafından ortaya konulan istatistiksel öğrenme teorisine dayalı öğrenme algoritmasıdır. El yazısı tanıma, ses tanıma, kanser doku tanısı, uzaktan algılanmış görüntülerin sınıflandırılması gibi alanlarda sıkça kullanılmaktadır (Burges, 1998).

DVM'lerin genelleme hataları problemin girdi boyutsallığıyla değil, verileri ayırdığı sınır genişliği ile ilişkilidir. DVM'ler istatistiksel kriter yerine sınır (marj) tabanlı kriter kullanır (Tan ve Wang, 2004). İki sınıflı bir sınıflandırma yöntemi olan DVM doğrusal ayırım fonksiyonuna dayanmaktadır.


Doğrusal Ayırım Fonksiyonu Şekil 3.44' de gösterildiği gibi giriş ve çıkış biriminden oluşmaktadır. Denklem (3.40)' de verilen doğrusal ayırım fonksiyonunda; $w=[w_1, w_2, w_3, \dots, w_n]$; ağırlık vektörü, w_0 ; sapma / eşik vektörüdür.

$$g(x) = w^T x + w_0 \quad (3.40)$$



Şekil 3.44. Doğrusal Ayırım Fonksiyonu

Şekil 3.45' deki veriler doğrusal ayırım fonksiyonu ile sınıflandırılmıştır. Her bir verinin fonksiyonda aldığı değer sıfırdan büyükse; veri sınıf 2 ye, değilse sınıf 1 ait olacak şekilde etiketlenmiştir.




Şekil 3.45. Doğrusal Sınıflandırma

3.5.1.1 Doğrusal ayrılabilirlik durumu


Destek vektör makineleri temelde doğrusal olarak ayırt edilebilen iki sınıf problemlerin çözümünden yola çıkarak doğrusal olarak ayırt edilemeyen veya çoklu sınıf problemlerin çözümü için genelleştirilebilir.

İkili sınıflandırma probleminde doğrusal olarak ayrılabilen bir veri setinin olduğu düşünülürse, bu veri setini ayırabilen sonsuz sayıda hiper-düzlem vardır (Şekil 3.46). Eğitim hatasını (Empirical Risk) minimize eden, bir başka ifadeyle verileri hatasız ayıran hiper düzlemler arasından en geniş sınıra (marj) sahip olan bulunmaya çalışılır.



Şekil 3.46. Birden Fazla Hiper-düzlem

Bu düzlemler arasında maksimum sınıra sahip sadece bir hiper-düzlem bulunmaktadır (Şekil 3.46). DVM karar yüzeyini oluştururken iki sınıfa olan uzaklığı maksimum yapmaya çalışır. Sınır genişliğini sınırlandıran noktalara ise destek vektörleri adı verilir.



Şekil 3.47. En İyi Hiper-düzlem

Hiper-düzlem üzerindeki noktalar $w \cdot x + b = 0$ eşitliğini sağlayacaktır. x noktasının $w^T x + b = 0$ bir düzlemine dik uzaklığı denklem (3.41)' de verilmiştir.

$$\frac{|w^T x + b|}{\|w\|} \quad (3.41)$$

$$\vec{w} \text{ vektörünün normu: } \|w\| = \sqrt{\langle w, w \rangle} = \sqrt{w^T w}$$

$|b|/\|w\|$: aşırı düzlemin orijine olan dik uzaklıktır. b : sapma (offset) değeri olarak tanımlanır.

Sınıf 1'e ait destek vektörünü oluşturan noktanın ayırım fonksiyonunda aldığı değer -1; Sınıf 2'ye ait destek vektörünü oluşturan noktanın ayırım fonksiyonunda aldığı değer +1 eşittir. Bu durumda aşırı düzlemin iki tarafındaki en yakın örneklerle olan dik uzaklığı denklem (3.42)'deki gibi hesaplanır.

$$\frac{|w^T x + b|}{\|w\|} = \frac{1}{\|w\|} \quad (3.42)$$

Bu iki dik uzaklıkların toplamı sınır (margin) olarak adlandırılır (Denklem (3.43)).

$$m = \frac{2}{\|w\|} \quad (3.43)$$


Destek vektör algoritması en büyük sınır genişliğine sahip ayırıcı hiper düzlem ile sınıflandırma yaparak öğrenme hatasını en aza indirmeye çalışır. Ağırlıklar vektörü normu; $\|w\|$ ile marj arasındaki ilişkiyi göstermek için geometrik ve grafiksel yaklaşım kullanılabilir; Şekil 3.48' de marjı (sınır) sınırlandıran noktalar x_1 ve x_2

noktalarıdır. Bu iki noktanın orjin ile oluşturdukları yönlü vektörler destek vektörleri olarak adlandırılır. M mesafesi D_1 ile D_2 dik uzaklıkları arasındaki farktır. D_1 ve D_2 ve M mesafesi denklem (3.44)' de verilmiştir. Denklem (3.45)' de $\cos(\alpha)$ ve $\cos(\beta)$ ' nin matematiksel karşılıkları verilmiştir. Denklem (3.45) ifadesi denklem (3.44)' de yerine konursa denklem (3.46) eşitliği elde edilir. x_1 ve x_2 destek vektörleri için; $y_j |w^T x_j + b| = 1, j=1,2$ yani $w^T x_1 + b = 1$ ve $w^T x_2 + b = -1$ kullanıldığında denklem (3.46) eşitliği, denklem (3.43) eşitliğine dönüşür.

$$D_1 = \|x_1\| \cos(\alpha), \quad D_2 = \|x_2\| \cos(\beta), \quad M = D_1 - D_2 \quad (3.44)$$

$$\cos(\alpha) = \frac{x_1^T w}{\|x_1\| \|w\|} \quad \text{ve} \quad \cos(\beta) = \frac{x_2^T w}{\|x_2\| \|w\|} \quad (3.45)$$

$$M = \frac{x_1^T w - x_2^T w}{\|w\|} \quad (3.46)$$



Şekil 3.48. En Geniş Sınıra Sahip Ayırıcı Hiper-Düzlem

Sınırı maksimum etmek denklem (3.47)' deki amaç fonksiyonunu denklem (3.48)' deki kısıtlar altında minimize etmeye eşittir.

$$J(w) = \frac{1}{2} \|w\|^2 \quad (3.47)$$

$$y_i (w^T x_i + b) \geq 1 \quad (3.48)$$

$J(w)$ ifadesini minimize etmek için; Lagrange çarpanları yöntemi kullanılmaktadır. Lagrange oluşturmak için, kısıt denklemleri pozitif lagrange çarpanlarıyla çarpılır ve amaç fonksiyonundan çıkarılarak denklem (3.49) elde edilir. (3.49) ifadesini çözmek için Lagrange Çarpanları yöntemi kullanılır.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i [y_i (w^T x_i + b) - 1] \quad (3.49)$$

Lagrange Çarpanları yöntemi (Lagrange's Multipliers); denklem (3.50)' deki amaç fonksiyonunu; denklem (3.51)' eşitliğindeki kısıta bağlı olarak minimize veya maksimize etmek için $H(x, y, z, t) = f(x, y, z) \pm t g(x, y, z)$ yardımcı fonksiyonunu kurarak H' nin x, y, z ve t 'ye göre kısmi türevlerinin sıfır olmasını sağlayan x, y, z, t değerlerini bulunur. (Maksimum için +, minimum için - işareti alınır)

w, b parametrelerini elimine etmek için denklem (3.49)' deki $L(w, b, \alpha)$ ifadesinin w ve b ' ye göre türevi alınıp sıfıra eşitlenir.

$$\min / \max f(x, y, z) \quad (3.50)$$

$$g(x, y, z) \quad (3.51)$$

$$\frac{\partial L(w, b, \alpha)}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^N \alpha_i y_i x_i \quad (3.52)$$

$$\frac{\partial L(w, b, \alpha)}{\partial b} = 0 \Rightarrow \sum_{i=1}^N \alpha_i y_i = 0 \quad (3.53)$$

Bunları birleştirirsek;

$$L(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (3.54)$$

Karush-Kuhn-Tucker (KKT) şartına göre (Abe, 2005);

$$\begin{aligned} \alpha_i &\geq 0 \\ y_i (w^T x_i + b) - 1 &\geq 0 \\ \alpha_i [y_i (w^T x_i + b) - 1] &= 0 \end{aligned} \quad (3.55)$$

Her örnek (3.55) denklemini sağlamalıdır. Yani $\alpha_i=0$ veya $y_i(w^T x_i + b) - 1 = 0$ olmalıdır. Eğer $\alpha_i=0$ ise; i . veri destek vektörü değildir ve yeni verilerin sınıflandırılmasında hiçbir rol oynamamaktadır. Eğer α_i sıfırdan farklı ise i . veri destek vektörü olarak adlandırılır.


3.5.1.2 Doğrusal ayrılamayan durum

Eğer veriler oluşturulan sınırın içerisinde veya hatalı tarafında ise bu veri noktaları için genelleme yapılırsa; kısıtları gevşetmek için denklem (3.57)' da yapay/aylak değişkenler tanımlanır (Tan ve Wang, April 2004):

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \zeta_i \quad (3.56)$$

$$\begin{aligned} y_i = +1 \text{ için, } w^T x_i + b &\geq +1 - \zeta_i \\ y_i = -1 \text{ için, } w^T x_i + b &\leq -1 + \zeta_i \\ \zeta_i &\geq 0 \end{aligned} \quad (3.57)$$

Denklem (3.56)' daki ilk terim doğrusal ayrılabilir durumdaki ile aynı ifadedir. İkinci terim ise yanlış sınıflandırma noktasını kontrol etmektedir. C parametresi kullanıcı girişlidir.



Şekil 3.49. Doğrusal Ayrılamayan Durum

Şekil 3.49' da görüldüğü gibi; $\zeta_i=0$ ise x_i örneği doğru sınıflandırılmıştır, $0 \leq \zeta_i \leq 1$ ise x_i örneği doğru sınıflandırılmıştır ancak aşırı düzlemler arasında yer almaktadır, $\zeta > 1$ için x_i örneği yanlış sınıflandırılmıştır. Denklem (3.56) ifadesini minimize etmek için; Lagrange çarpanları yöntemi kullanılmaktadır. Denklem (3.58)' da μ_i ; ζ_i değerlerinin pozitif olmasını sağlamak için eklenmiştir. Denklem (3.58) ifadesinin w , b ve ζ ' ye göre türevi alınır.

$$L_p = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \zeta_i - \sum_{i=1}^N \alpha_i \{y_i (w^T x_i + b) - 1 + \zeta_i\} - \sum_{i=1}^N \mu_i \zeta_i \quad (3.58)$$

$$\frac{\partial L_p}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i \quad (3.59)$$

$$\frac{\partial L_p}{\partial \mathbf{b}} = 0 \Rightarrow \sum_{i=1}^N \alpha_i y_i = 0 \quad (3.60)$$

$$\frac{\partial L_p}{\partial \xi_i} = 0 \Rightarrow C = \alpha_i + \mu_i \quad (3.61)$$

$$\begin{aligned} \mathbf{w}^T \cdot \mathbf{w} &= \mathbf{w}^T \cdot \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i = \sum_{i=1}^N \alpha_i y_i \mathbf{w}^T \mathbf{x}_i = \sum_{i=1}^N \alpha_i y_i \left[\sum_{j=1}^N \alpha_j y_j \mathbf{x}_j \right]^T \mathbf{x}_i \\ &= \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \end{aligned} \quad (3.62)$$

(3.58) ifadesini, L_p 'yi açarsak:

$$L_p = \frac{1}{2} \mathbf{w}^T \cdot \mathbf{w} + C \sum_i \zeta_i - \sum_i \alpha_i y_i \mathbf{w}^T \mathbf{x}_i - \mathbf{b} \sum_i \alpha_i y_i + \sum_i \alpha_i - \sum_i \alpha_i \zeta_i - \sum_i \mu_i \zeta_i \quad (3.63)$$

(3.59), (3.60), (3.61) ifadelerini, (3.63) ifadesinde yerine yazdığımızda;

$$\begin{aligned} L_p &= \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j + \\ &\quad C \sum_{i=1}^N \zeta_i + \sum_{i=1}^N \alpha_i - C \sum_{i=1}^N \zeta_i \end{aligned} \quad (3.64)$$

(3.64) ifadesinin sadeleşmiş hali (3.65) eşitliğinde verilmiştir.

$$L(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \quad (3.65)$$

C parametresi $0 \leq \alpha_i \leq C$: Lagrange çarpanlarının maksimum değerini göstermektedir.


3.5.1.3 Doğrusal olmayan destek vektör makineleri

Çoğu gerçek problemlerde verilerin doğrusal bir ayırım fonksiyonu ile hatasız ayrılabilmesi mümkün değildir. Giriş uzayında doğrusal olarak ayrılamayan durum için bir diğer çözüm yolu doğrusal olmayan haritalamadır. Şekil 3.50' de gösterildiği gibi doğrusal olarak ayrılamayan her bir giriş vektörü Φ : dönüşüm fonksiyonu yada koordinat dönüşüm fonksiyonu ile yüksek boyutlu bir uzaya haritalanarak doğrusal ayrılabilir duruma gelmektedir.




Şekil 3.50. Doğrusal Olmayan Haritalama

Şekil 3.51’ de giriş uzayında doğrusal olarak ayrılamayan veri, Φ dönüşümü kullanılarak özellik uzayında doğrusal ayrılması sağlanmıştır.



Şekil 3.51. Verilerin Giriş Uzayından Özellik Uzayına Aktarımı

DVM girdi uzayındaki verileri daha yüksek boyutlu özellik uzayına haritalamaktadır. Böylece veriler yüksek boyutlu uzayda doğrusal olarak ayrılmaktadır (Şekil 3.52).




Şekil 3.52. İki Boyutlu Giriş Uzayından Üç Boyutlu Özellik Uzayına Dönüşüm

Genellikle Φ : dönüşüm fonksiyonu elde edilebilir değildir, hesaplanamaz ya da mevcut değildir. Şekil 3.53’ de gösterildiği gibi giriş uzayında doğrusal olarak

ayrılmaz veriler özellik uzayına taşınır. Verilerin aktarıldığı özellik uzayı iç çarpımın tanımlı olduğu Hilbert uzayı olmalıdır. Özellik uzayına aktarılan verilere karşılık gelen vektörler $\phi^T(x_i), \phi(x_j)$ skalar çarpılır. Bu çarpıma kernel fonksiyonu denir. Kernel fonksiyonu özellik uzayında iç çarpımı gerçekleştirdiğinde Φ : dönüşüm fonksiyonunun analitik olarak bilinmesine gerek yoktur, kernel fonksiyonunu belirlenmesi yeterlidir. Böylece eşitlik (3.65)' daki ikili problem, denklem (3.66)' ya dönüşür.

$$L(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \phi(x_i)^T \phi(x_j) \quad (3.66)$$



Şekil 3.53. Özellik Uzayında Vektörel İç Çarpım


Doğrusal olarak ayırt edilemeyen sınıflarda ise doğru kernel fonksiyonun seçimi sınıflandırma işleminin başarısında oldukça etkilidir. Destek vektör makinesi Mercer koşullarını sağlayan kernel fonksiyonlarını kullanır (Vapnik, 1999). Yaygın olarak kullanılan kernel fonksiyonları Çizelge 3.11'de verilmiştir.

Çizelge 3.11. Kernel Fonksiyonları

Kernel Fonksiyonları	$K(x_i, x_j)$
Doğrusal	$x_i^T x_j$
Polinom	$(x_i^T x_j + 1)^p$
RTF (Radyal Tabanlı Fonksiyon)	$\exp\left(-\frac{1}{2\sigma^2} \ x - y\ ^2\right)$

Yeni bir x verisinin sınıf bilgisi eşitlik (3.67)' deki karar fonksiyonu ile elde edilir. Şekil 3.54' de verildiği gibi DVM modeli sigmoid bir kernel fonksiyonu kullanan; iki katmanlı, ileri beslemeli bir sinir ağ yapısına denktir (Tan ve Wang, April 2004).

$$f(x) = \text{sign}(\sum \alpha_i y_i K(x, x_i) + b) \quad (3.67)$$



Şekil 3.54. DVM Ağ Yapısı

Örnek: XOR probleminin DVM yöntemi ile çözümü

Veri seti

Sınıf 1: $x_1=(-1,-1)$, $x_4=(1,1)$

Sınıf 2: $x_2=(-1,1)$, $x_3=(1,-1)$

Bu örnek için kernel fonksiyonu 2. dereceden polinom kernel seçilmiştir.

$$K(x, x') = (x^T x' + 1)^2$$

$$\begin{aligned} K(x_i, x_j) &= (1 + x_i^T x_j)^2 = 1 + x_{i1}^2 x_{j1}^2 + 2 x_{i1} x_{j1} x_{i2} x_{j2} + x_{i2}^2 x_{j2}^2 + 2 x_{i1} x_{j1} + 2 x_{i2} x_{j2} \\ &= [1 \ x_{i1}^2 \ \sqrt{2} x_{i1} x_{i2} \ x_{i2}^2 \ \sqrt{2} x_{i1} \ \sqrt{2} x_{i2}]^T [1 \ x_{j1}^2 \ \sqrt{2} x_{j1} x_{j2} \ x_{j2}^2 \ \sqrt{2} x_{j1} \ \sqrt{2} x_{j2}] \\ &= \varphi(x_i)^T \varphi(x_j) \end{aligned}$$

Bu fonksiyona uygun dönüşüm:

$$\varphi(X) = [1, x_1^2, \sqrt{2} x_{i1} x_{i2}, x_{i2}^2, \sqrt{2} x_{i1}, \sqrt{2} x_{i2}]^T \quad , i = 1, 2, 3, 4$$

Veri seti kernel fonksiyonunda yerine konur ve kernel matrisi elde edilir.

$$K = \begin{bmatrix} 9 & 1 & 1 & 1 \\ 1 & 9 & 1 & 1 \\ 1 & 1 & 9 & 1 \\ 1 & 1 & 1 & 9 \end{bmatrix}$$

K matrisi ve verilere ait etiketler denklem (3.66)' da yerine yazılırsa:

$$L(\alpha) = \alpha_1 + \alpha_2 + \alpha_3 + \alpha_4 - \frac{1}{2}(9\alpha_1^2 - 2\alpha_1\alpha_2 - 2\alpha_1\alpha_3 + 2\alpha_1\alpha_4 + 9\alpha_2^2 + 2\alpha_2\alpha_3 - 2\alpha_2\alpha_4 + 9\alpha_3^2 - 2\alpha_3\alpha_4 + 9\alpha_4^2)$$

α_i ' lere göre türev alınır:

$$\begin{aligned} 9\alpha_1 - \alpha_2 - \alpha_3 + \alpha_4 &= 1 \\ -\alpha_1 + 9\alpha_2 + \alpha_3 - \alpha_4 &= 1 \\ -\alpha_1 + \alpha_2 + 9\alpha_3 - \alpha_4 &= 1 \\ \alpha_1 - \alpha_2 - \alpha_3 + 9\alpha_4 &= 1 \end{aligned}$$

Buradan Lagrange çarpanları: $\alpha_{0,1} = \alpha_{0,2} = \alpha_{0,3} = \alpha_{0,4} = \frac{1}{8}$ bulunur. Elde edilen α_i ' ler sıfırdan büyük olduğu için bütün noktalar destek vektörü olarak alınır. Denklem (3.58)' deki Φ dönüşüm kullanıldığında $W_0 = \sum_{i=1}^N \alpha_i y_i \phi(x_i)$ dönüşür.

Buradan w_0 vektörü elde edilir:


$$\begin{aligned} W_0 &= \frac{1}{8}[-\phi(X_1) + \phi(X_2) + \phi(X_3) + \phi(X_4)] \\ &= \frac{1}{8} \left[- \begin{bmatrix} 1 \\ 1 \\ 1 \\ -\sqrt{2} \\ -\sqrt{2} \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \\ 1 \\ -\sqrt{2} \\ \sqrt{2} \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \\ 1 \\ \sqrt{2} \\ -\sqrt{2} \end{bmatrix} - \begin{bmatrix} 1 \\ 1 \\ 1 \\ \sqrt{2} \\ \sqrt{2} \end{bmatrix} \right] = \begin{bmatrix} 0 \\ 0 \\ -1 \\ \frac{1}{\sqrt{2}} \\ 0 \end{bmatrix} \end{aligned}$$

w_0 ' ın ilk elemanı b yi verir. (b=0)

Optimal hiperdüzlem; $w^T \phi(x) + b = 0 \Rightarrow w^T \phi(x) = 0$

$$\text{Buradan; } [0, 0, \frac{-1}{\sqrt{2}}, 0, 0, 0] \begin{bmatrix} 1 \\ x_1^2 \\ \sqrt{2}x_1x_2 \\ x_2^2 \\ \sqrt{2}x_1 \\ \sqrt{2}x_2 \end{bmatrix} = 0$$

Bu problem için optimal ayırıcı hiper-düzlem: $-x_1x_2=0$ olarak bulunur. Şekil 3.55' de iki boyutlu uzaydaki veri seti doğrusal ayrılamazken uygun bir dönüşüm yapılarak üç boyutlu uzayda doğrusal ayrılabilmesi sağlanmıştır.



Şekil 3.55. XOR Örneği

3.5.2 K-En yakın komşu algoritması

K-En Yakın Komşu (K-EYK) algoritması öznitelik uzayındaki en yakın eğitim örneklerine dayanarak nesneleri sınıflandıran, en basit örüntü tanıma yöntemlerinden birisidir (Alpaydın, 2004). Bu algoritma verilen K değeri kadar en yakın komşunun sınıfına göre sınıflandırma işlemi yapmaktadır. K-En Yakın Komşu algoritmasında bir vektörün sınıflandırılması, sınıfı bilinen vektörler kullanılarak yapılmaktadır.


Test edilecek örnek, eğitim kümesindeki her bir örnek ile tek tek işleme alınır. Test edilecek örneğin sınıfını belirlemek için eğitim kümesindeki o örneğe en yakın k adet örnek seçilir. Seçilen örneklerden oluşan küme içerisinde hangi sınıfa ait en çok örnek varsa test edilecek olan örnek bu sınıfa aittir denilir. Örnekler arası uzaklıklar Öklid uzaklığı ile bulunur (denklem (3.68)).

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n \text{dizi}_r(x_i) - \text{dizi}_r(x_j))^2} \quad (3.68)$$

K-en yakın komşu algoritması eğitici ve örnek tabanlı bir sınıflandırma algoritmasıdır. Uygulanabilirliği diğer yöntemlere göre daha kolaydır. Bu tip algoritmalarda eğitime ihtiyaç yoktur. İşleyişi, ‘birbirine yakın olan nesneler muhtemelen aynı kategoriye aittir’ diyen sezgisel fikir üzerine kuruludur. K-en yakın komşu algoritması, veri madenciliği, bilgi güvenliğinin sağlanmasında saldırı tespit sistemlerinde, genetik ve biyo enformatiğin birçok alanında, örüntü tanıma sistemleri gibi birçok benzeri sistemde kullanılmaktadır.

Bu algoritma için sınıf sayısında bir kısıtlama yoktur. İstenilen sayıda sınıf belirlenerek (en az bir sınıf olacak şekilde) sınıflandırma işlemi yapılabilir.

K-en yakın komşu algoritması herkes tarafından bilinen “bana arkadaşını söyle sana kim olduğunu söyleyeyim” sözü ile örneklenebilir. Şekil 3.56’ da yeşil çöp adamın test edilecek örnek olduğu varsayılmıştır ve k değeri 5 olarak seçilmiştir. Yeşil adama en yakın 5 arkadaşı Yeşil adamın, mavi sınıfa ya da sarı sınıfa ait olduğunu belirleyecektir. Yeşil adamın en yakın beş arkadaşı işaretlenen daire ile belirlenmiştir. Bu dairenin içerisinde kalan beş arkadaşının üç tanesi mavi sınıftan iki tanesi ise sarı sınıftandır. Bu sonuçlara göre Yeşil adam mavi sınıftandır sınıflandırılması yapılır.



Şekil 3.56. K-En Yakın Komşu Algoritması ile Sınıflandırma

Yukarıdaki bilgiler doğrultusunda örnek bir uygulama: Çizelge 3.12’ de verilen verilere göre (8,4) değerinin hangi sınıfa ait olduğunu K-En yakın komşu algoritması ile bulalım.

Çizelge 3.12. İki Boyutlu Veri

x_1	2	3	3	4	5	6	7	9	11	10
x_2	4	6	4	10	8	3	9	7	7	2
y	kötü	iyi	iyi	kötü	kötü	iyi	iyi	kötü	kötü	kötü

Adım 1: K’ nın belirlenmesi: K=4 kabul edilmiştir.

Adım 2: Uzaklıkların hesaplanması: (8,4) noktası ile Çizelge 3.12’ deki verilerin her biri arasındaki Öklid uzaklıkları hesaplanır (Denklem (3.69)).


$$\begin{aligned}
d(i, j) &= \sqrt{(2-8)^2 + (4-4)^2} = 6.00 \\
d(i, j) &= \sqrt{(3-8)^2 + (6-4)^2} = 5.39 \\
d(i, j) &= \sqrt{(3-8)^2 + (4-4)^2} = 5.00 \\
d(i, j) &= \sqrt{(4-8)^2 + (10-4)^2} = 7.21 \\
d(i, j) &= \sqrt{(5-8)^2 + (8-4)^2} = 5.00 \\
d(i, j) &= \sqrt{(6-8)^2 + (3-4)^2} = 2.24 \\
d(i, j) &= \sqrt{(7-8)^2 + (9-4)^2} = 5.10 \\
d(i, j) &= \sqrt{(9-8)^2 + (7-4)^2} = 3.16 \\
d(i, j) &= \sqrt{(11-8)^2 + (7-4)^2} = 4.24 \\
d(i, j) &= \sqrt{(10-8)^2 + (2-4)^2} = 2.83
\end{aligned} \tag{3.69}$$

Adım 3: En yakın 4 komşunun belirlenmesi: Çizelge 3.13'te veriler uzaklık değerlerine göre sıralanmıştır.

Çizelge 3.13. İki Boyutlu Verileri Uzaklık Değerlerine Göre Sıralama

x ₁	2	3	3	4	5	6	7	9	11	10
x ₂	4	6	4	10	8	3	9	7	7	2
y	kötü	iyi	iyi	kötü	kötü	iyi	iyi	kötü	kötü	kötü
Uzaklık değerine göre sıralama	9	8	6	10	5	1	7	3	4	2

Adım 4: Seçilen satırlara ilişkin sınıfların belirlenmesi: (8,4) noktasına en yakın olan verilerin y sınıfları göz önüne alınır ve veriler içinde hangi değerlerin baskın olduğu araştırılır. Şekil 3.57' de çember içinde bir tane 'İYİ', üç tane 'KÖTÜ' sonuç vardır. 'KÖTÜ' değerlerin sayısı 'İYİ' değerlerin sayısından fazla olduğu için (8,4) noktasının sınıfı 'KÖTÜ' olarak belirlenir.



Şekil 3.57. (8,4) Noktasına En Yakın 4 Komşu

3.5.3 Diskriminant analiz


Bir sınıflandırma yöntemi olan diskriminant analiz (DA) farklı sınıfların farklı Gaussian dağılımına sahip oldukları ilkesine dayanmaktadır (Macit, 2014). Doğrusal Diskriminant Analiz (DDA) ve Karesel Diskriminant Analiz (KDA) olarak iki temel gruba ayrılan diskriminant analizinin, ayırma ve sınıflama şeklinde iki işlevi bulunmaktadır.

- DDA’da her sınıfın aynı kovaryans matrisine sahip olduğu kabul edilir. Ancak sadece ortalamalar farklıdır. Fisher (1936), tarafından geliştirilmiştir.
- KDA’da ise hem kovaryans matris hem de sınıf ortalamaları her sınıfta değişir.


Diskriminant analizde amaç çok değişkenli problemin tek değişkenli biçime dönüştürülmesidir. Bu durumu Şekil 3.58’ de grafiksel olarak anlatmak gerekirse; ölçülmüş x_1 ve x_2 özellikleri, iki boyutlu uzayda birer nokta olarak düşünebiliriz. Bu örnekte A sınıfına ait bölge R_1 ve B grubuna ait bölge R_2 ile ifade edilmiştir. Şekilde p tane özelliğin olması durumunda bu özelliklerin her birinin ayrı ayrı ele alınarak bireylerin sınıflara ayrılması güç ve bazen imkansızdır (Güler, 2002). Bu nedenle diskriminant analizinde uygun ağırlıklarla çarpılan değişkenler toplanıp tek bir fonksiyona dönüştürülür ve bu fonksiyona diskriminant fonksiyonu denilmektedir

(denklem (3.70)). Doğrusal ve karesel diskriminant fonksiyonları Şekil 3.59’ da verilmiştir.

$$y_i = a_1 x_{i1} + a_2 x_{i2} + \dots + a_p x_{ip} \quad (3.70)$$



Şekil 3.58. Diskriminat Analizi (Tatlídil, 1996)



Şekil 3.59. Diskriminat Fonksiyonları a)DDF b)KDF

Doğrusal diskriminant fonksiyonu denklem (3.71) de verilmiştir. Burada μ_1, μ_2 1. ve 2. grupların ortalama değeri, Σ ise ortak kovaryans matrisidir.

$$L(x) = \left\{ x' - \frac{1}{2}(\mu_1 + \mu_2)' \Sigma^{-1}(\mu_1 + \mu_2) \right\} \quad (3.71)$$

Karesel diskriminant fonksiyonu denklem (3.72)’ de verilmiştir. Burada Σ_1 ve Σ_2 1. ve 2. gruba ilişkin kovaryans matrisleridir. Eşitlik (3.72)’ de $\Sigma_1 = \Sigma_2 = \Sigma$ alınırsa karesel fonksiyon doğrusal fonksiyona dönüşür.

$$L(x) = \frac{1}{2} \log \frac{|\Sigma_2|}{|\Sigma_1|} - \frac{1}{2} (\mu_1' \Sigma_1^{-1} \mu_1 - \mu_2' \Sigma_2^{-1} \mu_2 + x' (\Sigma_1^{-1} \mu_1 - \Sigma_2^{-1} \mu_2)) - \frac{1}{2} x' (\Sigma_1^{-1} - \Sigma_2^{-1}) x \quad (3.72)$$

3.6 Yöntemlerin Geçerliğinin Değerlendirilmesi


Bu bölümde bir sınıflandırıcının doğruluğunu belirlemek için kullanılan bazı yöntemler gösterilmektedir.

3.6.1 Alıkoyma yöntemi

Belli sayıda örnek sına için ayrılır, geriye kalan örnekler öğrenme için kullanılır. Genelde veri kümesinin $2/3$ ' ü öğrenme, $1/3$ ' i sına kümesi olarak ayrılır.

Bu yöntemde, etiketlenen gerçek veri, eğitim ve test kümesi olarak iki ayrı kümeye bölünür (Şekil 3.60). Arkasından eğitim kümesinde bir sınıflandırma modeli türetilir ve başarımı test kümesinden ölçülür. Eğitim ve test amaçlı alınan verinin oranı değişmektedir. (50-50 veya $2/3$ eğitim ve $1/3$ test). Sınıflandırıcının doğruluğu, test kümesinden elde edilen modelin doğruluğundan çıkarılabilir.

Alıkoyma yönteminin, birkaç iyi bilinen sınırlaması vardır. İlki, az etiketlenen örnekler eğitim için uygundur çünkü bazı kayıtlar test için ayrılmıştır. Sonuçta, çıkarılan model, tüm etiketlenen örnekler eğitim için kullanıldığında gibi iyi olmayacaktır. İkincisi, model eğitim ve test kümelerinin birleşimine iyi derecede bağlı olabilir. Eğitim kümesi ne kadar küçük olursa, modelin değişkenliği de o kadar büyük olacaktır. Diğer yandan, eğitim kümesi çok büyük olursa, daha küçük olan test kümesinden hesaplanarak beklenen doğruluk daha az güvenilir olacaktır. Böyle bir beklentinin geniş bir güven aralığına sahip olduğu söylenebilir. Son olarak, eğitim ve test kümeleri artık birbirinden bağımsız değildir. Eğitim ve test kümeleri, gerçek verinin alt kümeleri olduğu için, bir alt kümeyi fazlasıyla kapsayan bir sınıf, diğerini az kapsayacaktır (Tosunoğlu, 2012).




Şekil 3.60. Alıkoyma Yöntemi (Gutierrez, 2010)

3.6.2 Çapraz geçerlilik

Çapraz geçerlilik yönteminde veri seti rastgele olarak “k” gruba ayrılır. Literatürde genelde “k” değerinin 10 olarak seçildiği görülmektedir. Bu gruplardan biri dışarıda

bırakılarak geriye kalan kısım ile model oluşturulur. Oluşturulan modelin sınıflama doğruluğu dışarıda bırakılan veriler üzerinde test edilir. Sırasıyla bu işlem dönüşümlü olarak diğer “k” grup için de tekrarlanır. Son olarak elde edilen “k” tane doğru sınıflama oranının ortalaması alınarak modelin genel başarımı değerlendirilir (Şekil 3.61).

Rastgele örnekleme bir alternatif yöntem çapraz doğrulamadır. Bu yaklaşımda, her kayıt eğitim için aynı sayıda kullanılır. Bu yöntemi göstermek için, veriyi 2 eşit parçaya böldüğümüzü düşünelim. İlk olarak, bir altkümeyi eğitim için diğerini test için seçeriz. Sonra altkümelerin rollerini değiştirip eğitim altkümesini test, test altkümesini eğitim yaparız. Bu yaklaşıma 2 yönlü çapraz onaylama denir. Toplam hata, her iki durumda oluşan hataların toplamıdır. Bu örnekte her kayıt bir kere eğitim ve bir kere test için kullanılır. Bölümleme sayısı (k) artırılarak onay sayısını (k kere) da arttırılabilir. Her durumda, bir bölüm test için, diğerleri eğitim için kullanılır. Her bölümün test için bir kere kullanıldığına emin olmak için bu işlem k kere tekrarlanır. Yine, toplam hata, tüm hataların (k tane hata) toplamından oluşur. (Tosunoğlu, 2012).



Şekil 3.61. Çapraz Doğrulama (Gutierrez, 2010)

3.6.3 Tekrarlı örnekleme


Şimdiye kadar gösterilen yöntemlerde eğitim ve test kümelerinde aynı kayıtlar yoktur. Tekrarlı örneklemede ise, bir örnekten tekrarlı örnekler bulunmaktadır. Eğitim kümesinde yer almayan örnekler test kümesi olarak kullanılır (Şekil 3.62).



Şekil 3.62. Tekrarlı Örnekleme (Gutierrez, 2010)

3.6.4 Basit geçerlilik

Modelin test edilmesinde kullanılan en basit yöntem basit geçerlilik yöntemidir. Bu yöntemde verilerin %5 ile %33 arasındaki kısmı test verileri olarak ayrılır. Kalan kısım üzerinde model bulmak için algoritmalar uygulanır (Şekil 3.63).



Şekil 3.63. Basit Geçerlilik (Gutierrez, 2010)

4. BULGULAR VE TARTIŞMA

Bu tez çalışmasında Şekil 3.1’ de verilen yapının her bir adımında farklı algoritmalar denenmiş ve her bir aşama için EMG işaretlerini en az hata ile sınıflandıran en iyi yöntem belirlenmiştir.

ALS ve miyopati hastalığının teşhisinde beş işlem adımından oluşan bir sınıflandırma yapısı ile veriler işlenerek sınıflandırılmıştır. İlk adımda ham veriler ön işlem aşamasından geçirilerek alçak ve yüksek frekans bileşenli gürültülerden arındırılmıştır. Bir sonraki adımda MUAP tepeleri bularak bölütleme ve MUAP’ ların başlangıç ve bitiş noktaları bulunarak bölütleme yöntemleri ile MUAP’ ların ayrıştırılması sağlanmıştır. Üçüncü adımda Hiyerarşik kümeleme ve Melez yapı gibi iki farklı kümeleme ile MUAP’ ların kümelenmesi sağlanmıştır. Dördüncü ve beşinci adımda Bölüm 3.4 verilen zaman, frekans uzayındaki öznitelikler ve morfolojik öznitelik vektörleri (Çizelge 4.2) her bir EMG verisi için hesaplanıp sırasıyla Destek Vektör Makinesi, K-En Yakın Komşu algoritması ve Diskriminant Analiz algoritmalarına giriş olarak verilerek verilerin sınıflandırılması sağlanmıştır. Sınıflandırıcının doğruluğunu belirlemek amacıyla Çapraz Geçerlilik (Cross Validation- CV) yöntemi kullanılmıştır. Sonrasında her bir aşamada kullanılan yöntemlerin başarımları sonuçları karşılaştırılmış ve aşağıda yorumlanmıştır.

Bu çalışmada kullanılan EMG işaretleri 10 normal, 7 miyopati ve 8 ALS hastası olan her bir veri grubunda 8 sn süren 230’ ar tane veri bulunmaktadır. Bu verilerin 1 sn’ lik kısmında tepe değeri 50uV aşan ortalama 36 adet MUAP yer almaktadır. Bölütleme aşamasında toplam 198600 MUAP elde edilmiştir.

Sınıflandırıcı başarımlarını belirlemek için çapraz geçerlilik yöntemi ile toplam 3x230 tane veri seti rastgele olarak “k” gruba ayrılmıştır. Bu yöntemde gruplardan biri dışarıda bırakılarak geriye kalan kısım ile ağ eğitilmiştir. Oluşturulan ağın sınıflandırma başarımları dışarıda bırakılan veriler üzerinde test edilmiştir. Sırasıyla bu işlem dönüşümlü olarak diğer “k” grup için de tekrarlanmıştır. Bu çalışmada k değeri 10 seçilmiştir.

DVM ile sınıflandırmada Matlab' ın BioinformaticsToolbox™ (MathWorks, 2007) adlı yazılımı kullanılmıştır. DVM ile yapılan sınıflandırmada kernel fonksiyonu olarak seçilen RTF' nin Gauss genişliği: $r=1.5$ ve ceza faktörü: $C=400$ seçilmiştir.

Sınıflandırma başarımının üstünlüğünün arkasında yatan ana neden öznitelik vektörlerinin sınıflar arası ayrılabilirliğinin yüksek derecede olmasıdır (Fattah ve diğ., 2012). Deneysel sonuçlar bu çalışmanın sınıflandırma yeteneğinin sadece iki sınıflı problemleri ayırabildiğini göstermiştir. Bu duruma en iyi örnek Şekil 4.1' de verilmiştir. Grafikte her üç sınıftaki 50 veriye ait MUAP' ların RMS öznitelik vektörlerinin ortalama değerleri çizdirilmiştir. Burada ALS hastalığına karşılık gelen RMS özniteliğinin ortalama değerleri diğer iki sınıfa (miyopati, sağlıklı) göre çok daha yüksek olmasına rağmen, RMS öznitelik vektörünün miyopati ile sağlıklı verileri ayırma derecesi çok tatmin edici değildir. Bu çalışmada kullanılan öznitelik vektörlerinin sadece sağlıklı veri ile ALS verilerini ya da ALS ile miyopati verileri arasında daha iyi bir sınıflandırma doğruluğunu mümkün kılmaktadır. Bu durum diğer tekli ve çoklu öznitelik vektörleri içinde geçerli olması nedeniyle sınıflandırma başarımları Çizelge 4.3' de ikili sınıflandırma olarak sunulmuştur. Sonuçlar göstermiştir ki önerilen özellikler sadece iki sınıfın (ALS-Sağlıklı ve ALS-Miyopati) yüksek derecede ayrılabilirliğini sağlamıştır.

Şekil 4.2-Şekil 4.16 aralığındaki bütün grafiklerde DVM-RTF sınıflandırma algoritması kullanılması durumunda zaman, frekans, morfolojik ve çoklu öznitelik vektörlerinin başarımlar sonuçları kutu grafiği ile verilmiştir. Her bir kutu grafiği k değeri kadar başarımlar sonucunun grafiksel bir özetini sunmaktadır.

Şekil 4.2, Şekil 4.3, Şekil 4.4 ve Şekil 4.5' de ALS ve sağlıklı veriler arasında yapılan sınıflandırma sonucunda; melez kümeleme yöntemi kullanılması durumunda; hiyerarşik kümeleme yöntemine göre (frekans öznitelik vektörlerinde; PKF, MDF, morfolojik öznitelik vektörlerinde ise; süre hariç) daha iyi sonuç vermiştir.

Şekil 4.6, Şekil 4.7, Şekil 4.8 ve Şekil 4.9' da ALS ve miyopati verileri arasında yapılan sınıflandırmada ise melez kümeleme yöntemi kullanılması durumunda; hiyerarşik kümeleme yöntemine göre (süre öznitelik vektörü hariç) daha iyi sonuç verdiği görülmüştür.

Şekil 4.10, Şekil 4.11, Şekil 4.12, Şekil 4.13' de miyopati ve sağlıklı sınıflandırma sonucunda; melez kümeleme yöntemi kullanılması durumunda; hiyerarşik kümeleme yöntemine göre (çoklu öznitelik vektörlerinde;

IEMG+WAMP+MF, IEMG+MNP+WAMP+MF, IEMG+SGS+Genlik+Faz, Sure+Genlik+Faz, frekans düzleminde; MDF dışında, morfolojik öznitelik vektörlerinde ise; faz hariç) daha iyi sonuç vermiştir.

Hiyerarşik kümeleme yöntemi ile elde edilen kümeler kullanıcı tarafından girilen eşik değerine göre değişkenlik gösterir. EMG işaretlerinin karmaşık ve zamanla değişen bir yapıya sahip olması sürekli değişen MUAP' lar için uygun bir eşik değeri bulmayı güçleştirmektedir. Melez kümeleme yönteminde ise kullanıcı sadece Kohonen ağı için gerekli tahmini bir yarıçap (d) girmektedir. Devamında ise BCO algoritmasının bulduğu küme sayısı bölüm doğrulama algoritması ile optimal olması sağlanır. Böylece melez kümelemede elde edilen küme sayısı sürekli olarak bölüm doğrulama algoritması tarafından denetlenerek MUAP' ların küme sayılarının doğrudan bir değişkene bağlı olması önlenmiş olur. Bu nedenle her üç sınıflandırmada öznitelik vektörlerinin çoğunda en iyi başarıyı melez kümeleme yöntemi sağlamıştır.

Şekil 4.14, Şekil 4.15 ve Şekil 4.16' da tanı koymada doktorların kullandığı MUAP' ın genlik, süre, faz değerleri ile yapılan sınıflandırma sonuçlarına ait kutu grafikleri ALS-Sağlıklı sınıflandırmada %74- 89; ALS-Miyopati de %76-93.5 ve Sağlıklı-Miyopatide ise %50- 69.5 aralığında değişim göstermiştir. Bu sonuçlar tanı koymada hesaplanan morfolojik öznitelik vektörlerinin yeterli olmadığını göstermiştir.

Ayrıca tanı koyarken MUAP dalgasının şeklinin bütününe bakarak karar verilir. Tanı koymada kullanılan (genlik, süre, alan) morfolojik parametreler tanı koyarken MUAP şeklini tam olarak yansıtmamaktadır (Dobrowolski, 2012).

Şekil 1.20' de aynı morfolojik parametrelere sahip 3 farklı MUAP verilmiştir. Burada sadece morfolojik parametrelere MUAP ayrımının yapılamayacağı görülmektedir. Bu nedenle bu morfolojik tanımlar hastalık ayrımı için yeterli değildir. İyi bir başarıyı elde etmek için MUAP' ları en iyi temsil edecek öznitelikler seçilmelidir.

Yüksek sınıflandırma başarıyı elde etmek için etkili öznitelik vektörü kullanmak gerekir (Windham, 1982). Bu amaç doğrultusunda bu tez çalışmasında sınıflandırma doğruluğunu arttırmak için öznitelik vektörlerinin çeşitli şekilde birleştirilmesi ile elde edilen çoklu öznitelik vektörleri kullanılmıştır. Şekil 4.14, Şekil 4.15 ve Şekil 4.16' da çoklu öznitelik vektörleri kullanılması durumunda tekli öznitelik vektörlerine göre sınıflandırma başarıyı artmıştır. Her üç sınıflandırmada

en iyi başarımı çoklu öznitelik vektörü IEMG+SGS+WAMP+MF sağlamıştır. ALS-Sağlıklı sınıflandırmada en iyi başarımların medyan değeri %98.91, ALS-Miyopati sınıflandırmada %95.65 ve Miyopati-Sağlıklı sınıflandırmada %86.95’ dir.

Bu tez çalışmasında elde edilen sınıflandırma sonuçlarını daha önce yapılan farklı tip veri setini kullanan çalışmalarla kıyaslamak yerine; ortak bir veri tabanını kullanan (Maboud ve diğ., 2015) ve (Krishna ve Thomas, 2015) çalışmaları ile karşılaştırmak daha doğru olacaktır. 2015 yılında yayınlanan bu iki çalışmada veriler (<http://www.EMGLab.net>, 2011) internet adresindeki veritabanından alınmıştır. Ancak bu iki çalışmada; bu tez çalışmasındaki veri setine göre daha az veri seti ile işlem yapılmıştır. Bu durumlar göz önünde bulundurulduğunda bu çalışmada elde edilen başarımların yüzdelere göre aynı veri setini kullanan çalışmalara göre daha iyi olduğu görülmüştür (Çizelge 4.1).

Çizelge 4.1. Aynı Veri Setini Kullanan Çalışmaların Karşılaştırılması

Çalışmalar	Kullanılan Yöntemler		Doğruluk (%)
	Öznitelik Çıkarma	Sınıflandırma	
(Krishna ve Thomas, 2015)	ADD	K-EYK	ALS-Sağlıklı ;%96.5 Miyopati-Sağlıklı; %83.5
(Maboud ve diğ., 2015)	ADD	DVM ve YSA	ALS için DVM; %98.0 Miyopati için YSA; %86.6
Yazarın önerisi	Çoklu Öznitelik Vektörü	DVM	ALS-Sağlıklı ;%97.39 Miyopati-Sağlıklı; %86.74


Bu tez çalışmasında ALS-Sağlıklı, ALS-Miyopati ve Miyopati-Sağlıklı sınıflarının başarımlarını değerlendirmek amacıyla bazı istatistiksel ölçütler Çizelge 4.3’ de hesaplanmıştır. Bu ölçütler şu şekilde tanımlanır (DP: Doğru Pozitif, DN: Doğru Negatif, YP: Yanlış Pozitif, YN: Yanlış Negatif) [31]:

- Duyarlılık, gerçekte hasta olanlar arasında testin pozitif sonuç verme oranıdır. $\text{Duyarlılık} = \frac{DP}{DP+YN}$ şeklinde gösterilir.
- Özgüllük, gerçekte hasta olmayan bireylerin testlerinin negatif sonuç verme oranıdır. $\text{Özgüllük} = \frac{DN}{DN+YP}$ şeklinde ifade edilir.
- Toplam Doğruluk, Hasta ve hasta olmayan kişilerin yüzde kaçının önerilen yöntemle tanınabildiğini gösterir. $\text{Toplam Doğruluk} = \frac{DP+DN}{DP+DN+YN+YP}$

Çizelge 4.3’ de öznitelik vektörü IEMG+SGS+WAMP+MF seçilmesi durumunda her bir sınıflandırma algoritması için yukarıda anlatılan ölçütler

hesaplanmıştır. ALS-Sağlıklı ve ALS-Miyopati ikili sınıflarda DVM-RTF sırasıyla %97.39, %94.57 en iyi başarıyı sağlarken; Miyopati-Sağlıklı ikili sınıfında en iyi başarıyı %86.74 ile DVM-Doğrusal ve DDA sağlamıştır.


Şekil 4.18’ de DVM, K-EYK ve DA algoritmalarının başarımları ve işlem süreleri, IEMG+SGS+WAMP+MF, IEMG+MNP+WAMP+MF ve IEMG+WAMP+MF çoklu öznitelik vektörleri ve RMS için hesaplanmıştır. Her üç çoklu öznitelik vektörlerinin başarımları birbirlerine yakın değişimler sergilemiştir. Sınıflandırma algoritması DVM-RTF, öznitelik vektörü RMS seçilmesi durumunda işlem süresi diğerlerine göre artış göstermiştir. Diğer durumlar için işlem süreleri hemen hemen aynı kalmıştır. Her üç sınıflandırmada K-EYK algoritmasında komşu sayısının K=11 seçilmesi başarıyı arttırmıştır. ALS-Sağlıklı ve ALS-Miyopati ikili sınıflandırmada DVM algoritması için çekirdek fonksiyonu doğrusal yerine, RTF seçilmesi; diskriminant analizinde ise doğrusal fonksiyon yerine kuadratik fonksiyon seçilmesi sınıflandırma başarımlarını arttırmıştır. Ancak Miyopati-Sağlıklı ikili sınıflandırmada DVM’ de doğrusal fonksiyon yerine RTF seçilmesi, aynı şekilde Diskriminant analizde karesel fonksiyon yerine doğrusal fonksiyon seçilmesi her iki sınıflandırma algoritmalarının daha düşük başarımlarına neden olmuştur. Bunun sebebi Miyopati-Sağlıklı ikili sınıflandırmada farklı sınıf verilerinin yoğun biçimde iç içe geçmiş olması sonucunda; eğitim aşamasında aşırı uyum (overfitting) göstermesinden kaynaklanmaktadır. Aşırı uyum sınıflandırma algoritmalarının başarımlarını kötü yönde etkilemektedir. Bu duruma en iyi örnek Şekil 4.17’ de sınıflandırma algoritması DVM seçilmesi durumunda verilmiştir: Özellikle Miyopati-Sağlıklı sınıflandırmanın ALS-Sağlıklı, ALS-Miyopati ikili sınıflandırmalara göre RMS öznitelik vektörünün farklı sınıflara ait verileri iyi ayırtamadığı görülmektedir.




Şekil 4.1. ALS, Miyopati ve Sağlıklı Kişilere Ait Verilerin RMS Öznitelik Vektörlerinin Ortalama Değer Değişimi

Çizelge 4.2. Zaman ve Frekans Uzayında Öznitelik Vektörleri


Zaman Uzayındaki Öznitelik Vektörleri		Frekans Uzayındaki Öznitelik Vektörleri	
Standart Sapma $STD = \sqrt{VAR}$	Tümleşik EMG $IEMG = \sum_{i=1}^N x_i $	Tepe Frekans $PKF = \max(P_j), j=1,...,M$	Ortalama Frekans $MF = \sum_{i=1}^M f_i P_i / \sum_{i=1}^M P_i$
Ortalama Mutlak Değer $MAV = \frac{1}{N} \sum_{i=1}^N x_i $	EMG Varyans $VAR = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$	Ortalama Güç $MNP = \sum_{i=1}^{OCF} P_i / M$	Ortanca Frekans(MDF) $\sum_{j=1}^{MDF} P_j = \sum_{j=MDF}^M P_j = \frac{1}{2} \sum_{j=1}^M P_j$
Etkin Değer $RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	Willison Genliği $WAMP = \sum_{i=1}^{N-1} [f(x_n - x_{n+1})]$ $f(x) = \begin{cases} 1, & x \geq \text{esik} \\ 0, & \text{aksi durumda} \end{cases}$	1.,2. ve 3. Dereceden Spektral Hareket $SM1 = \sum_{j=1}^M P_j f_j$ $SM2 = \sum_{j=1}^M P_j f_j^2$ $SM3 = \sum_{j=1}^M P_j f_j^3$	
Sıfır Geçiş Sayısı $\{x_i > 0 \text{ ve } x_{i+1} < 0\} \text{ veya } \{x_i < 0 \text{ ve } x_{i+1} > 0\} \text{ ve } x_i - x_{i+1} \geq \text{esik}$	(SGS)	N: EMG işaretinin uzunluğu; M: Güç spektral yoğunluğunun uzunluğu; Pj: j. frekansta EMG güç spektrumu; OCF: Ortanca Frekans	




Şekil 4.2. ALS- Sağlıklı Sınıflandırmada Zaman Düzlemindeki Öznitelik Vektörlerinin Başarımları




Şekil 4.3. ALS- Sağlıklı Sınıflandırmada Frekans Düzlemindeki Öznitelik Vektörlerinin Başarımları




Şekil 4.4. ALS- Sağlıklı Sınıflandırmada Nicel MUAP Parametreleri İle Elde Edilen Morfolojik Öznitelik Vektörlerinin Başarımları




Şekil 4.5. ALS- Sağlıklı Sınıflandırmada Çoklu Öznitelik Vektörlerinin Başarımları




Şekil 4.6. ALS- Miyopati Sınıflandırmada Zaman Düzlemindeki Öznitelik Vektörlerinin Başarımları




Şekil 4.7. ALS- Miyopati Sınıflandırmada Frekans Düzlemindeki Öznitelik Vektörlerinin Başarımları




Şekil 4.8. ALS- Miyopati Sınıflandırmada Nicel MUAP Parametreleri ile Elde Edilen Morfolojik Öznitelik Vektörlerinin Başarımları




Şekil 4.9. ALS- Miyopati Sınıflandırmada Çoklu Öznitelik Vektörlerinin Başarımları




Şekil 4.10. Miyopati-Sağlıklı Sınıflandırmada Zaman Düzlemindeki Öznitelik Vektörlerinin Başarımları




Şekil 4.11. Miyopati-Sağlıklı Sınıflandırmada Frekans Düzlemindeki Öznitelik Vektörlerinin Başarımları




Şekil 4.12. Miyopati-Sağlıklı Sınıflandırmada Nicel MUAP Parametreleri ile Elde Edilen Morfolojik Öznitelik Vektörlerinin Başarımları




Şekil 4.13. Miyopati-Sağlıklı Sınıflandırmada Çoklu Öznitelik Vektörlerinin Başarımları




Şekil 4.14. ALS-Sağlıklı Sınıflandırmada Zaman, Frekans ve Çoklu Öznitelik Vektörlerinin Başarımları




Şekil 4.15. ALS-Miyopati Sınıflandırmada Zaman, Frekans ve Çoklu Öznitelik Vektörlerinin Başarımları



Şekil 4.16. Miyopati-Sağlıklı Zaman, Frekans ve Çoklu Öznitelik Vektörlerinin Başarımları



Şekil 4.17. İkili Sınıflandırmada Öznitelik Vektörü RMS Olması Durumunda DVM-Doğrusal ve DVM-RTF Algoritmalarının Oluşturduğu Sınır Hatları



Şekil 4.18. Çoklu Öznitelik Vektörleri için DVM, K-EYK ve DA Sınıflandırıcılarının Başarımlarının Karşılaştırılması

Çizelge 4.3. Başarım Değerlendirme

ALS ve SAĞLIKLI (Özellik Vektörü: IEMG+SGS+WAMP+MF)							
Sınıflandırıcı	DP	YP	YN	DN	Duyarlılık (%)	Özgüllük (%)	Toplam Doğruluk(%)
DVM(Doğrusal)	203	23	27	207	88.26	90.00	89.13
DVM(RTF)	224	6	6	224	97.39	97.39	97.39
K-EYK(K=1)	198	21	32	209	86.09	90.87	88.48
K-EYK(K=11)	198	14	32	216	86.09	93.91	90.00
DDA	203	23	27	207	88.26	90.00	89.13
KDA	198	5	32	225	86.09	97.83	91.96
MİYOPATİ ve SAĞLIKLI (Özellik Vektörü: IEMG+SGS+WAMP+MF)							
Sınıflandırıcı	DP	YP	YN	DN	Duyarlılık (%)	Özgüllük (%)	Toplam Doğruluk(%)
DVM(Doğrusal)	186	17	44	213	80.87	92.61	86.74
DVM(RTF)	189	31	41	199	82.17	86.52	84.35
K-EYK(K=1)	185	36	45	194	80.43	84.35	82.39
K-EYK(K=11)	193	26	37	204	83.91	88.70	87.39
DDA	186	17	44	213	80.87	92.61	86.74
KDA	186	37	44	193	83.91	80.87	82.39
ALS ve MİYOPATİ (Özellik Vektörü: IEMG+SGS+WAMP+MF)							
Sınıflandırıcı	DP	YP	YN	DN	Duyarlılık (%)	Özgüllük (%)	Toplam Doğruluk(%)
DVM(Doğrusal)	210	29	20	201	91.30	87.39	89.35
DVM(RTF)	214	9	16	221	93.04	96.09	94.57
K-EYK(K=1)	200	31	30	199	86.96	86.52	86.74
K-EYK(K=11)	198	31	32	199	86.09	86.52	86.30
DDA	210	29	200	201	91.30	87.39	89.35
KDA	200	9	30	221	86.96	96.09	91.52

5. SONUÇ VE ÖNERİLER

Bu tez çalışması melez kümeleme algoritmasının sınıflandırma doğruluğunu arttırmada hiyerarşik kümelemeye göre daha iyi olduğunu; önerilen öznitelik vektörleri arasında çoklu öznitelik vektörlerinin tekli öznitelik vektörlerine göre daha başarılı olduğunu göstermiştir. Bu çalışma ile sınıflandırma başarımının öznitelik vektörünün sınıflar arası ayrılabilirliğinin yüksek derecede olmasına bağlı olduğu anlaşılmıştır. Bu amaç doğrultusunda IEMG+SGS+WAMP+MF çoklu öznitelik vektörünün kullanılması durumunda ALS-Sağlıklı ve ALS-Miyopati ikili sınıflarda DVM-RTF sırasıyla %97.39, %94.57 en iyi başarıyı sağlarken; Miyopati-Sağlıklı ikili sınıfında en iyi başarıyı %86.74 ile DVM-Doğrusal ve DDA sağlamıştır.

Sayıli miktarda bilgisayar tabanlı nicel EMG analiz algoritması geliştirilmiştir. Tıbbi bulgular için standart EMG uygulamaları yapılmaktadır. EMG işaretlerinin klinik teşhis ve biyomedikal uygulama alanlarında birçok sinyal işleme ve yapay zeka teknikleri kullanarak çok fazla denemeler gerçekleştirilmiştir. Ancak bu analiz algoritmalarından bazıları ticari olarak mevcut olmasına rağmen hemen hemen hiçbir yaygın rutin klinik bulgu için genel olarak kullanılmamıştır. EMG cihazları ile birlikte kullanılan yazılımlar bazı firmaların internet sayfalarında kas test cihazlarının yazılımlarının sınırlı sayıda veya sınırlı günde (10-20 kullanım veya 30 gün gibi vs.), tanıtım/pazarlama amaçlı, ücretsiz kullanım için deneme sürümleri mevcuttur, bu duruma en iyi örnek Delsys firmasının 30 gün süre ile kullanıma açık tamamen işlevsel ve ticari yazılımı EMGworks 4.2 yazılımıdır (EMGworks 4.2., 2015). Ancak tanı koymaya yönelik EMG cihazlarının üreticilerinin böyle bir uygulamasına rastlanmamıştır.

Bu çalışmada beş işlem aşamasından oluşan model; doktorlara, teşhis ve karar aşamasında yardımcı olmak amacıyla hastalardan alınan EMG işaretlerini nöromusküler rahatsızlığı olan veya olmayan şeklinde sınıflandırmaktadır. Bu yapı sayesinde gelecekte yapılacak çalışmalar ile EMG analiz algoritmasının uzman

teşhisine yardımcı olacak, gerçek zamanlı çalışan otomatik bir sistem şeklinde tasarlanmasına imkan sağlayacaktır.

Bu çalışma sınıflandırma başarımının etkili öznitelik vektörüne bağlı olduğunu göstermiştir. İleriki çalışmalarda öznitelik vektörü üç farklı şekilde oluşturulabilir: birincisi morfolojik parametrelerin (süre, genlik, yükselme zamanı, alan, uydu, faz ve dönüş sayısı) tamamını içeren çoklu öznitelik vektörleri, ikincisi bu çalışmada denenen zaman ve frekans düzlemi özniteliklerinden oluşan çoklu öznitelik vektörleri şeklinde; üçüncü olarak ise MUAP' ı en az katsayı ile temsil edecek (dalgacık analizi vb.) modelin oluşturulması ve bu modele ait katsayıların öznitelik vektörleri olarak kullanılmasıdır.

İleriki çalışmalarda amaçlanan bu çalışmada denenen algoritmik yazılımların Şekil 5.1' de 100.000 TL hibe ile bölümde tasarlanan EMG cihaz prototipine entegre etmektir. Bu sayede EMG cihazı uzman kişiye işaretleri sadece görüntülemekle kalmayacak; hastadan alınan verileri analiz edip kişinin miyopati veya nöropati hastası olup olmadığını söyleyebilecektir. Aynı zamanda bu çalışmada yazılan programların entegre edilecek EMG cihazında çalışabilmesi için gerçek zamanlı çalışan bir yazılım dilinde yazılması gerekmektedir.

Bu çalışma, sadece nöromusküler hastalıkların teşhisi için hazırlanacak olan bir uzman sistemin alt yapısı ve ön hazırlığı niteliğindedir. Bundan sonraki çalışma; bu tezde oluşturulan kas-sinir hastalıklarının sınıflandırılması için oluşturulan yapının Türkiye çapında elde edilecek veri seti ile başarımlarının ölçülmesi olacaktır. Doktor tanı sürecinde morfolojik parametrelerin yanı sıra hastanın hikayesi, yaşı cinsiyeti ve kişinin medikal geçmişi gibi bilgiler ışığında kişinin hasta olup olmadığına karar verir. Bu çalışmada verilerin sınırlı sayıda olması nedeniyle sınıflandırma aşamasında verilerin testi; kas grubu, yaş, cinsiyet gibi bilgilerine bakılmaksızın yapılmıştır. Eğer hastalık teşhisinde kullanılacak model; yaş, cinsiyet ve kas grupları dikkate alınarak eğitilirse, bu durum hastalık teşhisinde kullanılan yapının daha az hata yapmasına imkan sağlayacaktır. Bu nedenle veri seti oluşturulurken yaşa (çocuk, genç ve orta yaşlı gibi), cinsiyete, vücut şekline (zayıf, normal, kilolu gibi) ve hastalık durumuna (sağlıklı, nöropati, miyopati gibi), kas grubuna göre kaydın yapılması gerekmektedir. Veri bankasının oluşturulmasında çeşitlilik önemlidir bu açıdan bu veri setinin oluşturulması belli bir süreci gerektirir.

EMGlab internet sitesinden alınan veriler sadece miyopati, sağlıklı ve ALS şeklinde etiketlenmiştir. Ancak verilerin hastalığın başlangıç, orta veya terminal

dönemde olup olmadığı bilgisi yer almamaktadır. Kendi veri bankamızı oluştururken verileri hastalığın dönem bilgisini de içerecek şekilde etiketlenecektir. Bu sayede kişinin hastalığın hangi aşamasında olduğunu algoritmik olarak belirlemek mümkün olacaktır.


Bu çalışma kapsamında kullanılmak üzere Samsun Ondokuz Mayıs Üniversitesi Nöroloji bölümünde kullanılan Medelek Firmasına ait EMG cihazı ile birkaç hastadan kayıt alınmıştır. Ancak bu cihaz sadece ses dosyası formatında kayıtlanmaya imkan sağlamaktadır. EMG verilerinin ses verisi şeklinde kayıtlanması verilerin genlik ve frekans bilgilerinde değişime ve kayıplara sebep olmuştur. Bunun sonucu olarak bu şekilde kayıt edilen EMG verileri ile bu çalışmada oluşturulan sınıflandırma algoritması test edilememiştir. Ondokuz Mayıs Üniversitesi Elektrik-Elektronik Mühendisliği BAL-LAB' da bulunan Şekil 5.2' de verilen Nihon Kohden marka EMG cihazı ile yukarıda bahsedilen zorluklar olmadan kayıt söz konusu olduğundan Samsun çapında veri seti eldesi için bu cihaz ileriki çalışmalarda kullanılabilir.

Gelecekte yapılması düşünülen hedeflerden biride kas-sinir hastalıkları teşhisine yönelik Şekil 5.3' deki gibi hasta maketi üzerinde EMG testidir. Veri eldesinde kas - sinir hastası olan kişilerin farklı kas gruplarından alınan EMG verileri başlangıç, orta ve ileri derecede sınıflandırıldıktan sonra bilgisayar ile bağlantılı bir hasta maketine verilebilir. Doktor adayları hasta maketi üzerinde iğne EMG kaydı yaparken ölçüm yapacağı kasta iğneyi doğru noktaya batırıp batırmadığını bir uyarı sesi ile duyabilmeli, doğru noktada ise EMG verileri ekranda görüntülenebilmelidir. Burada amaçlanan tıp öğrencilerinin ve EMG alanında eğitim gören kişilerin bu alanda bilgilerini bir simülasyon cihazı üzerinde pekiştirmek ve canlı hastaya müdahale etmeden önce tecrübe kazanmalarını sağlamaktır.

Bilgisayar


Güç Kaynağı

Dört kanallı EMG yükseltici



Programlanabilir akım kaynağının uyarı (stimulator) EMG elektrodu

Şekil 5.1. Prototip EMG Cihazı



Şekil 5.2. Dört Kanallı EMG Cihazı



Şekil 5.3. Anatomik Eğitim Maketi (URL-1, 2015)

KAYNAKLAR

- Abe, S., 2005. *Support Vector Machines for Pattern Classification*, Advances in Pattern Recognition, 1 edition, Springer, London.
- Abel, E., Zacharia, P., Forster, A., Farrow, T., 1996. Neural network analysis of the EMG interference pattern, *Med. Eng. Phys.* 18 (1), 12–17.
- Alpaydın, E., 2004. *Introduction to Machine Learning*, MIT Press. London.
- Andreassen, S., 1987. Methods for computer-aided measurement of motor unit parameters, in Proc. *The London Symp.*, R. J. Ellington ve ark., Eds., *EEG suppl.* 39, 13–20.
- Arslan, Y. Z., 2005. İnsanın İki Kolunun Ortak Hareketi Esnasında Oluşan Eklem Momentlerinin Elektromyografi Sinyalleri Yardımıyla Analizi, Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 198506.
- Bahadır, C., EMG, <http://www.cengizbahadir.com>, (Ziyaret Edildi : 26 Temmuz 2015).
- Beni, X., 1991. Validity measure for fuzzy clustering. *IEEE Trans. Pattern Anal. Mach. Intell.*, 13(8), 841-846.
- Bergmans , J., 1971. Computer-assisted on-line measurement of motor unit potential paremeters in human electromyography. *Electromyography*, 11,161-181.
- Bergmans , J., 1973. Computer-assisted measurement of the parameters of single motor unit potentials in human electromyography, in Desmedt JE (ed): *New Dtelopments in Electromyography and Clinical Netcrophysiology*, 2, 482-488
- Bezdek, C., 1974. Cluster validity with fuzzy sets., *J. Cybernetics*, 3, 58-72.
- Bezdek, J. C., 1981. *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum, New York.
- Bezdek, J. C., 1984. FCM: The Fuzzy C-Means clustering algorithm, *Computers & Geosciences*, 10(2-3), 191-203.
- Bischoff, C., Stalberg, E. , Falck, B., Edebol K., 1994. Reference values of motor unit action potentials obtained with multi-MUAP analysis, *Muscle & Nerve*, 17 (8), 842–851.
- Bhardwaj, A., Manish,, A., Arora, K., 2012. Classification of MUAPs by using ANN pattern recognition technique, *Int. J. Sci. Res. Eng. Technol. (IJSRET)*, 1:10–14.
- Boostani, R., Moradi, M. H., 2003. Evaluation of the forearm EMG signal features for the control of a prosthetic hand, *Physiological Measurement*, 24(2), 309–319.
- Bozkurt, M. R., 2007. EMG İşaretlerinin Modern Yöntemlerle Önışlemesi ve Sınıflandırılması, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya, 216254.

- Burges, J. C., 1998. A Tutorial on Support Vector Machines for Pattern Recognition, *Data Mining and Knowledge Discovery*, 2, 121-167.
- Carr, J. J., Brown, J. M., 2000. *Introduction to Biomedical Equipment Technology*, 4thEd., Prentice Hall, New Jersey.
- Christodoulou, C., Pattichis, C., 1999. Unsupervised pattern recognition for the classification of EMG signals, *IEEE Trans. Biomed. Eng.*, 46, 169.
- Chu J. U., Moon I., Mun M. S., 2006. A real-time EMG pattern recognition system based on linear-nonlinear feature projection for a multifunction myoelectric hand, *IEEE Transactions on Biomedical Engineering*, 53, 11, 2232- 2239.
- De Luca, C. J., 2011. http://nmrc.bu.edu/tutorials/motor_units/decomp.html. (Ziyaret Edildi: 13 Nisan 2011).
- Dobrowolski, A., Wierzbowski, M., Tomczykiwicz, K., 2012. Multiresolution MUAPs decomposition and DVM-based analysis in the classification of neuromuscular disorders, *Comput. Methods Prog. Biomed*, 107 (3), 393–403.
- Doğan, M., 2003. Yapay Sinir Ağları Temelli Tıbbi Teşhis Sistemi, Y. Lisans Tezi, Anadolu Üniversitesi, Fen bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Eskişehir, 131199.
- Dorfman, L. J., McGill, K. C., 1988. AAEE Minimonograph 29: Automatic Quantitative Electromyography, *Muscle Nerve.*; 11 (8): 804-18.
- EMGworks 4.2., 2015. Signal Acquisition and Analysis Software User's Guide, <http://www.delsys.com/products/emgworks-software/> (Ziyaret Tarihi: 15 Ekim 2015).
- Ejderha, H., 2009. EMG İşaretlerini Kullanılarak Yorgunluk Seviyeleri; Neuro-Fuzzy ve YSA İle Sınıflandırılması, Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Kahramanmaraş, 252534.
- Ertekin, C., 2006. *Sentral ve Periferik EMG*, Meta Basım Matbacılık Hizmetleri, İzmir.
- Fattah, S. A., Doulah, S. U., Ahmed, M., 2012. Evaluation of Different Time and Frequency Domain Features of Motor Neuron and Musculoskeletal Diseases., *International Journal of Computer Applications*, 43(23), 34-40.
- Fisher, 1936. R. A. *The Use of Multiple Measurements in Taxonomic Problems*, *Annals of Eugenics*, 7, 179–188.
- Gan, G., Ma, C., Wu, J., 2007. *Data Clustering: Theory, Algorithms, and Applications*, SIAM, Philadelphia.
- Greenes, R. A., Pappalardo, A. N., Narble, C. W., Barnett, G., 1969. Design and Implementation of a Clinical Data Management System, *Computers and Biomedical Research* 2, 469-485.
- Guler, N. F., Koçer, S., 2005. Classification of EMG signals using PCA and FFT, *J. Neurosci. Methods*, 29 (3), 241–250.
- Gutierrez, R., L13: Cross-validation, http://research.cs.tamu.edu/prism/lectures/pr/pr_l13.pdf, (Ziyaret Tarihi: 5 Mayıs 2015)

- Güler, N., 2002. Antenatal Fetüs Verilerinin Örüntü Tanıma Yöntemleriyle Tanımlanması, Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 128816.
- Hamilton, A., Stashuk, D., Tizhoosh, H., 2007. Fuzzy classification using pattern discovery, *IEEE Trans. Fuzzy Syst.*, 15 (5), 772–783.
- Höppner, F., Klawonn, F., Kruse, R., Runkler, T., 2000. *Fuzzy Cluster Analysis*, John Wiley & Sons
- Hudgins, B., Parker, P., Scott, R., 1993. A new strategy for multifunction myoelectric control, *IEEE Transactions on Biomedical Engineering*, 40(1), 82–94.
- Katsis, C., Fotiadis, D., Likas, A., Sarmas, I., 2002. A novel EMG decomposition method that discovers the number of MUAP clusters, *Proceedings of the 2nd European Medical and Biological Engineering Conference EMBEC*, Vienna, Austria, 400.
- Katsis, C., Likas, A., Fotiadis, D., 2006. A novel method for automated EMG decomposition and MUAP, *Artificial Intelligence in Medicine*, 37(1), 55-64.
- Kaur, G., Arora, A. , Jain, V., 2010. EMG diagnosis via ar modelling and binary support vector machine classification, *Int. J. Eng. Sci. Technol.*, 2, 1767–1772.
- Kaur, G., Arora, A. S. , Jain, V. K., 2009. Multi-class support vector machine classifier in EMG diagnosis, *WSEAS Trans. Signal Process.*, 2, 379.
- Kayhan, G., Ozdemir, A. , Eminoglu, I., 2012. Reviewing and designing pre-processing units for RBF networks: Initial structure identification and coarse-tuning of free parameters, *Neural Computing and Applications*, 22, 7-8.
- Kilby, J., 2005. Wavelet Analysis and Classification of Surface Electromyography Signals, Master's thesis, Engineering University of Technology Auckland, New Zealand.
- Kimura, J., 1983. *Electrodiagnosis in disease of nerve and muscle: principles and practice*, F. A. Davis, Philadelphia,.
- Kohonen, T., 1984. *Self-Organizing and Associative Memory*, Springer-Verlag, Berlin.
- Krishna V, A., Thomas P., 2005. Classification of EMG Signals Using Spectral Features Extracted from Dominant Motor Unit Action Potential, *International Journal of Engineering and Advanced Technology (IJEAT)*, ISSN: 2249 – 8958, Volume-4 Issue-5.
- Kulikowski, C. A., 1979. Pattern Recognition Approach to Medical Diagnosis, *IEEE Trans. Sys. Sci., Cyber* SS6(3), 173-178.
- Li, G., Li, Y., Yu, L., Geng, Y., 2011. Conditioning and sampling issues of EMG signals in motion recognition of multifunctional myoelectric prostheses, *Annals of Biomedical Engineering*, 39(6), 1779–1787.
- Linkens, D. A., Chen, M. Y., 1997. Input selection and partition validation for fuzzy modelling using neural network, *Fuzzy Set and Systems*, 107(3), 299-308.

- Maboud N., F., A., Elbagoury M., B., Roushdy M., Salem M.,A., 2015, Hybrid Classifier for Neuromuscular Disorders Diagnoses, *Egyptian Computer Science Journal*, Vol. 39 No. 1.
- Macit, E G., 2014. Çok Kriterli Sıralı Sınıflandırma Problemi Ve Sağlık Sektöründe Bir Uygulama, Y. Lisans Tezi, Erciyes Üniv, Fen Bilimleri Enstitüsü,Kayseri, 374319.
- MathWorks, 2007. *Matlab Toolbox of Bioinformatics: User's Guide*, Mathworks Inc.,
- Merletti, R. , Parker, P. A., 2004. *Electromyography*, John Wiley & Sons, Hoboken New Jersey, 259-304.
- Nikolic M., 2001. Detailed Analysis of Clinical Electromyography Signals EMG Decomposition, Findings and Firing Pattern Analysis in Controls and Patients with Myopathy and Amyotrophic Lateral Sclerosis, PhD Thesis, , University of Copenhagen, Faculty of Health Science.
- Okkesim, Ş., 2006. Ortodontik Anormallikler Bulunan Hastalarda Kullanılan Pre Ortodontik Trainer Aparentinin Çene Ve Ağız Çevresindeki Kaslara Olan Etkisinin EMG Kayıtlarıyla Değerlendirilmesi, Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, , Kayseri, 197069.
- Oskoei, M. A., Hu, H., 2006. GA-based feature subset selection for myoelectric classification. In Proc. Int. Conf. Robot, *Biomimetics*, 1465–1470.
- Oskoei, M. A., Hu, H., 2008. Support vector machine based classification scheme for myoelectric control applied to upper limb, *IEEE Transactions on Biomedical Engineering*, 55(8), 1956–1965.
- Özkaya, U., 2005. Yüzey EMG Sinyallerinin Analizi ve Motor Ünite Aksiyon Potansiyellerinin Belirlenmesi. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Isparta, 168695.
- Panagiotacopoulos , N., Lae, J. S., Pope, M. H., 1998. Evaluation of EMG signals from rehabilitated patients with low back pain using wavelets. *J. Electromyography and Kinesiology*, 8, 269 – 278.
- Pangborn, A., 2010. Scalable Data Clustering for Flow Cytometry using GPUs. Master's thesis, The Kate Gleason College of Engineering at Rochester Institute of Technology, Rochester, New York.
- Pattichis, C.S., Schizas C.N., Middleton L, 1995. Neural networks models in EMG diagnosis, *IEEE Trans. on Biomedical Engineering*, 42 (5), 1–11
- Patil, V., 2007. Different forms of modularity in trunk muscles in the rat revealed by various. , Thesis (Ph. D.), Drexel University.
- Pfeiffer, G., 1999. The diagnostic power of motor unit potential analysis: an objective Bayesian approach, *Muscle Nerve*, 22 (5), 584–591.
- Philipson, L., 1987. The electromyographic signal used for control of upper extremity prostheses and for quantification of motor blockade during epidural anaesthesia. Ph.D. Thesis, Linköping University, Linköping, Sweden.
- Phinyomark, A., Phukpattaranont, P., Limsakul, C., 2012. Feature reduction and selection for EMG signal classification, *Expert Syst. Appl.*, 39(8), 7420-7431.

- Rasheed, S., Stashuk, D., Kamel, M., 2006. Adaptive fuzzy k-NN classifier for EMG signal decomposition, *Med. Eng., Phys.* 28, 694.
- Stalberg, E., Falck, B., Lang, H., Rosenfalck, A., Trojaborg, W., 1986. Quantitative Analysis Of Individual Motor Unit Potentials: A Proposition For Standardized Terminology And Criteria For Measurement, *J. Clinic Neurophysiology*, 3: 313-348 .
- Stalberg, E., Falck, B., Sonoo, M., Stalberg, S., 1995. Multi-MUP EMG analysis—A two year experience in daily clinical work, *Electroencealography and Clinical Neurophysiology* 97. Amsterdam, the Netherlands: Elsevier Science, 145–154.
- Stashuk, S., 2001. EMG signal decomposition: how can it be accomplished and used?, *Journal of Electromyography and Kinesiology*, 11, 151–173.
- Subasi, A., 2012. Medical decision support system for diagnosis of neuromuscular disorders using DWT and fuzzy support vector machines, *Comput. Biol. Med.*, 42, 806–815.
- Subasi, A., 2013. Classification of EMG signals using PSO optimized DVM for diagnosis of neuromuscular disorders, *Comput. Biol. Med.*, 43, 576–586.
- Subasi, A., Yilmaz, M., Ozcalik, H., 2006. Classification of EMG signals using wavelet neural network, *J. Neurosci. Methods*, 156 (1–2), 360–367.
- Tan, Y., Wang, J., April 2004. A Support Vector Machine with a Hybrid Kernel and Minimal Vapnik-Chervonenkis Dimension, *IEEE Transactions on Knowledge and Data Engineering*, v.16 n.4, 385-395.
- Tatlıdil, H., 1996. *Uygulamalı Çok Değişkenli İstatiksel Analiz*, Cem Web Ofset Ltd., Ankara.
- Tenore, V., Fahmy A., Acharya S., Thakor N., V., 2009. Decoding of individuated finger movements using surface electromyography, *IEEE Transactions on Biomedical Engineering*, 56(5), 1427–1434.
- Tosunoğlu, O., Model Değerlendirme. <http://bilmuh.gyte.edu.tr/~htakci/vm/> (Ziyaret Edildi: 7 Mayıs 2012).
- Türkoğlu, İ., 1996. Yapay Sinir Ağları İle Nesne Tanıma. , Y. Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.
- Uludağ, B., 2002. *Makro EMG*, Ege Üniversitesi Tıp Fakültesi, Nöroloji ABD Ve Klinik Nörofizyoloji Bilim Dalı, Bornova, İzmir.
- URL-1: <http://www.gazilabmedikal.net/ileri-hemsirelik-egitim-maketi-d497.htm#> (Ziyaret Edildi: 10 Ağustos 2015).
- URL-2: <https://en.wikipedia.org/wiki/Electrocardiography>, (Ziyaret Edildi: 12 Temmuz 2015).
- URL-3: <http://www.EMGlab.net>, (Ziyaret Edildi: 20 Mayıs 2015).
- Vapnik, V. N., 1999. An Overview of Statistical Learning Theory, *IEEE transactions on Neural Networks*, 10, 988-999.
- Weiss, L., 2004. Easy EMG, *A Guide to Performing Nerve Conduction Studies and Electromyography*, 271.

- Windham, M. P., 1982. Cluster validity for the fuzzy c- means clustering algorithm, *IEEE Trans. Patern Anal. Mach. Intell.*, 4(4), 357-363.
- Winslow, J., 2008. Automatic classification of long term involuntary spontaneous EMG, Phd, University Of Miami, Florida.
- Xiang, Y., 1993. Multiply sectioned Bayesian networks for neuromuscular diagnosis, *Intell. Med*, 5, 293.
- Xie, H. B., Z. Z. Wang, H. Huang, C. Qing, 2003. Support vector machine in computer aided clinical electromyography Machine Learning and Cybernetics, 2003 International Conference on, *IEEE*, 2, 1106-1108.
- Yasukavva, T., 1993. A fuzzy-logic-based approach to qualitative modeling, *IEEE Trans. on Fuzzy Systems*, 1(1), 7-31.
- Yousefi, J., Hamilton, A., 2014. Characterizing EMG data using machine-learning tools, *Computers in biology and medicine* 51, 1-13.
- Zardoshti, M., Wheeler, B. C., Badie, K., Hashemi, R. M., 1995. EMG feature evaluation for movement control of upper extremity prostheses, *IEEE Transactions on Rehabilitation Engineering*, 3(4), 324–333.
- Zecca, M., Micera, S., Carrozza, M. C., Dario, P., 2002. Control of multifunctional prosthetic hands by processing the electromyographic signal. *Critical Reviews in Biomedical Engineering*, 30(4–6), 459–485.

EKLER

EK A : Matlab kodları

EK B: ALS, miyopati ve sağlıklı kişilere ait EMG verileri

EK B1: ALS hastalarına ait EMG verileri

EK B2: Sağlıklı kişilere ait EMG verileri

EK B3: Miyopati hastalarına ait EMG verileri

EK C: MUAP' ların melez algoritma ile kümelendirilmesi

EK D: Tek kullanımlık konsantrik iğne ve yüzey elektrotlar

EK A: Matlab kodları

%Veri Edinme Ön İşlem için Matlab Kodu

%1-Veri Edinme Ön İşlem

```
clear all;clc;close all ;
sf=10000;
Wn=[10 1500]/(sf/2);
renk='black'; Marker='none';n=4;stip='bandpass';dbg = true;
dbnm = pathos('I:\kod_subat_2015\01-dataset-olusturma\db\als\');
dbnm_mat = pathos('I:\kod_subat_2015\01-dataset-olusturma\db\mat\myomat\');
mkdir(dbnm_mat);
DIR = dir(strcat(dbnm, '*.csv'));
sz = length(DIR);
if sz == 0,
    error(sprintf('"%s" icerigi bos. README.md yi oku.\n', dbnm));
end
for i=1:sz
    if dbg, fprintf('%d. veri isleniyor...\n', i); end
    dnm = DIR(i).name
    dfnm = strcat(dbnm, dnm);
    ham = csvread(dfnm);
    data.t = ham(:, 1);
    data.X = ham(:, 2);
    data.t';
    if dbg,
        figure(1), plot(data.t, data.X);
        title('ALS')
        ylabel('Genlik (uV)');xlabel('süre (sn)');
        axis([0,2,-1000,1000]);
        pause
    end
    s2 =saysuzgec(data.X,data.t,sf,Wn,n,stip,renk,Marker,dnm);
    data.X=s2;
    if dbg,
        plot(data.t, data.X);
    end
    [t, nm] = fileparts(dnm);
    save(strcat(dbnm_mat, nm, '.mat'), 'data');
end
%-----
%Alt Fonksiyon
function s2 = saysuzgec (data,t,sf,Wn,n,stip,renk,Marker,dnm)
datalength = size(data,1);
EMGmn=data;
Y=fft(EMGmn(1:datalength),sf);
Pyy=Y.*conj(Y)/sf;
f=sf*(0:(sf/2))/sf;
[b,a]=cheby1(n,0.05, Wn,stip);
EMGnfl=filtfilt(b,a,EMGmn);
s2=EMGnfl;
```

```

%-----
%Bölütleme için Matlab Kodu
clear all; clc; close all
Fs = 10000; % Hz
dbg = false;
dbgv=true;
dbnm_mat = pathos('F:\kod_subat_2015\01-dataset-olusturma\db\mat\myomat\');
dbnm_mats = pathos('F:\kod_subat_2015\02-segmentasyon\db\seg\myomat\');
DIR = dir(strcat(dbnm_mat, '*.mat'));
sz = length(DIR);
for di=1:sz
    dnm = DIR(di).name
    if dbgv, fprintf('%d. veri isleniyor...\n', di); end
    dnm = DIR(di).name;
    dfnm = strcat(dbnm_mat, dnm);
    load(dfnm);
    idx = find(data.X);
    xx = data.X;
    %Kayan pencere suresini ve kaç tane oldugunu belirle
    pen_sure = 1*1e-3;
    pen_point = Fs * pen_sure;
    pencere_sayi=round(size(xx,1)/pen_point);
    %-----
    bn=1;%kayan pencere için başlangıç
    %Bulunan degerler için dizi oluşturma
    ara_nokta=[];ara_noktat=[]; min_ara=[]; min_arat=[];
    alt_cizgic=[];ust_cizgic=[];pen_arac=[];pen_aratc=[];indis=[];
    %-----
    3) findpeak üzerinden aday framelerin orta noktalarının indisi
    [lmv, indd] = findpeaks(xx,'minpeakheight',50);
    idx_fort =idx(indd);
    for n=1:pencere_sayi-1
        sn=bn+pen_point;%kayan pencere için son nokta
        pen_ara=data.X(bn:sn);
        %Dalga biçimine göre tolereans aralığı-----
        pen_aramed=median(data.X(bn:sn));
        pen_arat=data.t(bn:sn);
        alt=pen_aramed-40;ust=pen_aramed+40;
        %-----
        xxx=(alt<=pen_ara&pen_ara<=ust);
        x=find(xxx);
        if xxx==1
            pencere_arasi=round(median(x));
            % pencere_arasi=x(end);
        else
            pencere_arasi=min(xxx) ;
        end
        nokta=pencere_arasi ;
        if n==1&nokta==0
            nokta=1;
        end
    end
end

```

```

end
if pen_ara(nokta)>50
nokta=[];
end
alt_cizgi=alt*ones(1,size(xxx,2));ust_cizgi=ust*ones(1,size(xxx,2));
alt_cizgic=[alt_cizgic ; alt_cizgi];ust_cizgic=[ust_cizgic ; ust_cizgi];
pen_arac= [pen_arac;pen_ara];
ara_nokta=[ara_nokta ; pen_ara(nokta)];
ara_noktat=[ara_noktat ; pen_arat(nokta)];
if nokta~=0
indis=[indis;find(data.t==pen_arat(nokta))];%start ve end point nokta indisi
end
min_ara=[min_ara ; pen_ara(x)];min_arat=[ min_arat;pen_arat(x)];
pen_aratc=[ pen_aratc; pen_arat];
bn=sn;
end
indis=indis';indis(2,:)=zeros;
idx_forti=idx_fort';idx_forti(2,:)=ones;
indisler=[indis idx_forti]';
indisleri=sortrows(indisler,1)';
%MUAPların başlangıç ve bitiş noktalarını belirle
startp=[];endp=[];
for w=1:size(indisleri,2)-1
if indisleri(2,w)==0 & indisleri(2,w+1)==1
startp=[startp indisleri(1,w)];
end
if indisleri(2,w)==1 & indisleri(2,w+1)==0
endp=[endp indisleri(1,w+1)];
end
end
segmenesit=[];
% sizestartp=size(startp,2)
% sizeendp=size(endp,2)
if size(startp,2)==size(endp,2)
startp_endp=[startp;endp]';
elseif size(startp,2)>size(endp,2)
for g=0:abs(size(startp,2)-size(endp,2))-1
startp(end-g)=[];
end
startp_endp=[startp;endp]';
else
for g=0:abs(size(startp,2)-size(endp,2))-1
endp(end-g)=[];
end
startp_endp=[startp;endp]';
end
for h=1:size(startp_endp,1)
frm = data.X(startp_endp(h,1):startp_endp(h,2));
t = data.t(startp_endp(h,1):startp_endp(h,2));
% Elde edilen MUAPların süreleri aynı değil eşit duruma getir.

```

```

size(frm,1);
size(segmenesit,2);
l=round((2000-size(frm,1))/2);
sesit= wextend('1','zpd',frm,l,'b');
size(sesit,2);
if size(sesit,2)<2000
    sesit=[sesit sesit(end)] ;
elseif size(sesit,2)>2000
    sesit(end)=[];
end
segmenesit=[segmenesit ; sesit];
segmen(h).X = frm;
segmen(h).t = t;
end
cc=segmenesit';
plot(segmenesit')
%Kayan sinyalleri üst üste çakıştırma-
x=cc';
son=[];
s=x(1,:);
% [a,b]=find(x(1,:)==max(x(1,:)));
for i=2:size(x,1)
aa=x(i,:);
aa=[aa zeros(1,( size(s(end,:),2)-size(x(i,:),2)))]);
[a,b]=find(s(end,:)==max(s(end,:)));
[a2,b2]=find(aa==max(aa));
se=size(s,1);
if(b2<b)
    s=[s zeros(se,(b-b2)) ];
    d=[zeros(1,(b-b2)) aa ];
    s=[s; d];
else
    s=[ zeros(se,(b2-b)) s];
    d=[ aa zeros(1,(b2-b))];
    s=[s;d];
end
end
mu=[];baslatop=[];bitistop=[];
%Kirpma
for h=1:size(s,1)-1
    MUAP= s(h,:);
    for k=1:size(MUAP,2)-1
        if MUAP(k)~=MUAP(k+1)
            basla=k;
            baslatop=[baslatop basla];
            baslamin=min(baslatop);
            break
        end
    end
    for kk=size(MUAP,2):-1:2

```

```

        if MUAP(kk)~=MUAP(kk-1)
            bitis=kk;
            bitistop=[bitistop bitis];
            bitismax=max(bitistop);
            break
        end
    end
end
for hk=1:size(s,1)
    MUAP= s(hk,:);
    mu1=MUAP([1],[baslamin:bitismax]);
    mu= [mu ;mu1] ;
end
if dbg
figure,plot(mu)
close all
end
segdata=mu';
[t, nm] = fileparts(dnm);
save(strcat(dbnm_mats, 'seg_',nm,'.mat'),'segdata');
end
%-----
%Kümeleme için Matlab Kodu
clc;clear all;close all;
delta=2;%input('Yarıçapı girin:');
dbg = true;
cizme=false;
dbnm_mat = pathos('F:\kod_subat_2015\02-segmentasyon\db\seg\healthymat\');
dbnm_mats = pathos('F:\kod_subat_2015\03-clustering\db\self_fcm_dog_test_train\healthy\');
DIR = dir(strcat(dbnm_mat, '*.mat'));
sz = length(DIR);
for di=1:sz
    clear indexler
    if dbg, fprintf('%d. veri isleniyor...\n', di); end
    dnm = DIR(di).name
    dfnm = strcat(dbnm_mat, dnm);
    load(dfnm);
    toplam_seg=segdata;
    %Adım 1:
    % Normalizasyon
    h=max(max(abs(toplam_seg)));
    for n=1:size(toplam_seg,2)
        toplam_seg(:,n)=toplam_seg(:,n)/h;
    end
    x=toplam_seg';
    [w,merkez,cm]= selfalt(x,delta) ;
    %fcm-----
    tol=10^-6;
    m=2; % ağırlıklandırma üsteli

```

```

yinele=100; % maks. yineleme
%-----
[mrkz,merkezdepo,U]=melez(x,cm,merkez,tol,m,yinele);
adet=size(mrkz,1);
U=U{size(mrkz,1)};
if adet==1
    maxU=U;
else
    maxU = max(U);
end
[toplama_ortalama,toplama_ortalama]=tekfaz_kurtul(x,mrkz,cm,indexler);
[t, nm] = fileparts(dnm);
save(strcat(dbnm_mats, 'clort_',nm,'.mat'),'toplama_ortalama');
end
%-----
%Alt Fonksiyon
function [mrkz,merkezdepo,uy]=melez(x,cm,merkez,tol,m,yinele)
%-----
% Giriş: x ... n1xn2 boyutlu veri
%      cm ... küme sayısı
%      tol ... sonlandırma kriteri (tol > 0)
%      merkez..merkezlerin başlangıç değerleri
%-----
% Çıkış : mrkz ... güncellenmiş merkez
%----- Başlangıç Değerleri -----
[n1 n2]=size(x); % veri boyutu
m=2; % ağırlıklandırma üsteli
opt_kume=cm; % maks. küme sayısı
yinele=10; % maks. yineleme
%-----Yineleme/Güncelleme-----
for c=1:cm
    for dn=1:yinele % Döngü (1)
        for i=1:c
            for j=1:n1
                d(i,j)=norm(merkez(i,:)-x(j,:));
                if d(i,j)==0
                    d(i,j)=0.000001;
                end
            end
        end
        u=(d.^(-2/(m-1)))/(ones(c,1)*sum(d.^(-2/(m-1))));
        merkez_yeni = (u.^m)*x./((ones(n2, 1)*sum((u.^m))))'; % yeni merkez
        % ones(n2, 1) toplamı verinin sütun sayısı kadar çoğaltır
        fark=norm(merkez(1:c,:)-merkez_yeni);
        if fark<tol
            dn=yinele; % Döngü(1) Kesme
        else
            merkez(1:c,:)=merkez_yeni;
        end
    end
end
end

```

```

    merkezdepo{c}=merkez_yeni;
    uy{c}=u;
    hece(c)=-( sum ( max(u).*log(max(u)) ))/n1;    % doğrulama kriteri
end
uy;
%
%----- Optimum Küme Karar Aşaması-----
hece;
son=[];
opt_kumeler=[];
if hece==0
    mrkz=merkez
end
if cm>2
for i=cm:-1:3
    if ((hece(i-1)<hece(i))&&(hece(i-1)<hece(i-2)))
        opt_kumeler=[opt_kumeler i-1];
        son=[son hece(i-1)];
    end
end
[aa,bb]=min(son);
opt_kume=opt_kumeler(bb);
else if cm<2
    mrkz=merkez;
end
end

if size(opt_kumeler,1)==0;
    mrkz=merkez;
else
mrkz=merkezdepo{opt_kume};
opt_kume;
opt_kumeler;
end
%-----
%Alt Fonksiyon
function [toplama_ortalama,toplam_ortalama]=tekfaz_kurtul(x,mrkz,cm,indexler)
%%%%%tek faz yoketme%%%%%%%%
group=0;
ortalama_notekfaz=[];
toplama_group={};
toplama_ortalama={};
for t=1:size(mrkz,1)
    if cm==1
        ortalama=mean(x)
    else
        ortalama=mean(x(indexler{t},:));
    end
    toplama_ortalama{1,t}=ortalama;
    xp=toplam_ortalama{1,t};

```

```

orn=find(xp==xp);
threshold=max( ortalama)*0.1;
zn = zc(ortalama,threshold);
if zn>1
    ortalama_notekfaz=[ortalama_notekfaz ; ortalama];
end
end
for w=1:size(ortalama_notekfaz,1)
    thresholdn=max( ortalama_notekfaz(w,:))*0.1;
    znw = zc(ortalama_notekfaz(w,:),thresholdn);
    if znw==1
        znw
        pause
    end
    toplam_ortalama{1,w}=ortalama_notekfaz(w,:);
end
%-----
%Alt Fonksiyon
function [w,merkez,cm] = selfalt(x,delta)
[n1 n2]=size(x);
for s=1:n1
    p{s}=x(s,:);
end
kume_degeri=[];
nt=1; l=1; j=1; ns(1)=1;
w{1}=p{1};
for a=1:100
    while l~=(n1+1)
        for s=1:j
            d1(s)=norm(p{1}-w{s});
        end
        d=min(d1);
        [j1,j2]=find(d1==min(d1)); % min uzaklığa bağlı katın konumu saptanıyor
        if d<delta
            ksi(l,j2)=1;
            alfa=0.6/(ns(j2));
            w{j2}=w{j2}+alfa*(p{1}-w{j2});
            ns(j2)=ns(j2)+1;
            l=l+1;
            kume_degeri=[kume_degeri j];
        else
            j=j+1;
            w{j}=p{1};
            ns(j)=1;
        end
    end
    end
    end
    cm=j
    merkez=[];
    for aa=1:j

```

```

merkez=[merkez w{aa}'];
end
merkez=merkez';
%Öznitelik Çıkarma için Matlab Kodu
clc;clear all
dbg = false;
% self_fcm_dog_test_train
dbnm_mat = pathos('F:\kod_subat_2015\03-
clustering\db\self_fcm_dog_test_train\als'); %ALS%healthy%myo dbnm_mats =
pathos('F:\kod_subat_2015\04-fextract\db\self_fcm_dog_test_train\');
dbnm_matss = dbnm_mats;
%%%%%%%%%%%%%%
nm_top='als'
DIR = dir(strcat(dbnm_mat, '*.mat'));
sz = length(DIR);
fext_toplam_alsmean=[];
for di=1:sz
    fext_toplam_als=[];fext_alsmean=[];
    if dbg, fprintf('%d. veri isleniyor...\n', di); end
    dnm = DIR(di).name
    dfnm = strcat(dbnm_mat, dnm);
    load(dfnm);
    zn={};
    x=[];
    for t=1:size(toplam_ortalama,2)
        fext_bir=[];
        x=(toplam_ortalama{1,t});
        x=[0 x 0];% sure hesabı için başına ve sonuna sıfır eklendi
        orn=find(x==x);
        threshold=max(x)*0.1;
% 2.1. Zaman Uzayında Kullanılan Öznitelik Vektörleri
% 2.1.1 Tümüleşik EMG (Integrated EMG -IEMG)
        IEMG =sum(abs(x));
% 2.1.2 Ortalama Mutlak Değer (Mean Absolute Value -MAV)
        MAV=mean(abs(x));
% 2.1.3 EMG Varyans (Variance of EMG-VAR)
        VAR=var(x);
% 2.1.4 Etkin Değer (Root Mean Square -RMS)
        RMS=sqrt (mean(x.^2));
% 2.1.5 Standart Sapma
        STD=std(x);
% 2.1.6 Sıfır Geçiş Sayısı
        SGS= getzcfeat(x',threshold);
% 2.1.7 Willison Genliği
        WAMP=wilson_amp(x,threshold);
% 2.1.8 Basit Karesel İntegral
        SSI= sum(x.^2);
%2.2. Frekans Uzayında Kullanılan Öznitelik Vektörleri
        sf=10000;%sample_frequency
% 2.2.2 Ortanca Frekans(median frekansı)

```



```

r=1.5;
%1EMG 2MAV 3VAR 4RMS 5STD 6SGS 7WAMP 8MF 9MDF 10TFRE 11MNP
12SM1 13SM2 14SM3
ad='EMG-HİBRİT';
etiket='EMG-HİBRİTİ';
indis1=4;
indis2=15;
indis3=7;
adet=1;
fprintf('SM2')
for di=1:sz
    dnm = DIR(di).name;
    dfnm = strcat(dbnm_mat, dnm);
    load(dfnm)
    if di==1
        fext_toplam_alsmeantop.X=fext_toplam_alsmean.X';
        fext_toplam_alsmean.X=[fext_toplam_alsmeantop.X(indis1:indis1,:) ;
        fext_toplam_alsmeantop.X(indis1+22:indis1+22,:)];
        fext_toplam_alsmean.y= 1*ones(size(fext_toplam_alsmean.X,2),1)';
    elseif di==2
        fext_toplam_healthymeantop.X=fext_toplam_healthymean.X';
        fext_toplam_healthymean.X=[fext_toplam_healthymeantop.X(indis1:indis1,:)
        ;fext_toplam_healthymeantop.X(indis1+22:indis1+22,:)];
        fext_toplam_healthymean.y= 2*ones(size(fext_toplam_healthymean.X,2),1)';
    else
        end
    end
    top.X=[fext_toplam_healthymean.X fext_toplam_alsmean.X ];
    top.y=[fext_toplam_healthymean.y fext_toplam_alsmean.y ];
    topo=top;
    % Normalize
    topo.X=premnmx(topo.X)';
    topo.y=topo.y';
    %cross_validation
    dogruluk=[];
    destek_vector=[];
    cvFolds = crossvalind('Kfold', topo.y, 10);
    cp = classperf(topo.y);
    fs=10;
    for i = 1:10
        testIdx = (cvFolds == i);
        trainIdx = ~testIdx;
        Model = svmtrain(topo.X(trainIdx,:), topo.y(trainIdx), ...
            'Autoscale',true, 'Showplot',ciz, 'Method','SMO', ...
            'BoxConstraint',C, 'Kernel_Function','rbf', 'RBF_Sigma',r);
        pred = svmclassify(Model, topo.X(testIdx,:), 'Showplot',ciz);
        cp = classperf(cp, pred, testIdx);
        size(topo.X(trainIdx,:));
        size(topo.X(testIdx,:));
        dogruluk=[dogruluk 100*cp.CorrectRate];
    end
end

```


```

destek_vector=[destek_vector size(Model.SupportVectors,1)];
end
size(top.X)
dogruluk_destek_vector=[dogruluk;destek_vector];
ort_basarim=[median(dogruluk) max(dogruluk)]
etikets=size(dogruluk,2);
dogruluktum.X=dogruluk;
for i=1:size(dogruluktum.X,2)
dogruluktum.y{1,i}= strcat(etiket*1);
end
save(strcat(dbnm_mats, ad,'.mat'),'dogruluktum');
boxplot(dogruluktum.X,dogruluktum.y)
%-----
%Alt Fonksiyon
function po = pathos(p)
po = p;
if pathsep == '\'
    ps = '\\';
    po = strep(p, '/', ps);
end


```

EK B: ALS, miyopati ve sağlıklı kişilere ait EMG verileri


EK B1: ALS hastalarına ait EMG verileri




(a)



Şekil B.1. ALS Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri





(a)




(b)


Şekil B.2. ALS Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri






Şekil B.3. ALS Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri






Şekil B.4. ALS Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri


EK B2: Sağlıklı kişilere ait EMG verileri




(a)




Şekil B.5. Sağlıklı Kişiye Ait EMG Verisinin (a) 8 Sn' lik (b) 1sn' lik Görüntüleri







Şekil B.6. Sağlıklı Kişiyeye Ait EMG Verisinin (a) 8 Sn' lik (b) 1sn' lik Görüntüleri




(a)



Şekil B.7. Sağlıklı Kişiyeye Ait EMG Verisinin (a) 8 Sn' lik (b) 1sn' lik Görüntüleri





(a)



Şekil B.8. Sağlıklı Kişiyeye Ait EMG Verisinin (a) 8 Sn' lik (b) 1sn' lik Görüntüleri


EK B3: Miyopati hastalarına ait EMG verileri






(b)

Şekil B.9. Miyopati Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri




(a)




(b)

Şekil B.10. Miyopati Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri




(a)




(b)

Şekil B.11. Miyopati Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri




(a)




(b)

Şekil B.12. Miyopati Hastasına Ait EMG Verisinin (a) 8 sn' lik (b) 1sn' lik Görüntüleri


EK C: MUAP' ların melez algoritma ile kümelendirilmesi




Şekil C. 1. ALS Hastasına Ait MUAP' ların Melez Algoritma İle Kümelendirilmesi



Şekil C. 2. ALS Hastasına Ait MUAP' ların Melez Algoritma İle Kümelenilmesi




Şekil C. 3. ALS Hastasına Ait MUAP' ların Melez Algoritma İle Kümelenirilmesi




Şekil C. 4. Miyopati Hastasına Ait MUAP' ların Melez Algoritma İle Kümelenendirilmesi

EK D: Tek kullanımlık konsantrik iğne ve yüzey elektrotlar



Şekil D. 1. Konsantrik İğne Elektrot



Şekil D. 2. Yüzey Elektrot

ÖZGEÇMİŞ

Adı Soyadı:	Hanife KÜÇÜK
Doğum Yeri ve Tarihi:	Samsun 04.04.1982
E-Posta:	hanifesms@gmail.com
Lisans:	Ondokuz Mayıs Üniversitesi – 2004
Yüksek Lisans:	Ondokuz Mayıs Üniversitesi – 2007
Mesleki Deneyim ve Ödüller:	Araş. Gör., Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü – (2005 - 2012) Y. Elektrik-Elektronik Müh., Diyarbakır Kamu Hastaneleri Birliği (2012-Devam)

TEZDEN TÜRETİLEN YAYINLAR/SUNUMLAR

- **Küçük, H.**, Tepe, C., Eminoğlu, İ., 2012. Amyotrofik Lateral Skleroz (ALS) Hastalığının Destek Vektör Makinesi ile Teşhisi, *Elektrik-Elektronik Ve Bilgisayar Mühendisliği Konferansı, ELECO2012, IEEE Conferences*, 406-410, Bursa, Türkiye.
- **Küçük, H.**, Tepe, C., Eminoğlu, İ., 2013. K-En Yakın Komşu Algoritması ve Destek Vektör Makinesi Yöntemleri İle EMG İşaretlerinin Sınıflandırılması, *IEEE 21. Sinyal İşleme ve İletişim Uygulamaları, SİU2013*, 1-4, Girne, Kıbrıs.
- **Küçük, H.**, Eminoğlu, İ., 2015. Destek Vektör Makinesi Kullanarak ALS Hastalığının Sınıflandırılması, *IEEE 23. Sinyal İşleme ve İletişim Uygulamaları, SİU2015*, 1664 – 1667, Malatya, Türkiye.