



Classification of neuromuscular diseases with artificial intelligence methods

Hanife Küçük^{1*}, İlyas Eminoğlu¹, Kemal Balcı²

¹Electrical - Electronics Engineering, Ondokuz Mayıs University, Samsun, 55105, Turkey

²Department of Internal Medicine, Ondokuz Mayıs University, Samsun, 55105, Turkey

Highlights:

- MUAP (Motor Unit Action Potential) clustering with hybrid structure
- Use of multiple attribute vectors
- Classification of neuromuscular diseases by artificial intelligence methods

Keywords:

- Electromyogram,
- Amyotrofik Lateral Sklerozis,
- Support Vector Machine,
- K-NN,
- Discriminant Analysis

Article Info:

Research Article
Received: 05.01.2018
Accepted: 07.11.2018

DOI:

10.17341/gazimmfd.571506

Acknowledgement:

This work was supported by Ondokuz Mayıs University PYO.MUH.1906.10.001-BAL-LAB-project.

Correspondence:

Author: Hanife Küçük
e-mail:
hanifesms@gmail.com
phone: +90 553 755 5553

Graphical/Tabular Abstract

In this study, a classification structure consisting of five processing stages was organized for the diagnosis of ALS and Myopathic diseases, the most common types of neuromuscular diseases (Figure A).




Figure A. Structure used to classify EMG data

Purpose: To design a system that classifies EMG signals with or without neuromuscular disorder and to establish the infrastructure and preliminary preparation of a real-time software that can be integrated into the prototype EMG device which is designed in BAL-LAB (Ondokuz Mayıs University, Faculty of Engineering, Department of Electrical and Electronics Engineering, Biomedical Research Graduate Laboratory).

Theory and Methods:

EMG (Electromyogram) signals have been passed through pre-processing, division, clustering, and feature extraction steps before being classified. Hybrid clustering method is used in clustering phase. Afterwards, feature vectors in time and frequency domains and their different combinations of multiple feature vectors (a total of 25 feature vectors) are used. In the next step, data are classified by Support Vector Machine (SVM), K-Nearest Neighbor (K-NN) algorithm and Discriminant Analysis (DA) algorithms. Verification is used as a measure of cross-validation method. Cross-validation of the k-value of 10 is selected.

Results:

Experimental results show that the proposed feature vectors are more successful than the single feature vectors of multiple feature vectors. When used in multiple feature vectors; SVM classifier, has classified the EMG signals with higher accuracy in according to the K-NN and DA classifiers.

Conclusion:

It is understood with this study; the classification performance depends on a high degree of feature vectors of interclass separability.



Nöromusküler hastalıkların yapay zeka yöntemleri ile sınıflandırılması

Hanife Küçük*¹, İlyas Eminoğlu¹, Kemal Balcı²

¹Ondokuz Mayıs Üniversitesi, Elektrik - Elektronik Mühendisliği, Samsun, 55105, Türkiye

²Ondokuz Mayıs Üniversitesi, İç Hastalıkları Anabilim Dalı, Samsun, 55105, Türkiye

Ö N E Ç I K A N L A R

- Melez Yapı İle MUAP (Motor Unit Aksiyon Potansiyeli) kümeleme
- Çoklu öznelik vektörlerinin kullanılması
- Yapay zeka yöntemleri ile nöromusküler hastalıkların sınıflandırılması

Makale Bilgileri

Araştırma Makalesi

Geliş: 05.01.2018

Kabul: 07.11.2018

DOI:

10.17341/gazimmfd.571506

Anahtar Kelimeler:

Elektromiyogram,
Amyotrofik Lateral
Sklerozis,
Destek Vektör Makinesi,
K-NN,
Diskriminant Analiz

ÖZET

Bu çalışmada Nöromusküler hastalıkların en yaygın çeşidi olan ALS ve Myopati hastalıklarının teşhisi için beş işlem aşamasından oluşan bir sınıflandırma yapısı düzenlenmiştir. EMG (Elektromiyogram) işaretleri, sınıflandırılmadan önce ön işleme, bölütleme, kümeleme ve öznelik çıkarma aşamalarından geçirilmiştir. Kümeleme aşamasında melez kümeleme yöntemi kullanılmıştır. Sonrasında zaman, frekans uzayındaki öznelik vektörleri ve bunların farklı birleşimleri ile elde edilen çoklu öznelik vektörleri olmak üzere toplam 25 tane öznelik vektörü denenmiştir. Bir sonraki aşamada ise Destek Vektör Makinesi (DVM), K-En Yakın Komşu (K-EYK) algoritması ve Diskriminant Analiz (DA) algoritmaları ile veriler sınıflandırılmıştır. Doğrulama ölçütü olarak çapraz geçerlilik yöntemi kullanılmıştır. Çapraz geçerlilikte k değeri 10 seçilmiştir. Deneysel sonuçlar önerilen öznelik vektörleri arasında çoklu öznelik vektörlerinin tekli öznelik vektörlerine göre daha başarılı olduğunu göstermiştir. Çoklu öznelik vektörlerinin kullanılması durumunda DVM sınıflandırıcı, K-EYK ve DA sınıflandırıcılarına göre EMG işaretlerini daha yüksek doğrulukla sınıflandırmıştır. Toplam doğruluk ALS için %97,39 iken myopati olanlar için %86,74'tür. Bu çalışma ile sınıflandırma başarımının öznelik vektörünün sınıflar arası ayrılabilirliğinin yüksek derecede olmasına bağlı olduğu anlaşılmıştır.

Classification of neuromuscular diseases with artificial intelligence methods

H I G H L I G H T S

- MUAP (Motor Unit Action Potential) clustering with hybrid structure
- Use of multiple attribute vectors
- Classification of neuromuscular diseases by artificial intelligence methods

Article Info

Research Article

Received: 05.01.2018

Accepted: 07.11.2018

DOI:

10.17341/gazimmfd.571506

Keywords:

Electromyogram,
Amyotrofik Lateral
Sklerozis,
Support Vector Machine,
K-NN,
Discriminant Analysis

ABSTRACT

In this study, a classification structure consisting of five processing stages was organized for the diagnosis of ALS and Myopathic diseases, the most common types of neuromuscular diseases. EMG (Electromyogram) signals have been passed through pre-processing, division, clustering, and feature extraction steps before being classified. Hybrid clustering method is used in clustering phase. Afterwards, feature vectors in time and frequency domains and their different combinations of multiple feature vectors (a total of 25 feature vectors) are used. In the next step, data are classified by Support Vector Machine (DVM), K-Nearest Neighbor (K-EYK) algorithm and Discriminant Analysis (DA) algorithms. Verification is used as a measure of cross-validation method. Cross-validation of the k-value of 10 is selected. Experimental results show that the proposed feature vectors are more successful than the single feature vectors of multiple feature vectors. When using multiple feature vectors; SVM classifier, has classified the EMG signals with higher accuracy in according to the K-NN and DA classifiers. Total accuracy is 97.39% for ALS and 86.74% for the myogenic. It is understood with this study; the classification performance depends on a high degree of feature vectors of interclass separability.

*Sorumlu Yazar/Corresponding Author: hanifesms@gmail.com, ilyaseminoglu@hotmail.com, kemal.balci@omu.edu.tr /

Tel: +90 553 755 5553

1. GİRİŞ (INTRODUCTION)

Son yirmi yıl içinde elektromiyografi (EMG), araştırmacılar ve klinisyenler tarafından yaygın nöromusküler hastalıkların doğru tanısı için değerli bir araç olarak kullanılmaktadır [1]. Bazı hastalıkların teşhisinde, EMG ölçümleri gerekmektedir. EMG işaretlerinin ayrıştırılması ve MUAP'lerden benzer şekilli olanlarının gruplandırılarak sınıflandırması nöromusküler patoloji değerlendirmesi açısından değerli bilgiler sunmaktadır [2]. Nöromusküler bozukluk motor nöron, kas kavşağı ve kas dokusu dahil sinir veya kasın herhangi bir bölümünü etkileyen hastalıkları ifade eden genel bir terimdir. Myopati ve nöropati iki önemli nöromusküler hastalık türüdür. Bu iki hastalığın belirtileri birbirine çok benzer olabilmektedir. Örneğin ikisinde de hasta hastalıklı bölgedeki kaslarını hareket ettirememeye şikayetinde bulunmaktadır. Ancak hastalıklar birbirinden farklıdır. Nöropatide bu hareket bozukluğu kasa giden sinirlerin bozuk olmasından kaynaklanırken, Myopatide sinirler sağlamdır fakat kasta arıza olmasından dolayı hareket bozukluğu oluşmaktadır [3]. Nörojenik hastalıklarda görülen en tipik bulgu MUAP'ların 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 bilinmektedir. Hastalığın adının anlamı omurilikte kaslara giden yan (lateral) taraftaki sinir hücrelerinin etkilenmesiyle kasların beslenememesi ve katlaşmasıdır. 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 sayılırlıkla polifazik potansiyel artışı görülür. Polifazik MUAP'ların süresi bifazik, trifazik olanlara göre kuşkusuz daha uzun, normal kasta görülen polifazik potansiyellere göre kısadır. Tablo 1'de Nörojenik/ Miyojenik EMG ayrımı verilmiştir.

Elektromiyografinin amacı klinik teşhisi desteklemektir [4]. EMG işaretlerinin klinik teşhis ve biyomedikal uygulama alanları; kas yorgunluğunun belirlenmesi, kas ve sinir sistemi hastalıklarının tanı ve tedavisi, kasların performanslarının ölçülmesi ve protez ya da robot kolu denetimidir. Karmaşık bir yapıya sahip olan EMG işaretleri

kolay anlaşılabilir bilgiler içermez. Bu nedenle bu işaretlerin bilgisayarda işlenmesi anlamlandırılması gerekmektedir. EMG işaretinde meydana gelen anormal değişimlerin tanımlanması ve açıklanması, kas aksiyon potansiyellerinin karakteristik özelliklerinin, şeklinin, genliğinin, süresinin ve frekansının dikkatli incelenmesine bağlıdır. 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 [4]. Klinik uygulamalarda nöromusküler hastalıkların teşhisinde kullanılan tekniğin uygulanabilirliği, doğru sonuç alınması ve kullanım kolaylığı açısından önemlidir [5].

Literatürde biyomedikal uygulamalarda yorumlama ve sınıflandırma problemlerinin çözümleri birçok sinyal işleme, yapay zeka ve yapay sinir ağları metotları ile elde edilmeye çalışılmaktadır. 1970'li yıllarda yapay zeka tekniklerinin biyomedikal alanındaki kullanımı artmış ve o günden sonra gelişimi hızlanmıştır [8]. Nöromusküler hastalıkların sınıflandırılmasında literatürde kullanılan en yaygın yöntemler; bayes teknikleri [7, 8] sinir ağları [9, 11], çok katmanlı perseptronlar [2], bulanık yaklaşımlar [10], destek vektör makineleri [11], ve nöro-bulanık sistemlerdir [12].

Bu çalışmada, nöromusküler bozuklukların tanısı için EMG sinyalleri sınıflandırma alanında literatürde bulunan bir kısım çalışmaların yayın yılı, kullanılan yöntemler, denek sayısı, MUAP sayısı ve başarımları Tablo 2'de verilerek bir özet sunulmuştur.

Nöromusküler hastalık tanısında EMG sinyallerini sınıflandırmada son derece sağlam sınıflandırma modellerinden biride DVM [11, 21] dir. Katsis vd. çalışmalarında bulanık k-ortalama yöntemini ile MUAP'ların kümelenmesini sağlamışlardır. Bu çalışmada DVM algoritması ile sağlıklı, myopati ve nöropati sınıflarını sırasıyla %93, 95 ve 92 doğrulukta sınıflandırmıştır [22]. Koçer ve Güler; Sağlıklı, Myopatik ve Nöropatik EMG sinyallerini sınıflandırmak için MLP ve DVM algoritmalarını denemişlerdir. DVM sınıflandırıcı için sonuçlar MLP ile karşılaştırıldığında %92,3 doğrulukla DVM sınıflandırıcı, %91,6 hassasiyetle MLP sınıflandırıcıyı geride bırakmıştır. Ancak DVM'nin eğitim ve test sırasındaki çekirdek fonksiyonunun seçim karmaşıklığı, hız ve sınıflandırıcılarda boyut sınırlaması gibi bazı sakıncaları mevcuttur [12]. Subaşı yeni bir parçacık sürüsü optimizasyonu ve DVM (PSO-DVM) modelini, sağlıklı

Tablo 1. Nörojenik / Miyojenik EMG Ayrımı (Ertekin, 2006) (Neurogenic / Myogenic EMG Separation (Ertekin, 2006))

	Nörojenik	Miyojenik
1. Pozitif keskin dalgalar	Oldukça sık	Oldukça seyrek
2. Fasikülasyon potansiyelleri	Sık (ALS gibi)	Çok seyrek
3. MUAP süresi	Artar (%20 üzeri)	Azalırlar (%20 altı)
4. MUAP genliği	Artar veya normal	Azalırlar
5. Polifazik MUAP tipi	Geniş süreli gruplaşmış dikenler	Kısa süreli küçük genlikli dikenler

Tablo 2. Nöromusküler Bozuklukların Tanısı İçin EMG Sinyallerinin Sınıflandırılması Alanında Yapılan Bazı Çalışmalar [13] (Some Studies on the Classification of EMG Signals for the Diagnosis of Neuromuscular Disorders [13])

Yıl	Kullanılan Yöntemler	MUAP Sayısı	Doğruluk (%)
1999	[2] SOFM, LVQ ve Öklid uzaklığına dayalı istatistiksel yöntemler	1213	90
2006	[14] Dalgacık tabanlı sinir ağı (WNN)	1200	90,7
2012	[15] SOFM ve LVQ	11	97,6
2006	[16] Uyarlamalı Bulanık K-EYK sınıflandırıcı (AFNNC)	11	96,6
2005	[12] DVM	59	92,3
2010	[18] İkili DVM	12	100
2012	[19] Dalgacık Tekniği ile Öznitelik Çıkarımı ve DVM	300	99,4
2012	[20] Ayırık dalgacık dönüşümü ile öznitelik çıkarma ve Bulanık Destek Vektör Makinesi (FDVM)	27	97,67

nöropatik veya Myopatik EMG sinyallerini sınıflandırmak için önermiştir. Onlar sınıflandırma doğruluğunu geliştirmek için PSO ve DVM den oluşan bir melez yapı kullanmıştır. Başarım sonuçları RTF çekirdeği üzerine dayalı, DVM sınıflandırıcı için %96,75 doğruluk elde ederken, RBN(Radyal Basis Network) sınıflandırıcı için %94,08 ve K-EYK sınıflandırıcı için %95,17 dir. Bu çalışmada RTF çekirdeği üzerine dayalı DVM sonuçları RBN ve K-EYK sınıflandırıcılara göre daha iyi olduğu görülmüştür. Bu deneyler RBN ve K-EYK, karşılaştırıldığında RTF çekirdeği üzerine dayalı bir DVM'nin üstün olduğunu doğrulamıştır [23]. Subaşı diğer bir çalışmada; 7 sağlıklı, 7 Myopatik ve 13 nöropatik kişi olmak üzere, 27 denekten aldıkları EMG sinyallerini sınıflandırmada altı adet sınıflandırma algoritması karşılaştırmıştır. Sınıflandırma algoritmasının giriş boyutunu azaltmak için öznitelik vektörü olarak ayırık dalga dönüşümlerinin (DWT) katsayılarının kümesi üzerinden hesaplanan dört istatistik özellikler kullanılmıştır. Sınıflandırma algoritması olarak da bir bulanık destek vektör makinesi (FDVM) sınıflandırıcı önermiştir. Sonuçlar lineer diskriminant analizi (LDA), MLP, RBN, C4,5 karar ağacı ve DVM sınıflandırıcıları ile karşılaştırılmıştır. Bu çalışmada DWT özelliklerini kullanarak FDVM ile yapılan sınıflandırma diğer yöntemlere göre %3 daha iyi başarımla sağlanmıştır [20, 18]'de, Kaur vd. nöromusküler bozuklukları teşhisinde EMG sinyallerini sınıflandırmak için bir ikili DVM sınıflandırıcı geliştirmiştir. İlk olarak, bir ikili DVM sınıflandırıcı sağlıklı ve hastalığı olan bireylerde sınıflandırmak için kullanılmıştır. İşaret hastalıklı olarak sınıflandırıldı ise, o zaman başka bir ikili sınıflandırıcı myopati ve nöropati sinyallerini sınıflandırmak için kullanılmıştır. Analiz 3 sağlıklı, 5 myopatik ve 4 motor nöron hastalıklı bireylerden alınan 12 EMG sinyalleri kullanılarak tamamlanmıştır. Bu modelin başarımla değeri %100 olarak sunulmuştur. %100 doğruluk, bu çalışmada bildirilmiş olmasına rağmen çalışma küçük veri seti için denenmiştir. Rasheed vd.'leri nöromusküler tanı için EMG sinyallerinin sınıflandırılmasında bir uyarlamalı bulanık K-EYK sınıflandırıcı (AFNCC-Adaptive Fuzzy K-NN Classifier) önermiştir. AFNCC sınıflandırıcı için sonuçlar; uyarlamalı kesinlik sınıflandırıcısı (ACC-Adaptive Fuzzy K-NN Classifier) ile karşılaştırılmıştır. AFNCC sınıflandırıcı her bir girişe ait üyelik fonksiyonunu tahmin etmek için bulanık K-EYK algoritmasını kullanmıştır. AFNCC için

ortalama performans %96,6 iken; ACC için %86,9 dir. Deneysel sonuçlar K-EYK modelinin sınıflandırma doğruluğunu artırmada başarılı bir performans sergilediğini göstermiştir [16]. Lahmire vd. 160 EMG sinyallerinden elde edilen ARMA katsayılarını Doğrusal Diskriminant Algoritmasına girdi olarak verip sağlıklı ve nöropatik EMG sinyallerinin sınıflandırılması sağlanmıştır. Sonuç olarak sağlıklı ve nöropatik EMG sinyalleri %100 hassasiyet, %99,66 özgüllük ve %99,74 doğrulukla sınıflandırılmıştır [17]. Christodoulou ve Pattichis nöromusküler hastalıkların teşhisinde EMG sinyallerinin sınıflandırılması için iki farklı örüntü tanıma tekniği denemişlerdir. Bu yöntemlerden ilki SOFM ve LVQ algoritmalarının değiştirilmiş bir versiyonuyla ile eğitilmiş bir denetimsiz YSA, ikincisi öklid mesafe tabanlı istatistiksel yaklaşım %95,3 doğruluk elde ederken; YSA %97,6 doğruluk ile verileri sınıflandırmıştır. Bu çalışmada LVQ algoritmasının ek kullanımı sınıflandırma performansını arttırmıştır [2]. Bhardwaj vd. nöromusküler hastalıkların teşhisi için MUAP'ları LVQ ile SOFM algoritmasına dayalı bir YSA tekniği ile sınıflandırmıştır. Bu yöntem, üç aşamada gerçekleştirilmiştir. İlk aşamasında SOFM kullanılırken, ikinci aşamasında LVQ YSA'nin performansını artırmak için uygulanmıştır. Gerçek sınıflandırma üçüncü aşamada yer almıştır. Deneyler (2 sağlıklı, 4 myopati, 5 nöropati) 11 olgudan oluşan bir veri kümesi üzerinde gerçekleştirilmiştir. Bu teknik için başarı oranı %97,6 dir [15]. Subaşı vd., EMG işaretinin sınıflandırılması için ileri beslemeli hata geri yayımlı yapay sinir ağları (FEBANN) ve dalgacık sinir ağları (WNN) temelli sınıflandırıcılar karşılaştırılmıştır. Nörolojik 13 denek, Myopati 7 denek ve sağlıklı 7 denekten elde edilen 1200 MUAP analiz edilmiş, WNN tekniğinden en başarılı %90,7, FEBANN tekniğinden en başarılı %88 sonuç elde edilmiştir ve WNN temelli sınıflandırıcıların FEBANN temelli sınıflandırıcılara karşı daha iyi sınıflandırma yaptığı gösterilmiştir [14]. Tomczykiewicz vd.'leri nöromusküler bozuklukların sınıflandırılması için özellik çıkarımı dalgacık temelli bir DVM algoritması denenmişlerdir. Bu çalışmada 300 denekğin deltoid kasından toplanan 800 EMG verileri kullanılmıştır. Sonuç olarak %99,4 doğruluk elde edilmiştir. Özgüllük %100, duyarlılık myojenik durumlar için %98,4 ve nörojenik olanlar için %98,7 düzeyindedir. Sonuçlar önerilen yöntemin patolojik ve patolojik olmayan olgular arasında yüksek ayırım

sağladığını göstermiştir [19]. Fattah vd. ALS, myopati ve normal verileri ayırt etmek için zaman ve frekans düzlemindeki işlemlere dayalı (otokoralyon, sıfır geçiş sayısı ve Fourier dönüşümü gibi) bir sınıflandırma performansı geliştirmişlerdir. Sınıflandırıcı olarak K-EYK algoritması kullanılmıştır. Bu çalışmada önerilen öznelik vektörleri ALS ve Myopati hastalıklarını ayırt edici özellikler sergilemişlerdir. Önerilen spektral tepe ve otokorelasyon tabanlı özelliklerinin performansının iyi olması, basit bir K-EYK sınıflandırıcı kullanılmasıyla yüksek sınıflandırma doğruluğu sağlanmıştır. Ancak bu çalışma ALS-Normal ve ALS- Myopati ikili sınıfları otokoralyon öznelik vektörü kullanılması durumunda %100 doğrulukla sınıflandırırken; Myopati-Sağlıklı sınıfları %86 doğrulukla sınıflandırmıştır. Myopati-Sağlıklı sınıf için önerilen öznelik vektörünün ayırma derecesi önceki iki sınıftan farklı olarak, çok tatmin edici değildir [6]. Aydın ve Arslan; Amyotrofik lateral skleroz (ALS), Huntington hastalığı (HD) ve Parkinson hastalığı (PD) ve 16 kontrol bireyi (CO) sınıflandırılmasında ilk olarak dalgacık dönüşümü ile öznelik vektörü çıkarılmış; sonrasında OneRules sınıflandırıcı kullanılarak bu öznelikler içerisinde en iyi öznelikler seçilmiştir. Sınıflandırma aşamasında ise Radyal Tabanlı Fonksiyon Ağı (RBFNetwork), Adaptif Yükseltme (Adaboost) ve Eklenebilir Lojistik Regresyon (LogitBoost) algoritmaları kullanılarak ALS-CO için %93,1 doğruluk, HD-CO için %97,22 doğruluk, PD-CO için %83,87 doğruluk ve NDD-CO için %92,18 doğruluk elde edilmiştir [43]. Artuğ vd.'ları çalışmalarında nöromusküler hastalıkların ayırıcı tanısını destekleyen yeni özellikler bulmayı amaçlamıştır. Bu özellikler maksimum genlik, diken süresi (en sağ ve en soldaki minimum tepeler arasındaki süredir), pikler, maksimum genlik x diken süresi, tepelerin sayısı x diken süresi, aktivite koridorunun [44] dışındaki gücün aktivite koridorundaki güce oranı ve aktivite koridorunun dışındaki piklerin sayısıdır. Nörojenik hastalıkları teşhis etmek için maksimum genlik ve maksimum genlik süreleri artış süresinin önemli olduğu bulunmuştur. Ayırıcı tanıda normal ve hastalıklı kişilerden oluşan veri seti; çok katmanlı perceptron (MLP), radyal temel fonksiyon ağı (RBF), destek vektör makineleri (SVM) ve k en yakın komşu algoritması kullanılarak sınıflandırılmıştır. En iyi doğruluk MLP ağı ile %85 olarak elde edilmiştir [45].

Bu çalışmada Amiyotrofik Lateral Skleroz (ALS) ve myopati hastalığının teşhisinde kullanılan öznelik vektörleri zaman uzayı ve frekans uzayında hesaplanmıştır. Daha sonra öznelik vektörleri sırasıyla Destek Vektör Makinesi, K-En Yakın Komşu algoritması ve Diskriminant Analiz algoritmalarına giriş olarak verilerek verilerin sınıflandırılması sağlanmıştır. Bu yayının ön çalışması 27-29

Ekim 2016 tarihinde Antalya'da gerçekleştirilen TIPTEKNO 2016 kongresinde sunulmuştur [41, 42].

2. MATERYAL VE YÖNTEM (MATERIALS AND METHODS)

Bu bölümde EMG verilerinden özellik çıkarılması, anlamlandırılması ve sınıflandırılması için kullanılan algoritmalar açıklanacaktır. Önerilen ana yapının öbek çizgesi Şekil 1'de verilmiştir.

2.1. Veri Edinme Ve Ön İşlem (Data Acquisition and Preprocessing)

Bu çalışmada kullanılan veriler EMGLAB (<http://www.EMGLab.net>) internet sitesinden alınmıştır. Veriler 8 saniye boyunca brachial biceps, vastus medialis, abductor pollicis brevis, tibialis anterior, vastus lateralis, triceps brachii, deltoideus kaslarından iğne elektrot ile alınmıştır. Bu çalışmada kullanılan EMG işaretleri 10 normal (21-37 yaş aralığı), 7 myopati (19-63 yaş aralığı) ve 8 ALS hastasına (37-67 yaş aralığı) aittir ve her bir veri grubunda 8 sn süren 230'ar tane veri bulunmaktadır.


Şekil 2'de ALS, myopati, ve sağlıklı kişilerden alınan EMG kayıtlarının ilk 2 saniyesi gösterilmektedir. EMG işaretlerine analog bant geçiren filtre (2 Hz-10 KHz) uygulanmıştır. İşaretler 23,438 KHz de örneklenmiştir. EMG ölçümü sırasında elektrotların vücutla etkileşimi ve hareketleri nedeniyle EMG işaretinde 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. Bu çalışmada EMG işaretindeki yüksek frekans bileşenli gürültüyü ve düşük frekanslı kaymaları gidermek için frekans aralığı 10-1500 Hz olan "chebyshev" bant geçiren süzgeç kullanıldı (Bu çalışmada kullanılan bant geçiren süzgeç yapısı Matlab yazılımının "Signal Processing Toolbox" aracı yardımıyla tasarlanmıştır). İzoelektrik çizgideki dalgalanmayı gidermek için yüksek geçiren süzgeç kullanılması durumunda elde edilen EMG işareti Şekil 3'de verilmiştir. Şekilde kaymanın net görülebilmesi için izoelektrik çizgideki dalgalanmaya odaklama yapılmıştır.

2.2. MUAP'ların Başlangıç Ve Bitiş Noktaları Bulunarak Bölütlenme (Segmenting MUAPs by Finding Start and End Points)

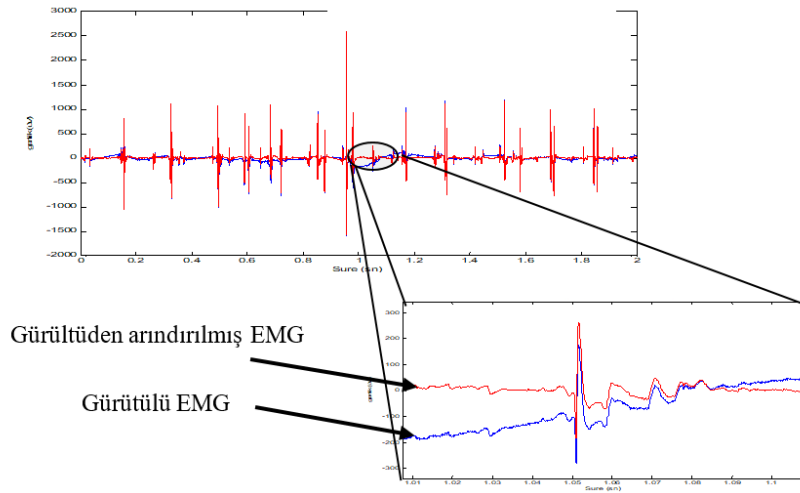
Bu bölümde, EMG işaretindeki MUAP'ların bölütlenmesi [24]'deki çalışmadan esinlenerek gerçekleştirilmiş ve yöntemin hassasiyetini, doğruluğunu arttırmak amacıyla 3. adımdaki kural eklenmiştir.



Şekil 1. EMG verilerinin sınıflandırılmasında kullanılan yapı (Structure used to classify EMG data)



Şekil 2. ALS, sağlıklı ve myopati hastasına ait EMG verisi (ALS, healthy and EMG data of myopathy patient)



Şekil 3. İzoelektrik çizgideki dalgalanmanın giderilmesi (Elimination of isoelectric fluctuation)

Adım 1: EMG işaretinde eşiği aşan tepeler belirlenir: Literatürde yapılan çalışmalarda MUAP genliği için standart bir eşik seviyesi kullanılmamaktadır. Dorfman ve McGill [24]'deki çalışmalarında eşik genliğini 20–50 uV, Stalberg vd., 1995'deki çalışmalarında eşik genliğini, 50 uV olarak seçmiştir [4]. Bu çalışma için eşik değeri 50 uV olarak seçilmiştir.

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 [25].

Adım 3: Başlangıç ve bitiş noktasına aday olacak noktaların belirlenmesi (Şekil 4): eğer Adım 2'de belirlenen pencere içerisinde alt ve üst eşiği aşan tepe yoksa bu noktalardan

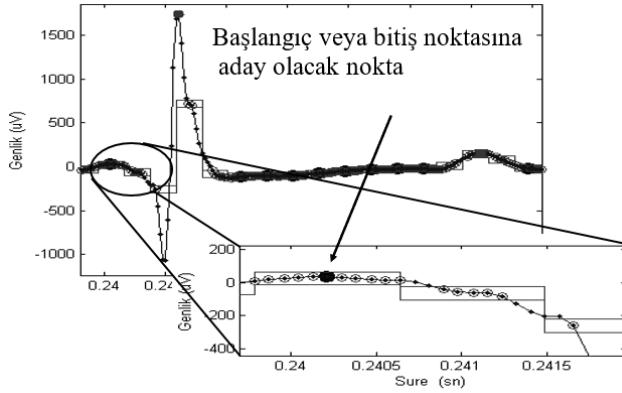
ortancası başlangıç veya bitiş noktası olmaya adaydır. değilse (pencere içerisinde en az bir nokta eşik değerini aşarsa) pencere içerisindeki noktalar dikkate alınmaz.

Adım 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.

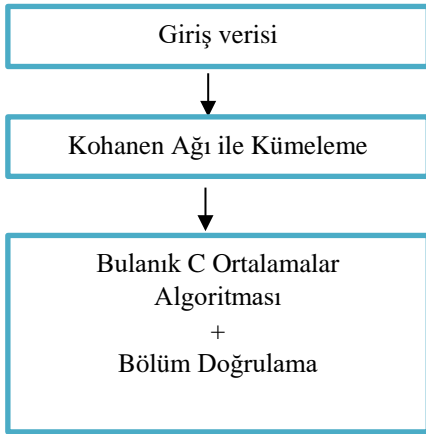
2.3. Melez Yapı İle MUAP Kümeleme (MUAP Clustering with Hybrid Structure)

Bu yöntemde Kohanen ağı ile kümeleme kullanıcının girdiği yarıçapa göre verileri kabaca kümelendirir. Bulduğu küme sayısı en iyi olmamasına rağmen kullanıcıya bir başlangıç değeri sunar. Bu çalışmada [27]'de sunulan melez yapı denenmiştir. Kohanen ağı ile BCO (Bulanık C Ortalamalar) algoritması melez kullanılmıştır. Ancak bu melez yapının sonucunda bulunan küme sayısı optimal değildir. Bu

bölümde küme sayılarını optimize etmek için melez algoritma bölüm doğrulama algoritması ile tümleşik bir yapıya dönüştürülmüştür (Şekil 5).



Şekil 4. Başlangıç ve bitiş noktasına aday olacak noktalar (Points for starting and ending point)



Şekil 5. Melez Yapı (Hybrid Structure)

2.3.1. Kendini düzenleyen haritalar (kohonen ağı) ile kümeleme (Clustering with kohonen network)

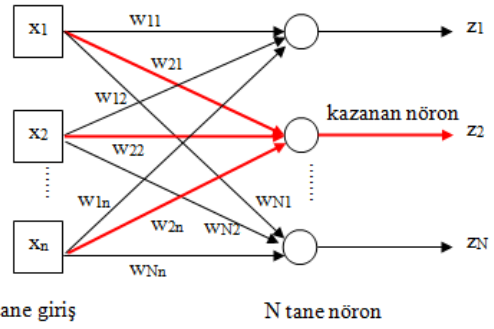
Kohonen ağları, başlangıçta grupları belli olmayan verileri kümelemeyi amaçlamaktadır. Kohonen ağı, bir tür eğitimsiz yarışmacı öğrenme kuralıdır (Kohonen, 1984). Çünkü Kohonen ağlarında kestirim yapacak bir çıktı değişken bulunmamaktadır. Kohonen algoritması, yarışmacı öğrenme algoritması olarak da adlandırılır. Basit işlem elemanlarından oluşan Kohonen yapay sinir ağı, Şekil 6'da gösterildiği gibidir.

Şekil 6'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

İlk veri dizisi (p) başlangıç ağırlıkları (w) olarak seçilir (Eş. 1).



Şekil 6. Kohonen ağ yapısı (Kohonen network structure)

$$w_1 = p_1 \quad (1)$$

Adım 2:

Bu durumda ilk olarak her bir p_1 örneğinin w_1 'e olan uzaklıkları Eş. 2'deki gibi hesaplanır ve en minimum uzaklık seçilir.

$$D = \min \|w_1 - p_1\| \quad (2)$$

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 (Eş. 3):

$$w_j(t) = w_j(t-1) + \alpha(p_1 - w_j(t-1))\zeta(j) \quad (3)$$

Kazanan birimin aktivasyonu artırılır; $N_s(j) = N_s(j) + 1$

$\alpha = \alpha_0 / N_s(j)$: 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; $N_s(j)=1$

Bu adımlar veri dizinin adeti kadar yinelenir.

2.3.2. Bulanık c-ortalamalar (fuzzy c-means) algoritması ile kümeleme (Clustering with fuzzy c-means algorithm)

Bulanık C- Ortalamalar algoritması da amaç fonksiyonu temelli bir metottür. 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 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 (Eş. 4).

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2, \quad 1 \leq m < \infty \quad (4)$$

BCO’da amaç, Eş. 4’deki hedef fonksiyonu minimize etmektir. Burada m; birden büyük gerçek bir sayı, u_{ij} ; j. sınıfa ait x_i elemanın 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), Eş. 5’deki fonksiyonlar ile bulunmaktadır.

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad C_i = \frac{\sum_{j=1}^c u_{ij}^m x_j}{\sum_{j=1}^c u_{ij}^m} \quad (5)$$

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

2.3.2.1. BCO algoritması ile bölüm doğrulama (Segment verification with BCO algorithm)

Bulanık C-Ortalamalar 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).

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

$$H(U, c) = -\frac{1}{n} \sum_{k=1}^n \sum_{i=1}^c U_{ik} \log(U_{ik}) \quad (6)$$

Eş. 6’daki U_{ik} ’nın değeri çok küçük olması durumunda logaritmik fonksiyonun işlem hatası çok büyük olacaktır ve bu durum geçerlilik güvenilirliğini etkiler. Bu eksikliği gidermek için Eş. 7’de değiştirilmiş basit ve daha verimli küme doğrulama kriteri verilmiştir.

$$H(U, c) = -\frac{1}{n} \sum_{k=1}^n \max_i(U_{ik}) \log(\max_i(U_{ik})), \quad i = 1, 2, \dots, c \quad (7)$$

Eş. 7’de verilen ölçüte göre bölüm doğrulama algoritması şu biçimde gerçekleştirilir (Linkens ve Chen, 1997):


Adım 1: Maksimum küme sayısı c_{max} , yineleme 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 (Eş. 8).

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{D_{ij}}{D_{kj}} \right)^{\frac{2}{m-1}}} \quad V_i = \frac{\sum_{j=1}^c U_{ij}^m x_j}{\sum_{j=1}^c U_{ij}^m}, \quad i = 1 \dots c \quad (8)$$

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



Şekil 7. EMG verisinin melez algoritma ile kümelendirilmesi (Clustering of EMG data with hybrid algorithm)

Adım 4: Eş. 7'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 dönülür.

Şekil 7 de bir ALS hastasına ait EMG verisindeki MUAP'lar (Şekil 7-a) melez algoritma ile kümelendirilmiştir. Kohonen ağı+BCO algoritması ile bulunan 7 adet küme sayısı ; melez algoritma ile 4'e düşmüştür (Şekil 7-b,c,d,e).

2.4. EMG Verisinde Öznitelik Çıkarma (Features extraction from the EMG signal)

EMG verisinden gizlenmiş faydalı bilgileri çıkarmak ve verinin içinden istenmeyen bölümleri, girişimleri kaldırmak adına EMG verilerinde özellik çıkarımı önemli bir aşamadır [29]. EMG verisinin sınıflandırılmasıyla ilgili birçok çalışmaya bakıldığında gereksiz özellik vektörlerinin kullanıldığı görülmektedir. EMG verilerinin başarılı sınıflandırması, özellik vektörünün doğru seçilmesine bağlıdır [30]. Veriye uygun özellik seçimi sınıflandırıcının yüksek doğruluğa yaklaşması açısından doğrudan ilgilidir [31, 32]'e göre EMG verilerinde öznitelik çıkarımı üç farklı uzayda gerçekleştirilir: i) zaman uzayı, ii) frekans uzayı, iii) zaman -frekans uzayı.

Bu çalışmada Tablo 3'de verilen zaman uzayı ve frekans uzayındaki toplam 14 tane öznitelik vektörleri her bir EMG verisi için hesaplanmıştır. Yüksek sınıflandırma performansı elde etmek için etkili öznitelik vektörü kullanmak gerekir [31]. Bu amaç doğrultusunda sınıflandırma doğruluğunu arttırmak için öznitelik vektörlerinin çeşitli şekilde

birleştirilmesi ile elde edilen çoklu öznitelik vektörleri kullanılmıştır.

3. SINIFLANDIRMA (CLASSIFICATION)

Bu çalışmada EMG analizi için toplam 25 kişiye (10'u sağlıklı, 8 ALS hastası ve 7 Myopati) ait toplam 690 veriyi sınıflandırmak için Matlab'ın Bioinformatics Toolbox™ [28] yazılımı kullanılmıştır.

3.1. Destek Vektör Makinesi İle Sınıflandırma (Classification with Support Vector Machine)

Destek vektör makineleri (DVM), Vladimir N. Vapnik tarafından ortaya konulan istatistiksel öğrenme teorisine dayalıdır [35]. Genellikle DVM'de ikili sınıflandırmada etiketlenmiş eğitim verisi Eş. 9'daki gibi belirtilir. Burada l ; örnek sayısı, x_i ; örnekler, y_i ; bu örneklere ait etiketleri temsil etmektedir.


$$\{x_i, y_i\}_{i=1}^l \quad x_i \in R, \quad y_i \in \{-1, +1\} \quad (9)$$

İkili sınıflandırma probleminde doğrusal olarak ayrılabilen bir veri setinin olduğu düşünülürse, bu veri setini ayırabilen sonsuz sayıda hiper-düzlem vardır. DVM karar yüzeyini oluştururken iki sınıfa olan uzaklığı maksimum yapmaya çalışır. Bu düzlemler arasında maksimum sınıra sahip sadece bir hiper-düzlem bulunmaktadır. Sınır genişliğini sınırlandıran noktalara ise destek vektörleri adı verilir. Şekil 8'de M maksimum aralık, x_1, x_2 ; sınır genişliğini sınırlandıran destek vektörleridir. Destek vektör algoritması

Tablo 3. Zaman ve Frekans Uzayında Öznitelik Vektörleri (Feature vectors in Time and Frequency Spaces)

Zaman Uzayındaki Öznitelik Vektörleri		Frekans Uzayındaki Öznitelik Vektörleri	
Standart Sapma $STD = \sqrt{VAR}$	Tümleşik EMG $IEMG = \sum_{i=1}^N x_i $	Tepe Frekans $PKF = \max(P_j), j = 1, \dots, M$	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 (SGS) $\{x_i > 0 \text{ ve } x_{i+1} < 0\} \text{ veya } \{x_i < 0 \text{ ve } x_{i+1} > 0\} \text{ ve } x_i - x_{i+1} \geq \text{esik}$	N: EMG işaretinin uzunluğu; M: Güç spektral yoğunluğunun uzunluğu; P _j : j. frekansta EMG güç spektrumu; OCF: Ortanca Frekans		

en büyük sınır genişliğine sahip ayırıcı hiper-düzlem ile sınıflandırma yaparak eğitim hatasını minimize etmeye çalışır.



Şekil 8. İkili sınıflandırmada karar düzlemi
(Decision plane in binary classification)

Sınırı maksimum yapmak; Eş. 10'daki amaç fonksiyonunu, Eş. 11'deki kısıtlar altında minimize etmeye denktir. Eş. 11 ifadesindeki w : ağırlık parametreleri vektörü, b ise: öteleme değeridir.

$$\frac{1}{2} \|w\|^2 \quad (10)$$

$$y_i (w^T x_i + b) \geq 1 \quad (11)$$

Eğer veriler oluşturulan sınırın içinde veya hatalı tarafında ise bu veri noktaları için genelleme yapılır ve kısıtları gevşetmek için yapay/aylak değişkenler tanımlanır [36]. Eş. 10 ve Eş. 11'deki denklemlerine yapay/aylak değişkenler eklenmesi durumunda Eş. 12 ve Eş. 13 elde edilir.

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \zeta_i \quad (12)$$

$$y_i (w^T x_i + b) \geq 1 - \zeta_i \quad i = 1, 2, \dots, N \text{ ve } \zeta_i \geq 0 \quad (13)$$

Eş. 12'yi minimize etmek için; Lagrange çarpanları yöntemi kullanılmaktadır. Böylece problem, Eş. 14'deki ikili (dual) biçime dönüşür. Eş. 14'deki α_i 'ler lagrange çarpanlarıdır. Karush-Kuhn-Tucker şartına göre [36]; herhangi bir veri için $\alpha_i > 0$ ise bu veriler destek vektörleri olarak adlandırılır, $\alpha_i = 0$ ise bu veri destek vektörü değildir ve yeni verilerin sınıflandırılmasında hiçbir rol oynamamaktadır. Eş. 15'deki α_i 'nin üst sınırı olan C kullanıcı giriştir.

$$\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (14)$$

$$0 \leq \alpha_i \leq C \quad i = 1, 2, \dots, N \quad (15)$$

Diğer bir çözüm yolu olarak giriş uzayında doğrusal olarak ayrılmayan veriler haritalama fonksiyonu, $\phi(\cdot) : \mathbb{R}^d \rightarrow \mathbb{R}^{d^p}$

ile yüksek boyutlu bir uzaya haritalanarak ayrılabilir bir duruma gelmektedir. Özellik uzayına aktarılan iki vektör çarpılır bu çarpıma kernel fonksiyonu denir: $K(x, z) = \phi(x)^T \phi(z)$. Böylece Eş. 14'deki ikili problem, Eş. 16'ya dönüşür.

$$\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (16)$$

DVM, Mercer koşullarını sağlayan kernel fonksiyonlarını kullanır. Yaygın olarak kullanılan kernel fonksiyonlarından biri denklem Eş. 17'de verilen radyal tabanlı fonksiyon (RBF) kerneldir. Eş. 18'deki σ değeri RBF fonksiyonunun genişliğidir.

$$K(x_i, x_j) = \exp\left(-\frac{1}{\gamma} \|x_i - x_j\|^2\right) \quad (17)$$

$$\gamma = 1/2\sigma^2 \quad (18)$$

3.2. K-En Yakın Komşu (K-EYK) Algoritması (K-Nearest Neighbor Algorithms)

K-En Yakın Komşu (K-EYK) algoritması öznitelik uzayındaki en yakın eğitim örneklerine dayanarak nesnelere sınıflandıran, en basit örüntü tanıma yöntemlerinden birisidir [38]. 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 Eş. 19 daki Öklid uzaklığı ile bulunur.

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (dizi_r(x_i) - dizi_r(x_j))^2} \quad (19)$$

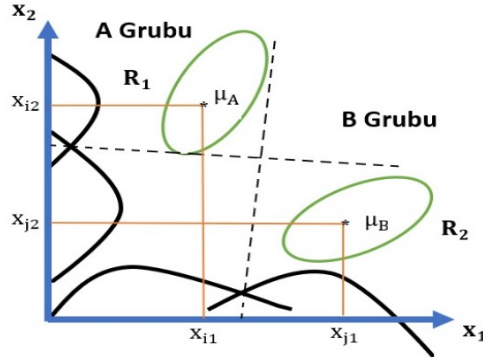
K-en yakın komşu algoritması eğitici ve örnek tabanlı bir sınıflandırma algoritmasıdır. Uygulanabilirliği diğer yöntemlere göre daha kolaydır. Bu tip algoritmalarda eğitime ihtiyaç yoktur. İşleyişi, "birbirine yakın olan nesnelere muhtemelen aynı kategoriye aittir" diyen sezgisel fikir üzerine kuruludur. 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.

3.3. Diskriminant Analiz (Discriminant Analysis)

Bir sınıflandırma yöntemi olan diskriminant analiz (DA) farklı sınıfların farklı Gaussian dağılımına sahip oldukları ilkesine dayanmaktadır [37]. Doğrusal Diskriminant Analiz (LDA) ve Quadratik Diskriminant Analiz (QDA) olarak iki temel gruba ayrılan diskriminant analizinin, ayırma ve sınıflama şeklinde iki işlevi bulunmaktadır.

LDA'da her sınıfın aynı kovaryans matrisine sahip olduğu kabul edilir. Ancak sadece ortalamalar farklıdır. Fisher [29] tarafından geliştirilmiştir. QDA'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 9'da 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 [39]. Bu nedenle diskriminant analizinde uygun ağırlıklarla çarpılan değişkenler toplanıp tek bir fonksiyona dönüştürülür ve bu fonksiyona diskriminant fonksiyonu denilmektedir (Eş.20). Doğrusal ve karesel diskriminant fonksiyonları Şekil 10'da verilmiştir.




Şekil 9. Diskriminant analizi [38].
(Discriminant analysis [38])

4. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSION)

$$y_i = a_1x_{i1} + a_2x_{i2} + \dots + a_px_{ip} \quad (20)$$


Bu çalışmada kullanılan veriler 10 normal, 7 myopati ve 8 ALS hastasına aittir. Her bir veri grubunda; 8 sn süren 230'ar tane EMG verisi bulunmaktadır. Bu verilerin 1 sn'lik kısmında tepe değeri 50uV aşan ortalama 36 adet MUAP yer almaktadır. Bölütleme aşamasında ise toplam 198600 MUAP elde edilmiştir.

Sınıflandırıcı başarımını 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 başarımı dışarıda bırakılan veriler üzerinden 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.



Şekil 10. Diskriminant fonksiyonları (Discriminant functions)

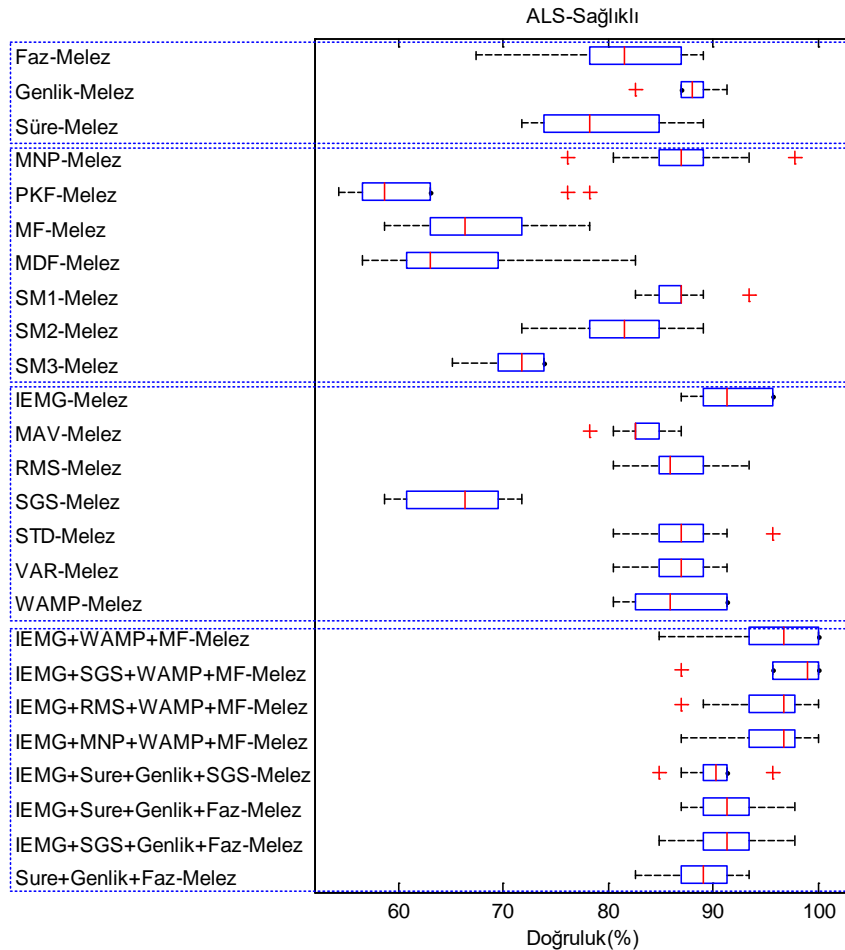
Sınıflandırma başarımının üstünlüğünün arkasında yatan ana neden öznitelik vektörlerinin sınıflar arası ayrılabilirliğinin yüksek derecede olmasıdır [6]. Bu makaledeki deneysel sonuçlar bu çalışmanın sınıflandırma yeteneğinin sadece iki sınıflı problemleri ayırabildiğini göstermiştir. Bu duruma en iyi örnek Şekil 11'de verilmiştir. Grafikte her üç sınıftaki 50



Şekil 11. ALS, Myopati ve Sağlıklı kişilere ait verilerin RMS öznitelik vektörlerinin ortalama değer değişimi
(Mean value change of RMS feature vectors of data from ALS, Myopathy and Healthy persons)

veriye ait MUAP'ların RMS öznitelik vektörlerinin ortalama değerleri çizdirilmiştir. Burada ALS hastalığına karşılık gelen RMS özniteliklerinin ortalama değerleri diğer iki sınıfa (myopati, sağlıklı) göre çok daha yüksek olmasına rağmen, RMS öznitelik vektörünün myopati ile sağlıklı verileri ayırma derecesi çok tatmin edici değildir. Bu çalışmada kullanılan öznitelik vektörlerinin sadece sağlıklı veri ile ALS verilerini ya da ALS ile myopati verileri arasında daha iyi bir sınıflandırma doğruluğunu mümkün kılmaktadır. Bu durum diğer tekli ve çoklu öznitelik vektörleri içinde geçerli olması nedeniyle sınıflandırma başarımları Tablo 5'de ikili sınıflandırma olarak sunulmuştur. Sonuçlar göstermiştir ki önerilen özellikler sadece iki sınıfın (ALS-Sağlıklı ve ALS-Myopati) yüksek derecede ayrılabilirliğini sağlamıştır. Şekil 12'de morfolojik (süre, genlik ve faz), zaman, frekans ve çoklu öznitelik vektörlerinin başarımları kutu grafiği ile verilmiştir. Her bir kutu grafiği k değeri kadar başarımların sonucunun grafiksel bir özetini sunmaktadır. Yüksek sınıflandırma başarımları elde etmek için etkili öznitelik vektörü kullanmak gerekir (Windham, 1982). Bu amaç doğrultusunda bu çalışmada sınıflandırma doğruluğunu arttırmak için öznitelik vektörlerinin çeşitli şekilde birleştirilmesi ile elde edilen çoklu öznitelik vektörleri kullanılmıştır. Şekil 12'de çoklu öznitelik vektörleri

kullanılması durumunda tekli öznitelik vektörlerine göre sınıflandırma başarımları artmıştır. En iyi başarımları çoklu öznitelik vektörü IEMG+SGS+WAMP+MF sağlamıştır. ALS-Sağlıklı sınıflandırmada en iyi başarımların medyan değeri %98,91 dir. Bu çalışmada elde edilen sınıflandırma sonuçlarını daha önce yapılan farklı tip veri setini kullanan çalışmalarla kıyaslamak yerine; ortak bir veri tabanını kullanan (Maboud vd. , 2015), (Krishna ve Thomas, 2015) ve (Mishra vd.,2016) çalışmalarını ile karşılaştırmak daha doğru olacaktır. 2015 ve 2016 yıllarında yayınlanan bu çalışmalardaki veriler (<http://www.EMGLab.net>, 2011) internet adresindeki veri tabanından alınmıştır. Ancak bu üç yayında da; bu çalışmadaki veri setine göre daha az veri seti ile işlem yapılmıştır. Bu durumlar göz önünde bulundurulduğunda bu çalışmada elde edilen başarımların yüzdelere aynı veri setini kullanan çalışmalara göre daha iyi olduğu görülmektedir (Tablo 4). Bu çalışmada ALS-Sağlıklı, ALS-Myopati ve Myopati-Sağlıklı sınıflarının başarımlarını değerlendirmek amacıyla bazı istatistiksel ölçütler Tablo 5'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.



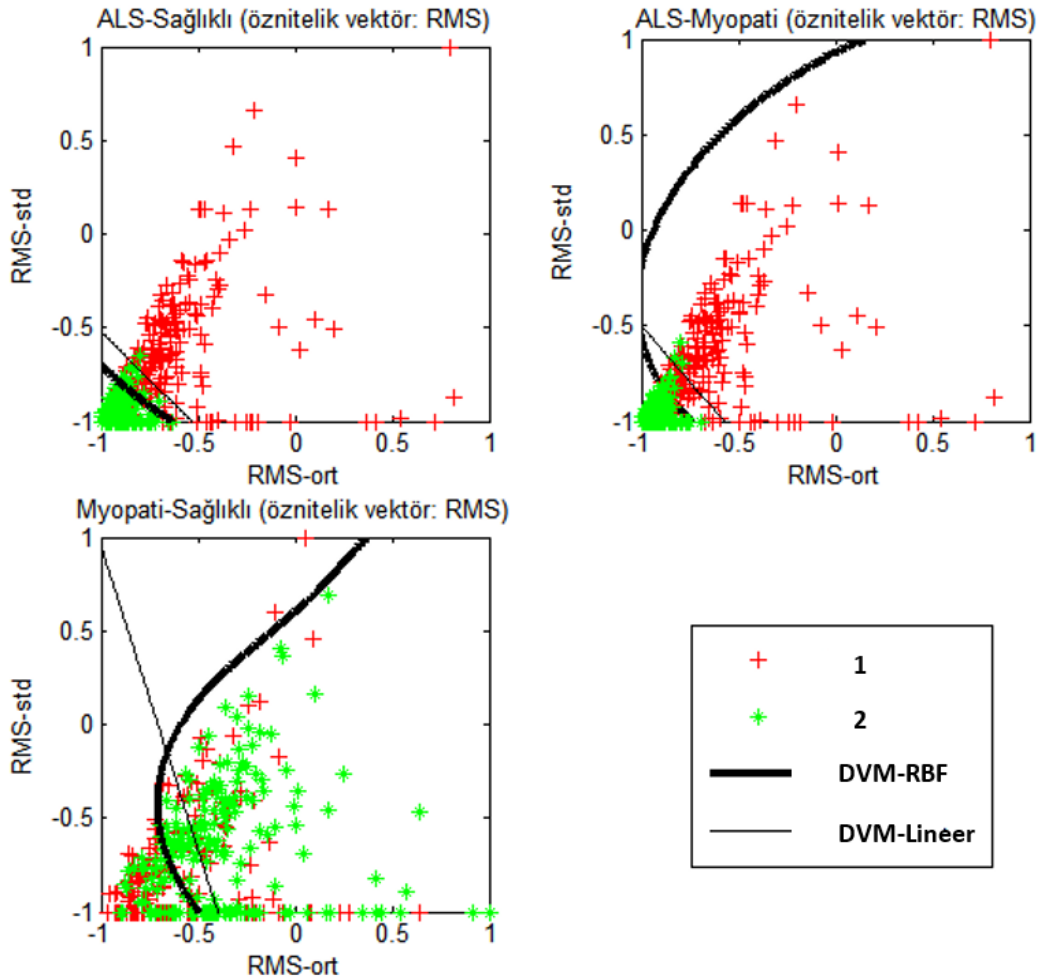
Şekil 12. Zaman, Frekans ve Çoklu öznitelik vektörlerinin başarımları
(Achievements of Time, Frequency and Multiple Feature vectors)

Duyarlılık = $DP/(DP+YN)$ şeklinde gösterilir.

- Özgüllük, gerçekte hasta olmayan bireylerin testlerinin negatif sonuç verme oranıdır.
Özgüllük = $DN/(DN+YP)$ şeklinde ifade edilir.
- Toplam Doğruluk, Hasta ve hasta olmayan kişilerin yüzde kaçının önerilen yöntemle tanınabildiğini gösterir.
Toplam Doğruluk = $DP+DN/(DP+DN+YN+YP)$

Tablo 5’de öznelik vektörü IEMG+SGS+WAMP+MF seçilmesi durumunda her bir sınıflandırma algoritması için yukarıda anlatılan ölçütler hesaplanmıştır. ALS-Sağlıklı ve ALS-Myopati ikili sınıflarda DVM-RTF sırasıyla %97,39, %94,57 en iyi başarıyı sağlarken; Myopati-Sağlıklı ikili sınıflarda en iyi başarıyı %86,74 ile DVM-Doğrusal ve DDA sağlamıştır. Şekil 14’de DVM, K-EYK ve DA algoritmalarının başarımları ve işlem süreleri, IEMG+SGS+WAMP+MF, IEMG+MNP+WAMP+MF ve IEMG+WAMP+MF çoklu öznelik vektörleri ve RMS için hesaplanmıştır. Her üç çoklu öznelik vektörlerinin başarımları birbirlerine yakın değişimler sergilemiştir. Sınıflandırma algoritması DVM-RTF, öznelik vektörü RMS seçilmesi durumunda işlem süresi diğerlerine göre artış

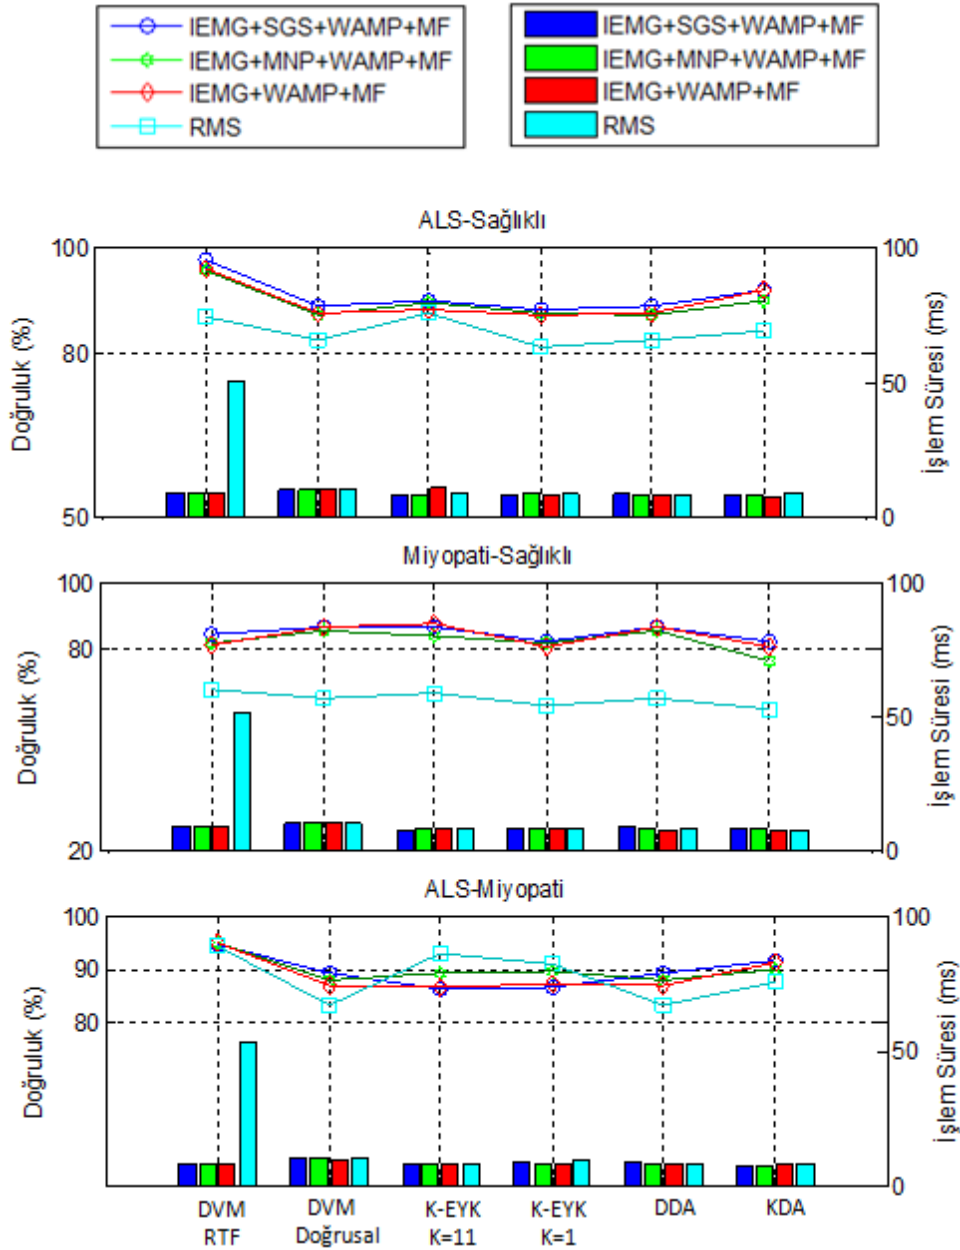
göstermiştir. Diğer durumlar için işlem süreleri hemen hemen aynı kalmıştır. Her üç sınıflandırmada K-EYK algoritmasında komşu sayısının K=11 seçilmesi başarıyı arttırmıştır. ALS-Sağlıklı ve ALS-Myopati ikili sınıflandırmada DVM algoritması için çekirdek fonksiyonu doğrusal yerine, RTF seçilmesi; diskriminant analizinde ise doğrusal fonksiyon yerine kuadratik fonksiyon seçilmesi sınıflandırma başarımlarını arttırmıştır. Ancak Myopati-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 Myopati-Sağlıklı ikili sınıflandırmada farklı sınıf verilerinin yoğun biçimde iç içe geçmiş olması sonucunda; eğitim aşamasında ağır verilere aşırı uyum (overfitting) göstermesinden kaynaklanmaktadır. Aşırı uyum sınıflandırma algoritmalarının başarımlarını kötü yönde etkilemektedir. Bu duruma en iyi örnek Şekil 13’de sınıflandırma algoritması DVM seçilmesi durumunda verilmiştir: Özellikle Myopati-Sağlıklı sınıflandırmanın ALS-Sağlıklı, ALS-Myopati ikili sınıflandırmalara göre RMS öznelik vektörünün farklı sınıflara ait verileri iyi ayırtmadığı görülmektedir.



Şekil 13. İkili Sınıflandırmada Öznelik Vektörü RMS olması durumunda DVM- Lineer ve DVM-Rbf Algoritmalarının oluşturduğu sınır hatları (Limitations of DVM-Linear and DVM-Rbf Algorithms in the case of RMS in Feature Vector in Binary Classification)

Tablo 4. Aynı Veri Setini Kullanan Çalışmaların Karşılaştırılması
(Comparison of Studies Using the Same Data Set)

Çalışmalar	Kullanılan Yöntemler		Doğruluk (%)
	Öznitelik Çıkarma	Sınıflandırma	
(Krishna ve Thomas, 2015)	ADD	K-EYK	ALS-Sağlıklı ;%96,5 Myopati-Sağlıklı; %83,5
(Maboud ve diğ., 2015)	ADD	DVM ve YSA	ALS için DVM; %98,0 Myopati için YSA; %86,6
(Mishra ve diğ.,2016)	Analitik Öznitelik Vektörleri	EKK-DVM	ALS-Sağlıklı ;%95
Yazarın önerisi	Çoklu Öznitelik Vektörleri	DVM	ALS-Sağlıklı ;%97,39 Myopati-Sağlıklı; %86,74

**Şekil 14.** Çoklu öznitelik vektörleri için DVM, K-EYK ve DA Sınıflandırıcılarının başarımlarının karşılaştırılması
(Comparison of the performance of DVM, K-EYK and DA Classifiers for multiple feature vectors)

Tablo 5. Performans değerlendirme (Performance evaluation)

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	20	201	91,30	87,39	89,35
KDA	200	9	30	221	86,96	96,09	91,52

5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada önerilen öznelik vektörleri arasında çoklu öznelik vektörlerinin tekli öznelik vektörlerine göre daha başarılı olduğunu göstermiştir. Bu çalışma ile sınıflandırma başarımının öznelik vektörünün sınıflar arası ayrılabilirliğinin yüksek derecede olmasına bağlı olduğu anlaşılmıştır. Bu amaç doğrultusunda IEMG+SGS+WAMP+MF çoklu öznelik vektörünün kullanılması durumunda ALS-Sağlıklı ve ALS-Myopati ikili sınıflarda DVM-RTF sırasıyla %97,39, %94,57 en iyi başarıyı sağlarken; Myopati-Sağlıklı ikili sınıfında en iyi başarıyı %86,74 ile DVM-Doğrusal ve DDA sağlamıştır.

Bundan sonraki gelecek çalışmada amaçlanan bu çalışmada önerilen/denenen yöntemleri BAL-LAB 'ta tasarımı tamamlanan 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 desteklenmiştir. Dört kanallı bu cihaz yüzey EMG ve sinir ileti hızı ölçümü yapabilecek kapasiteye sahiptir)

TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma Ondokuz Mayıs Üniversitesi PYO.MUH.1906.10.001-BAL-LAB'nolu proje ile desteklenmiştir.

KAYNAKLAR (REFERENCES)

1. V. Basmajian, C.J. De Luca, Muscles Alive: Their Functions Revealed by Electromyography, 5th edition, William & Wilkins, Baltimore, 1985.
2. C.I. Christodoulou, C.S. Pattichis, Unsupervised pattern recognition for the classification of EMG signALS, IEEE Trans. Biomed. Eng. 46, 169, 1999.
3. M.R. Bozkurt, EMG İşaretlerinin Modern Yöntemlerle Önışlemesi ve Sınıflandırılması, Sakarya Üni. , Fen Bilimleri Ens., Doktora Tezi, Sakarya, 2007.
4. Stalberg, Andressan S., 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.
5. Ejderha, H., EMG İşaretlerin Kullanılarak YorgunlukSeviyeleri; Neuro-Fuzzy ve YSA İle Sınıflandırılması, Yüksek Lisans Tezi,Fen Bilimleri Enstitüsü,Kahramanmaraş Sütçü İmam Üniversitesi, Kahramanmaraş, 2009.
6. Fattah, Shaikh Anowarul, et al. Evaluation of Different Time and Frequency Domain Features of Motor Neuron and Musculoskeletal Diseases, International Journal of Computer Applications 43.23, 34-40, 2012.
7. G. Pfeiffer, The diagnostic power of motor unit potential analysis: an objective Bayesian approach, Muscle Nerve 22 (5),584–591, 1999.
8. Y. Xiang, B. Pant, A. Eisen, M.P. Beddoes, D. Poole, Multiply sectioned Bayesian networks for

- neuromuscular diagnosis, *Artif. Intell. Med.* 5, 293, 1993.
9. E. Abel, P. Zacharia, A. Forster, T. Farrow, Neural network analysis of the EMG interference pattern, *Med. Eng. Phys.* 18 (1), 12–17, 1996.
 10. A. Hamilton-Wright, D.W. Stashuk, H.R. Tizhoosh, Fuzzy classification using pattern discovery, *IEEE Trans. Fuzzy Syst.* 15 (5), 772–783, 1999.
 11. C.D. Katsis, D.I. Fotiadis, A. Likas, I. Sarmas, A novel EMG decomposition method that discovers the number of MUAP clusters, in: *Proceedings of the 2nd European Medical and Biological Engineering Conference EMBEC 2002, Vienna, Austria*, 400, 2002.
 12. N.F. Guler, S. Koçer, Classification of EMG signals using PCA and FFT, *J. Neurosci. Methods* 29 (3), 241–250, 2005.
 13. Yousefi, Jamileh, and Andrew Hamilton-Wright. Characterizing EMG data using machine-learning tools. *Computers in biology and medicine* 51, 1-13, 2014.
 14. A. Subasi, M. Yilmaz, H.R. Ozcalik, Classification of EMG signALS using wavelet neural network, *J. Neurosci. Methods* 156 (1–2), 360–367, 2006.
 15. A. Bhardwaj, A. Manish, K. Arora, Classification of MUAPs by using ANN pattern recognition technique, *Int. J. Sci. Res. Eng. Technol. (IJSRET)* 1, 10, 2012.
 16. S. Rasheed, D. Stashuk, M. Kamel, Adaptive fuzzy K-NN classifier for EMG signal decomposition, *Med. Eng. Phys.* 28, 694, 2006.
 17. S., Lahmiri, B., Mounir. Improved Electromyography Signal Modeling for Myopathy Detection, *Circuits and Systems (ISCAS), 2018 IEEE International Symposium on.* IEEE, 2018.
 18. G. Kaur, A.S. Arora, V.K. Jain, EMG diagnosis via modelling and binary support vector machine classification, *Int. J. Eng. Sci. Technol.* 2, 1767–1772, 2010.
 19. A.P. Dobrowolski, M. Wierzbowski, K. Tomczykiewicz, Multiresolution MUAPs decomposition and DVM-based analysis in the classification of neuromuscular disorders, *Comput. Methods Prog. Biomed.* 107 (3), 393–403, 2012.
 20. A. Subasi, Medical decision support system for diagnosis of neuromuscular disorders using DWT and fuzzy support vector machines, *Comput. Biol. Med.* 42, 806–815, 2012.
 21. G. Kaur, A.S. Arora, V.K. Jain, Multi-class support vector machine classifier in EMG diagnosis, *WSEAS Trans. Signal Process.* 2, 379, 2009.
 22. Katsis, C.D., Likas, A. & Fotiadis, D.I. A novel method for automated EMG decomposition and MUAP, *Artificial Intelligence in Medicine*, 37 (1), 55-64, 2006.
 23. A. Subasi, Classification of EMG signALS using PSO optimized DVM for diagnosis of neuromuscular disorders, *Comput. Biol. Med.* 43, 576–586, 2013.
 24. Dorfman LJ, McGill KC., *AAEE Minimonograph 29: Automatic Quantitative Electromyography. Muscle Nerve.*; 11 (8), 804-18, 1988.
 25. Gurmanik, K., Shatru, A., Jain, V. K., Multi-Class Support Vector Machine Classifier in EMG Diagnosis, *WSEAS Transactions on Signal Processing.* 5 (12), 379-389, 2009.
 26. Mc Grew, J.C., Monroe, C.B., *Statistical Problem Solving in Geography*, Ww C. Brown, 1993.
 27. G. Kayhan, A. Ozdemir ve I. Eminoglu, Reviewing and designing pre-processing units for RBF networks: Initial structure identification and coarse-tuning of free parameters, *Neural Computing and Applications*, 2012.
 28. MathWorks, *Matlab Toolbox of Bioinformatics: User's Guide.* Mathworks Inc, 2007.
 29. Fisher, R. A. *The Use of Multiple Measurements in Taxonomic Problems*, 1936.
 30. Özdamar K: *Paket Programlar ile İstatistiksel Veri Analizi (Çok Değişkenli Analizler).* Kaan Kitabevi, Eskişehir, 2004.
 31. Weinstein S, Obuchowski NA, Lieber ML. Clinical evaluation of diagnostic tests. *AJR Am J Roentgenol.* 184, 14-19, 2005.
 32. M. R. Bozkurt, EMG İşaretlerinin Modern Yöntemlerle Önışlemesi ve Sınıflandırılması, *Sakarya Üni. Fen Bilimleri Ens., Doktora Tezi, Sakarya*, 2007.
 33. C. Katsis, A.L.Y. Goletsis, D. Fotiadis, I. Sarmas, A two-stage method for MUAP classification based on EMG decomposition, *Artif. Intell. Med.* 37, 55–64, 2006.
 34. N.F. Guler, S. Kocer, Classification of EMG signALS using PCA and FFT, *J. Neurosci. Methods* 29 (3), 241–250, 2005.
 35. M.J. Aminoff, *Electromyography in Clinical Practice: Electrodiagnostic Aspects of Neuromuscular Disease*, 2nd edition, Churchill Livingstone, New York, 1987.
 36. Günay M., EMG İşaretlerinin Sınıflandırılması Ve Öbekleştirilmesi, *Y.Lisans Tezi Fen Bilimleri, Sütçü İmam Üniversitesi, Kahramanmaraş*, 2011.
 37. Macit, E G. Çok Kriterli Sıralı Sınıflandırma Problemi Ve Sağlık Sektöründe Bir Uygulama. *Y. Lisans Tezi, Erciyes Ün.*, 2014.
 38. Tatlıdil, H. *Uygulamalı Çok Değişkenli İstatistiksel Analiz* Ankara: Cem Web Ofset Ltd., 1996.
 39. N Güler, Antenatal Fetüs Verilerinin Örüntü Tanıma Yöntemleriyle Tanımlanması, *Doktora Tezi. İstanbul: Yıldız teknik üniversitesi fen bilimleri enstitüsü, Matematik müh. Anabilim dalı*, 2002.
 40. Mishra, V.K., Bajaj, V., Kumar, A., Singh, G.K.: Analysis of ALS and normal EMG signals based on empirical mode decomposition. *IET Sci. Meas. Technol.* 10 (8), 963–971, 2016
 41. H. Küçük, İ. Eminoğlu, Nöromüsküler Hastalıkların Teşhisinde SVM, K-EYK ve DA Algoritma Tabanlı Sınıflandırma Bölüm-I, *TIP TEKNO'16.* 150-153, 2016.
 42. H. Küçük, İ. Eminoğlu, Nöromüsküler Hastalıkların Teşhisinde SVM, K-EYK ve DA Algoritma Tabanlı Sınıflandırma Bölüm-II, *TIP TEKNO'16.* 154-157, 2016.
 43. Aydın F., Aslan Z., Diagnosis of neuro degenerative diseases using machine learning methods and wavelet transform, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32 (3), 749-766, 2017.

44. T. Artug, B. Bolat, O. Osman, I. Göker, B. Baslo, Determining MUAP activity corridor in scanning EMG recordings, in: IEEE International Symposium on INnovations in Intelligent SysTems and Applications (INISTA), Autonomous University of Madrid, Madrid, Spain, 2015.
45. T., Artuğ, I., Goker, B., Bolat, O., Osman, E. K., Orhan, & M. B., Baslo. New features for scanned bioelectrical activity of motor unit in health and disease. Biomedical Signal Processing and Control, 41, 109-128, 2018.

