

Determining Effective Features to Use the EOG Sign as a Source Sign

 İlhan ZENGİN¹,  Mehmet Recep BOZKURT²,  Muhammed Kürşad UÇAR³

¹ Corresponding Author; Sakarya Üniversitesi Mühendislik Fakültesi Elektrik - Elektronik Mühendisliği Bölümü
ilhan.zengin1@ogr.sakarya.edu.tr; <https://orcid.org/0000-0002-6446-0933>

² Sakarya Üniversitesi Mühendislik Fakültesi Elektrik - Elektronik Mühendisliği Bölümü,
mbozkurt@sakarya.edu.tr; <https://orcid.org/0000-0003-0673-4454>

³ Sakarya Üniversitesi Mühendislik Fakültesi Elektrik - Elektronik Mühendisliği Bölümü,
mucar@sakarya.edu.tr; <https://orcid.org/0000-0002-0636-8645>

Received 20 November 2019; Revised 10 December 2019; Accepted 18 December 2019; Published online 31 December 2019

Abstract

In this study, the processing of the Electrooculogram (EOG) signal for human machine interface (İMA) was performed to facilitate the lives of paralyzed patients. Eye movements were detected with Biopac MP30 instrument using 5 Ag-AgCl electrodes. The marks were pre-processed and their attributes were made to be extracted in Matlab environment. The obtained biopotential signals were extracted and labeled according to the system to be controlled. These labels are right, left, up, down, and blink. The extracted features were classified using artificial neural networks. Following the classification, feature reduction methods were used to eliminate the features that had little effect on the results and test the performance of the classification with fewer features.

Keywords: Human Machine Interface (HMI), Electrooculogram (EOG), Artificial Neural Network (ANN), Feature Reduction

EOG İşaretini Kaynak İşaret Olarak Kullanmak Üzere Etkin Özelliklerin Belirlenmesi

Öz

Bu çalışmada, özellikle felçli hastaların yaşamlarını kolaylaştırmak için Elektrokülogram (EOG) işaretinin insan makine arabirimi (İMA) için işlenmesi gerçekleştirilmiştir. Göz hareketleri, Biopac MP30 cihazıyla, 5 adet Ag-AgCl elektrot kullanılarak algılanmıştır. Alınan işaretler ön işleme tabii tutularak Matlab ortamında öznitelikleri çıkarılacak hale getirilmiştir. Elde edilen biyopotansiyel sinyallerden öznitelikler çıkarılarak kontrol edilecek sisteme göre etiketlenmiştir. Bu etiketler sağ, sol, yukarı, aşağı ve göz kırpmasıdır. Çıkarılan özellikler yapay sinir ağları kullanılarak sınıflandırılmıştır. Sınıflandırmanın ardından özellik azaltım yöntemleri kullanılarak sonuç üzerinde etkisi az olan öznitelikler elenmiş ve daha az özellik ile sınıflandırma başarımları test edilmiştir.

Anahtar Kelimeler: İnsan Makine Arabirimi (İMA), Elektrokülogram (EOG), Yapay Sinir Ağları (YSA), Özellik azaltımı

1. Giriş

Amyotrofik Lateral Skleroz (ALS), felç gibi hastalıkları olan kişilerin, gözlerinin kontrolünü nadiren kaybettikleri bilgisine dayalı olarak, hayatlarını kolaylaştırmak için çeşitli sistemler önerilmiştir. Örneğin, bu sistemlerden bir tanesi, ALS hastalığına sahip ünlü bilim insanı Stephen Hawking'in kullandığı, bilgisayar entegreli tekerlekli bir sandalyeydi. Bu sandalyedeki sistem, Hawking'in yanığında aktif halde bulunan bir kastan alınan işareti, bilgisayar ekranında bir fare imleci olarak kullanmasına olanak sağlamaktaydı. Bu alanda sadece beyin dalgalarından alınan işaretlerle benzer sistemler tasarlanmaktadır [1]. Ayrıca başka bir örnek, tobii firmasının oyun ve eğlence için geliştirdiği göz takip (eye tracker) sistemleri, bu sahaya çok daha esnek ve konforlu bir çözüm getirecektir [2]. Bu çalışmamızda, EOG tabanlı sistemlere katkı olması açısından, kaynak işaret üzerine çalışılmıştır. EOG


tabanlı sistemler üzerine de bir çok çalışma mevcuttur. Örneğin bu çalışmada Elektroensefalografi (EEG) ve Elektrokülogram (EOG) sinyallerini ortak değerlendirerek bir tekerlekli sandalye kontrol edilmeye çalışılmıştır [3]. Başka bir çalışmada, yazarlar göz hareketleriyle bir klavyeyi kontrol etmeye çalışmışlardır [4]. Bir diğer örnekte, giyilebilir gözlüklerle alınan sinyaller ile bir bilgisayar ekranında farenin imleci kontrol edilmeye çalışılmıştır [5]. Bir başka örnekte, ölçümleri alın bölgesinden yapabildiği giyilebilir bir alın bandı yapısında bir EOG sistemi tasarlanmıştır [6]. Bir diğer örnekte EOG sinyalleri ile kontrol edilebilen bir tekerlekli sandalye sistemi tasarlanmıştır [7]. Bir başka örnekte, EOG tabanlı gözle yazı yazma sistemi geliştirilmiştir [8]. Literatürdeki sistemlerde kullanılan yöntemlerde EOG işaretleri kaynak işaret olarak kullanılmıştır. Gözlerden alınan biyolojik işaretlerinin insan makine arabirimi için işlenmesi, kontrol edilecek sisteme göre elektrokülogram işaretinin uygun şekilde etiketlenmesidir [9]. Bu işlem için çeşitli yöntemler önerilmiştir. Büyük miktarlardaki verilerden farklı parametreler çıkararak çeşitli problemlerin çözümüne daha kompakt, daha düşük maliyetli ve ulaşılabilir çözümler getirmek için farklı algoritmalar kullanılmaktadır [10]. Bu çalışmada EOG sinyallerinden zaman domeninde (ZD) özellik çıkarımı yapılmış ve özelliklerin ağırlıkları belirlenerek özellik azaltımı yöntemleri kullanılarak sınıflandırma başarımları test edilmiştir. Sınıflandırıcı olarak Yapay Sinir Ağları (YSA) kullanılmıştır [11]-[13]. EOG sinyalleri beş farklı şekilde etiketlenmiştir. Bunlar sağ, sol, yukarı, aşağı ve göz kırpmasıdır. EOG'nin zaman domeninden 22 adet özellik çıkarılmıştır [14] [15]. Bu özellikler ile yapılan sınıflandırma sonucunda %99 doğruluk oranı elde edilmiştir. Daha sonra F-Score ile kullanılan özellik sayısı azaltılmıştır [16]. 22 adet özellikten 8 adet özellik seçilmiştir ve seçilen özellikler kullanılarak sınıflandırmada %97 seviyelerinde doğruluk oranı tespit edilmiştir.

2. Materyal ve Yöntem

Çalışmada kullanılan veri tabanı Sakarya Üniversitesi Tıp Elektronik Laboratuvarında oluşturulmuştur. Veri tabanı, hastaya özel sistem tasarımına uygun olması açısından, 1 bireyden, Biopac MP30 veri toplama birimi kullanılarak elde edilen 2 kanal veriden oluşmaktadır. EOG sinyallerinin örnekleme frekansları 100 Hz'dir. Veriler alınırken deneyin göz hareketlerinin düzenli bir şekilde alınması için kalibrasyon işlemleri yapılmış ve ardından 4 farklı yön ve göz kırpması olmak üzere beş farklı işaret türü için kayıt yapılmıştır. Çalışmada verisi alınan birey 30 yaşında, 163 cm boyunda ve 75 kg ağırlığında bir erkektir. Çalışmada EOG sinyalleri Matlab ortamında filtrelenmiş, ardından sınıflandırma işlemi için kullanılacak kısımlar, kesitlenmiştir [17]-[19]. Yatay göz hareketleri için 1,158 adet kesit, dikey göz hareketleri içinse 1606 adet olarak, Şekil 1'deki gibi elde edilmiştir ve Tablo 1'de gösterilmiştir. Bu aşamadan sonra her bir kesitten özellik çıkarımı yapılmıştır. Özellik çıkarımının ardından YSA ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işleminin ardından, iş yükünün azaltılması ve sınıflandırma süresinin düşürülmesi için özellik azaltım yöntemleri kullanılmıştır. Bu işlemin ardından sonuçlar karşılaştırılmıştır.

Tablo 1 Kesitlerin Dağılım Tablosu

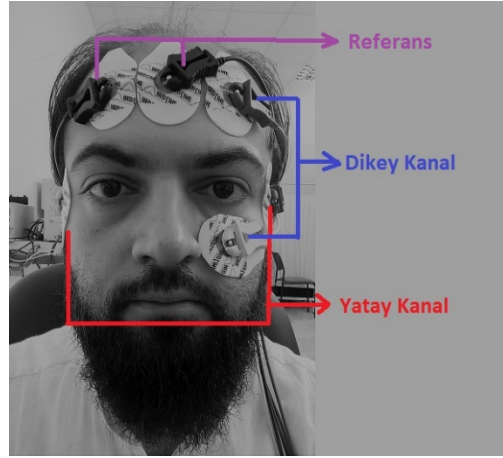
	Sağ	Sol	Alt	Üst	Göz Kırpması
Kesit Sayısı	578	580	619	596	391



Şekil 1 Sinyallerin Kesitlenmesi

2.1. EOG Sinyali Özellikleri

Çalışmada, EOG sinyali Şekil 2'deki gibi 2 kanaldan kaydedilmiştir. Referans elektrodu olarak alın kullanılmıştır [6] [20]. Alınan sinyallerin, örnekleme frekansı 100 Hz'dir.



Şekil 2 Elektrodların Yerleşimi

EOG sinyalinden elde edilen kesitlerin her birinden zaman domeninde Tablo 2'deki 21 adet özellik çıkartımı yapılmıştır[14].

Tablo 2 Özellik Çıkarma Tablosu

Sıra	Özellik	Denklem
1	Basıklık	$x_{kur} = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)S^4}$
2	Çarpıklık	$x_{ske} = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)S^3}$
3	Varyasyon katsayısı	$DK = (S/\bar{x})100$
4	Geometrik Ortalama	$G = \sqrt[n]{x_1 + \dots + x_n}$
5	Harmonik Ortalama	$H = n/((1/x_1) + \dots + (1/x_n))$
6	Varyans	$A = S^2$
7	Ortanca	$\tilde{x} = \begin{cases} \frac{x_{n+1}}{2} & : x \text{ tek} \\ \left(\frac{x_n + x_{n+1}}{2} \right) & : x \text{ çift} \end{cases}$
8	Ortalama	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (x_1 + \dots + x_n)$
9	Ortalama Enerji	$E = \frac{1}{n} \sum_{i=1}^n x_i^2$
10	Karekök Ortalama	$x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i ^2}$
11	Standart Hata	$S_{\bar{x}} = S/\sqrt{n}$
12	Standart Sapma	$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
13	Şekil Faktörü	$SF = X_{rms} / \frac{1}{n} \sum_{i=1}^n \sqrt{ x_i }$

14	*Çeyrekler Açıklığı	$IQR = iqr_x$
15	*%50 Kırpılmış Ortalama	$T50 = trimmean(x, 50)$
16	*%25 Kırpılmış Ortalama	$T25 = trimmean(x, 25)$
17	*Maksimum	$x_{max} = max(x)$
18	*Ortalama Mutlak Sapma	$MAD = mad(x)$
19	*Minimum	$x_{min} = min(x)$
20	*Merkezi Moment	$CM = moment(x, 10)$
21	*Tekil Değer Ayırıştırması	$SVD = svd(x)$

* ile işaretlenmiş özellikler Matlab komutları ile hesaplanmıştır.

Bu özelliklerden sonra kesitlerin işaret süreleri Şekil 3'deki gibi 22. özellik olarak özellik matrisine eklenmiştir.

	1	2	3	4	5	6	7
13	0.1388	0.1316	0.1340				
14	0.3725	0.3627	0.3660				
15	0.3850	-0.3712	0.3742				
16	0.3876	-0.3736	0.3757				
17	0.3566	0.3537	0.3527				
18	0.6190	0.6075	0.6123				
19	3.6309	3.4982	3.7859				
20	-4.1408e-05	1.1501e-05	-2.9180e-05				
21	0.0045	0.0028	0.0038				
22	0.9400	0.9200	1.0600				
23	1	-1	1				
24							

Şekil 3 Özellik Matrisi

Sonuç olarak yatay ve düşey göz hareketleri için özellik matrisleri Şekil 4'deki gibi elde edilmiştir.

Name	Value	Size
input	22x1158 double	22x1158
target	1x1158 double	1x1158

Name	Value	Size
input	22x1606 double	22x1606
target	1x1606 double	1x1606

Şekil 4 Yatay ve Düşey Özellik Matrisleri

2.2. Özellik Azaltımı ve F-Score Özellik Seçme Algoritması

Makine öğrenmesi alanında özellik seçme algoritmaları büyük öneme sahiptir. Çok büyük verilerin anlamlı bir şekilde azaltılması özellik seçme algoritmalarının temel işlevidir. Gelişen teknoloji ile birlikte devasa miktarlarda veri depolanmaktadır. Devasa boyutlardaki veriler, işlem süreçlerini uzatması sebebiyle, makine öğrenmesini olumsuz etkilemektedir. Bu problemin üstesinden gelebilmek

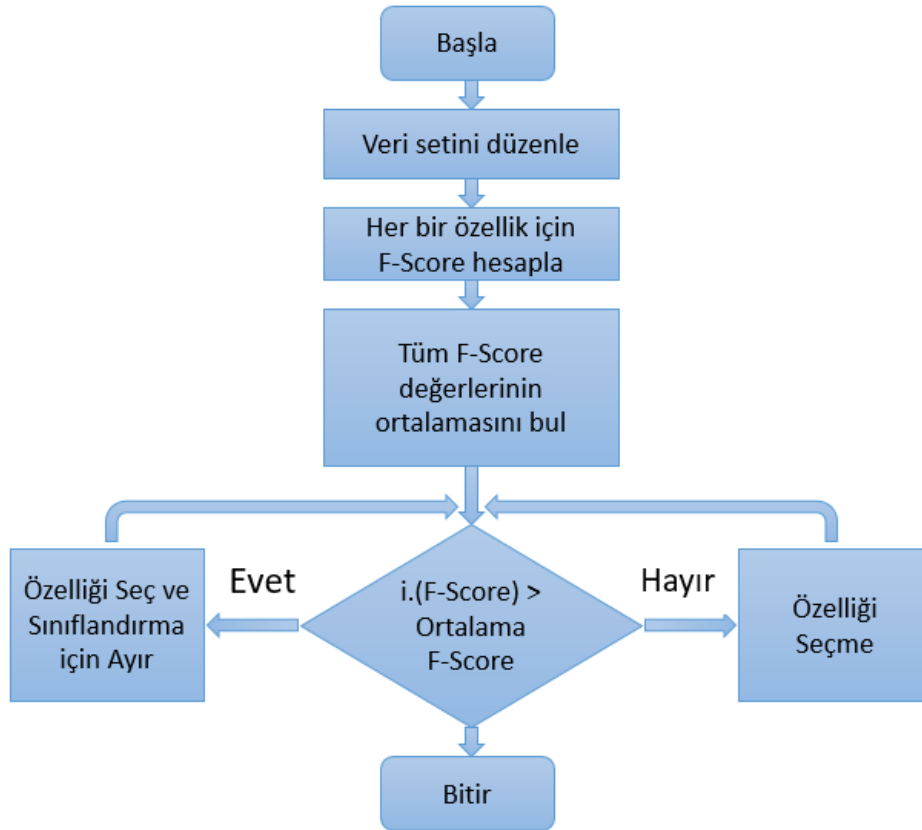
için özellikler içerisinde etkisi yüksek olan özellikleri seçecek algoritmalar geliştirilmiştir [21]. Bu çalışmada Kernel F-Score özellik seçme algoritması kullanılmıştır [16]. F-Score değerlerinin hesaplanmasında kullanılan genel formül Denklem 1’de gösterilmiştir. Burada \bar{x}_i^+ birinci sınıfın i. özelliğinin ortalaması, \bar{x}_i^- ikinci sınıfın i. özelliğinin ortalaması ve \bar{x}_i de tüm sınıfların, i. özelliğinin ortalaması olarak ifade edilmiştir.

$$F_{(i)} = \frac{(\bar{x}_i^+ - \bar{x}_i)^2 + (\bar{x}_i^- - \bar{x}_i)^2}{\frac{1}{n_+ - 1} \sum_{k=1}^{n_+} (x_{k,i}^+ - \bar{x}_i^+)^2 + \frac{1}{n_- - 1} \sum_{k=1}^{n_-} (x_{k,i}^- - \bar{x}_i^-)^2} \quad (1)$$

Denklem 1, iki sınıf içerdiği için yatay kanaldan gelen özellikleri sınıflandırmak için yeterlidir. Fakat çalışmada dikey kanalda üç sınıf bulunduğu için, denklem Denklem 2 şeklinde revize edilmiştir.

$$F_{(i)} = \frac{(\bar{x}_i^a - \bar{x}_i)^2 + (\bar{x}_i^b - \bar{x}_i)^2 + (\bar{x}_i^c - \bar{x}_i)^2}{\frac{1}{n_a - 1} \sum_{k=1}^{n_a} (x_{k,i}^a - \bar{x}_i^a)^2 + \frac{1}{n_b - 1} \sum_{k=1}^{n_b} (x_{k,i}^b - \bar{x}_i^b)^2 + \frac{1}{n_c - 1} \sum_{k=1}^{n_c} (x_{k,i}^c - \bar{x}_i^c)^2} \quad (2)$$

Denklemler ile özelliklere ait F-Score değerleri hesaplanmıştır ve Şekil 5’de görülen F-Score özellik seçme algoritması ile özellikler seçilmiştir [16].



Şekil 5 F-Score algoritması

Bu aşamadan sonra, 22 adet özellik içerisinde, Minimum, Ortalama, Maksimum, Ortanca, Harmonik Ortalama, Çarpıklık, T25 ve T50 özellikleri seçilmiştir ve Şekil 6’deki gibi tanımlanmıştır.

9x1158 double					
	1	2	3	4	5
1	0.1013	-0.4074	0.0967	Minimum	
2	0.3665	-0.3590	0.3608	Ortalama	
3	0.4141	-0.1407	0.4210	Maksimum	
4	0.3892	-0.3735	0.3761	Medyan	
5	0.3400	-0.3463	0.3394	Harmonik Ortalama	
6	-2.5323	2.2910	-2.4086	Çarpıklık	
7	0.3850	-0.3712	0.3742	T25	
8	0.3876	-0.3736	0.3757	T50	
9	1	-1	1	Sınıf Bilgisi	
10					

Name	Value	Size
input	8x1158 double	8x1158
target	1x1158 double	1x1158

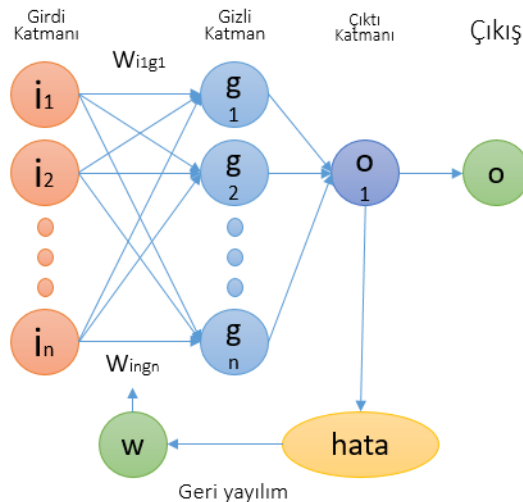
Workspace		
Name	Value	Size
input	8x1606 double	8x1606
target	1x1606 double	1x1606

Şekil 6 Özellik Azaltılmış Yatay ve Düşey Özellik Matrisleri

2.3. Yapay Sinir Ağı (YSA) ve Sınıflandırma

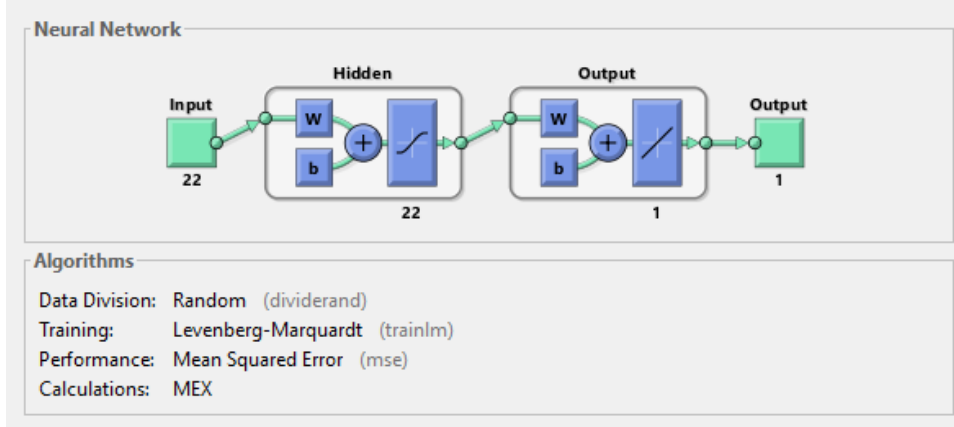
İlk olarak 1940'lı yılların başında Warren McCulloch ve W.A Pitts tarafından ortaya atılan, İnsan beyninden esinlenerek geliştirilmiş olan YSA, eldeki verilerden yola çıkarak genelleme yapmakta ve hiç görmediği veriler hakkında bu genellemelere göre karar verebilmektedir [22] [23].

Yapay sinir ağlarında, parametrelerin güncellenmesinde sık kullanılan yöntemlerin başında geri yayılma algoritmaları gelmektedir. Genelleştirilmiş delta kuralı, geri yayımlı ağ eğitilirken hedef değerler ile çıkış değerleri arasındaki farkın (hata) bir kısmı, her bir eğitim hücresine geri yansıtılarak ağırlıkların hataya göre değiştirilmesini ve bu işlemin belli sayıda tekrarlanarak hatanın en küçük değere ulaşmasını sağlayan bir yöntemdir [24]. Geri yayımlı yapay sinir ağı, çıkış "o", girişler "i" olarak uyarlandığında Şekil 7'deki gibi tanımlanır.



Şekil 7 Geri Yayımlı Yapay Sinir Ağı

Çalışmada Levenberg-Marquardt geri yayılım algoritması kullanılmıştır. Sınıflandırma işlemi Matlab ortamında YSA kodları kullanılarak yapılmıştır. Ağın oluşturulması sırasında bir adet gizli katman oluşturulmuştur. Giriş katmanı ve gizli katmandaki nöron sayısı özellik sayısı ile eşit seçilmiştir. Giriş ve hedef verileri girilmiş, eğitim fonksiyonu olarak Levenberg-Marquardt backpropagation seçilmiş, eğitim, doğrulama ve test için veriler Tablo 3’de gösterildiği gibi %70, %15 ve %15 oranında bölünmüş ve rassal olarak seçilmiştir. Performans fonksiyonu olarak mean square error (mse) seçilmiştir. Ağa ait bilgiler Şekil 8’de gösterilmiştir.

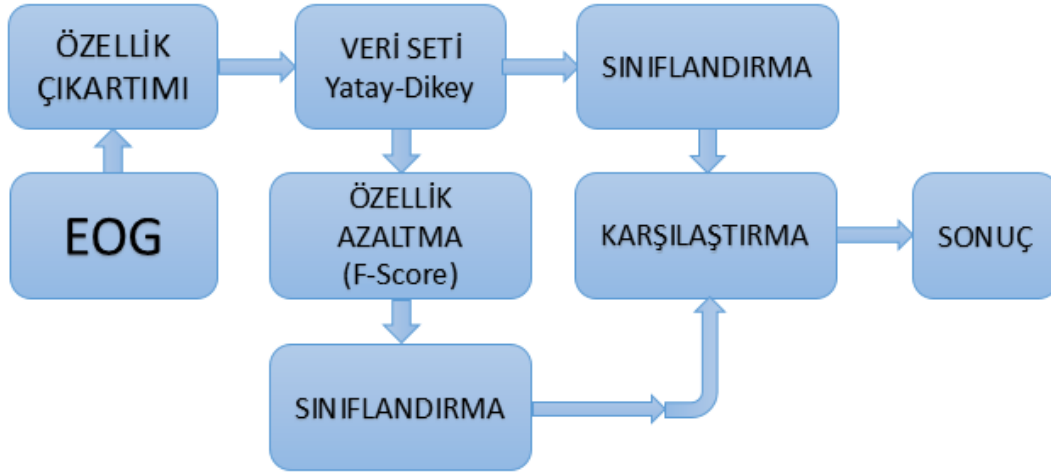


Şekil 8 Çalışmada Kullanılan Ağın Yapısı

Tablo 3 Kesitlerin % Dağılımları

	Kesit Sayısı	
Eğitim (%70)	Sağ	404
	Sol	406
	Alt	433
	Üst	416
	Göz Kırpma	273
Test (%15)	Sağ	87
	Sol	87
	Alt	93
	Üst	90
	Göz Kırpma	59
Doğrulama (%15)	Sağ	87
	Sol	87
	Alt	93
	Üst	93
	Göz Kırpma	59

Sınıflandırma işlemi için işlem basamakları Şekil 9’daki akış diyagramında gösterilmiştir. Diyagrama göre alınan EOG sinyallerden özellik çıkarım işlemleri gerçekleştirilmiştir. Ardından YSA ile veriler çıkartılan özellikler kullanılarak sınıflandırılmıştır. Sınıflandırmanın ardından özellikler azaltılarak tekrar sınıflandırılmış ve sonuçlar karşılaştırılmıştır.



Şekil 9 Akış Diyagramı

Sınıflandırma sonuçları karmaşıklık matrisiyle ifade edilmiştir ve performans değerlendirmesi için Duyarlılık, Özgüllük ve Doğruluk oranı değerleri hesaplanmış ve aşağıdaki Tablolarda sunulmuştur [25]-[28].

3. Sonuçlar

Bu çalışmanın amacı ALS hastalarının hayatlarını kolaylaştırabilmek adına EOG tabanlı kontrol sistemi tasarlamaktır. Bunun için bir erkek bireyden alınan EOG kayıtları ile birlikte 5 farklı komut verebilen sistem tasarımı yapılmıştır. Erkek bireyden alınan EOG sinyalleri 5 farklı komut (göz hareketleri: aşağı, yukarı, sağ, sol ve göz kırpması) ile etiketlenmiştir. Toplamda 2,764 adet etiketli sinyal parçası elde edilmiştir. EOG sinyalinden zaman domeninde özellikler çıkarılmış ve daha sonra özellik seçilerek sınıflandırma işlemleri yapılmıştır.

Çalışma sonucunda elde edilen sonuçlar karmaşıklık matrisi halinde Tablo 4-5’de verilmiştir.

Tablo 4 Yatay İşaretlerin Karmaşıklık Matrisi

22 Özellik				8 Özellik			
		Tahmin Edilen Değer				Tahmin Edilen Değer	
		Sol	Sağ			Sol	Sağ
Gerçek Değer	Sol	579	1	Gerçek Değer	Sol	579	1
	Sağ	0	578		Sağ	1	577

Tablo 5 Dikey İşaretlerin Karmaşıklık Matrisi

22 Özellik					8 Özellik				
		Tahmin Edilen Değer					Tahmin Edilen Değer		
		Aşağı	Yukarı	G.Kırpma			Aşağı	Yukarı	G.Kırpma
Gerçek Değer	Aşağı	619	0	0	Gerçek Değer	Aşağı	617	2	0
	Yukarı	0	581	15		Yukarı	7	561	28
	G.Kırpma	1	10	380		G.Kırpma	0	29	372

Performans değerlendirme sonuçları ise Tablo 6-7’de verilmiştir.

Tablo 6 Yatay İşaretler için Performans Çıktıları

22 Özellik				8 Özellik			
	Duyarlılık	Özgüllük	Doğruluk		Duyarlılık	Özgüllük	Doğruluk
Sol	1	0.9983	0.9991	Sol	0.9983	0.9983	0.9983
Sağ	0.9983	1	0.9991	Sağ	0.9983	0.9983	0.9983

Tablo 7 Dikey İşaretler için Performans Çıktıları

22 Özellik				8 Özellik			
	Duyarlılık	Özgüllük	Doğruluk		Duyarlılık	Özgüllük	Doğruluk
Aşağı	1	0.999	0.9994	Aşağı	0.9968	0.9929	0.9944
Yukarı	0.9748	0.9901	0.9844	Yukarı	0.9413	0.9792	0.9651
Göz kırpma	0.9719	0.9877	0.9938	Göz kırpma	0.9514	0.9770	0.9707

Özellik seçme algoritması ile başlangıca göre seçilen özellik sayısı %60 oranında azaltılırken, sınıflandırma sonuçlarının %1 ile %5 arasında olumsuz etkilendiği gözlemlenmiştir. Genel doğruluk oranları açısından değerlendirildiğinde, yatay kanalın performans değerlerinde belirgin bir etkilenme görülmezken, dikey kanalın performansı %99 seviyelerinden %97 seviyelerine gerilemiştir.

Buna göre EOG işaretlerinin İMA olarak kullanılabilmesi için 22 adet özellik içerisinde, Minimum, Ortalama, Maksimum, Ortanca, Harmonik Ortalama, Çarpıklık, T25 ve T50 özellikleri ile sınıflandırılmasının uygun olduğu kanaatine varılmıştır.

Özellik seçme algoritmaları makine öğrenmesinin önemli bir parçasıdır. Bu algoritmaların öğrenme süresini kısaltması ve özellik sayısını minimuma indirmesi istenir [14] [16] [21] [26]. Çalışmada elde edilen sonuçlar literatür ile uyum içerisindedir.

Elde edilen sonuçlara göre ALS hastalarının hayatlarının kolaylaştırabilmek adına EOG tabanlı ve gerçek zamanlı çalışan sistemler tasarlanırken bu çalışmada seçilen özelliklerin kullanılabilmesi düşünülmektedir. Çalışmanın geliştirilmesi için zaman domeni özellikleri ile beraber frekans domeni özellikleri de kullanılarak çalışma tekrarlanabilir.

Referanslar

- [1] T. Öztürk, "Hawking'in Konuşma Cihazı ve P300 - Toprak Öztürk - Medium," 2018. [Online]. Available: <https://medium.com/@toprakozt/hawkingin-konusma-cihazı-ve-p300-b38f938733dd>. [Accessed: 13-Dec-2019].
- [2] Tobii, "Tobii Eye Tracker 4C for PC Gaming. Buy Now at €169 - Tobii Gaming," 2019. [Online]. Available: <https://gaming.tobii.com/tobii-eye-tracker-4c/>. [Accessed: 13-Dec-2019].
- [3] J.-S. Lin and W.-C. Yang, "Wireless brain-computer interface for electric wheelchairs with EEG and eye-blinking signals," *Int J Innov Comput Inf Control*, vol. 8, pp. 6011–6024, Sep. 2012.
- [4] A. B. Usakli and S. Gurkan, "Design of a novel efficient humancomputer interface: An

- electrooculagram based virtual keyboard,” *IEEE Trans. Instrum. Meas.*, vol. 59, no. 8, pp. 2099–2108, Aug. 2010.
- [5] M. Y. Esas and F. Latifoglu, “Computer-Based design with dual channel device electrooculography and eye movement tracking,” in *2015 Medical Technologies National Conference (TIPTEKNO)*, 2015, pp. 1–4.
- [6] J. Heo, H. Yoon, and K. Park, “A Novel Wearable Forehead EOG Measurement System for Human Computer Interfaces,” *Sensors*, vol. 17, no. 7, p. 1485, Jun. 2017.
- [7] S. Gül, Z. Tiryaki, E. Kuzu, M. Milligüney, and G. Çetinel, “Move Your Wheelchair with Your Eyes,” *Int. J. Appl. Math. Electron. Comput.*, vol. 1, no. SpecialIssue, pp. 5–8, Aug. 2017.
- [8] H. Ö. Ülkütaş, “Eog’nin Kodlanmasına Dayanan Bilgisayar Tabanlı Gözle Yazı Yazma Sistemi Geliştirilmesi,” *Başkent Üniversitesi*, 2015.
- [9] M. K. Uçar, K. Polat, M. R. Bozkurt, and C. Bilgin, “Effect of Time and Frequency Domain Features in Sleep Eeg and Eog Signals Classification,” in *Tip Teknolojileri ulusal Kongresi*, 2014, vol. 1, pp. 0–5.
- [10] G. Gündüz and İ. H. Cedimoğlu, “Derin Öğrenme Algoritmalarını Kullanarak Görüntüden Cinsiyet Tahmini,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 2, no. 1, pp. 9–17, Apr. 2019.
- [11] K. Serbest, M. R. Bozkurt, and O. Eldoğan, “Classification of cardiac arrhythmias with artificial neural networks according to gender differences,” *J. Eng. Sci. Technol.*, vol. 10, no. 9, pp. 1144–1149, 2015.
- [12] G. D. Çetin, Ö. Çetin, and M. R. Bozkurt, “The Detection of Normal and Epileptic EEG Signals using ANN Methods with Matlab-based GUI,” *Int. J. Comput. Appl.*, vol. 114, no. 12, pp. 45–50, 2015.
- [13] M. R. Bozkurt, A. Subaşı, E. Köklükaya, and M. Yılmaz, “Comparison of AR parametric methods with subspace-based methods for EMG signal classification using stand-alone and merged neural network models,” *Turkish J. Electr. Eng. Comput. Sci.*, vol. 24, no. 3, pp. 1547–1559, 2016.
- [14] M. R. Bozkurt, M. K. Uçar, F. Bozkurt, and C. Bilgin, “In obstructive sleep apnea patients, automatic determination of respiratory arrests by photoplethysmography signal and heart rate variability,” *Australas. Phys. Eng. Sci. Med.*, pp. 1–21, 2019.
- [15] M. K. Uçar, M. R. Bozkurt, K. Polat, and C. Bilgin, “Investigation of effects of time domain features of the photoplethysmography (PPG) signal on sleep respiratory arrests,” in *2015 23rd Signal Processing and Communications Applications Conference (SIU)*, 2015, pp. 124–127.

- [16] K. Polat and S. Güneş, “A new feature selection method on classification of medical datasets: Kernel F-score feature selection,” *Expert Syst. Appl.*, vol. 36, no. 7, pp. 10367–10373, Sep. 2009.
- [17] A. R. Kavsaoğlu, K. Polat, and M. R. Bozkurt, “An innovative peak detection algorithm for photoplethysmography signals: an adaptive segmentation method,” *Turkish J. Electr. Eng. Comput. Sci.*, vol. 24, no. 3, pp. 1782–1796, 2016.
- [18] V. Gerla *et al.*, “Automatic identification of artifacts and unwanted physiologic signals in EEG and EOG during wakefulness,” *Biomed. Signal Process. Control*, vol. 31, pp. 381–390, 2017.
- [19] J. G. Colonna, M. Cristo, M. Salvatierra, and E. F. Nakamura, “An incremental technique for real-time bioacoustic signal segmentation,” *Expert Syst. Appl.*, vol. 42, no. 21, pp. 7367–7374, Nov. 2015.
- [20] N. A. B. Baharom, “Analysis of Electrooculography (Eog) for Controlling Wheelchair Motion.” 2015.
- [21] M. K. Uçar, “Eta Correlation Coefficient Based Feature Selection Algorithm for Machine Learning: E-Score Feature Selection Algorithm,” *Zeki Sist. Teor. ve Uygulamaları Derg.*, vol. 2, no. 1, pp. 7–12, 2019.
- [22] E. Şahin, “Makine Öğrenme Yöntemleri ve Kelime Kümesi Tekniği ile İstenmeyen e-Postasınıflandırması,” Hacettepe Üniversitesi, 2018.
- [23] J. B. Ahire, “The Artificial Neural Networks Handbook: Part 4,” 2018. [Online]. Available: <https://medium.com/@jayeshbahire/the-artificial-neural-networks-handbook-part-4-d2087d1f583e>. [Accessed: 17-Nov-2019].
- [24] M. Tosun, M. Erginli, Ö. Kasım, B. Uğraş, Ş. Tanrıverdi, and T. Kavak, “EEG Verileri Kullanılarak Fiziksel El Hareketleri ve Bu Hareketlerin Hayalinin Yapay Sinir Ağları İle Sınıflandırılması,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 1, no. 2, pp. 1–9, Aug. 2018.
- [25] C. Beleites, R. Salzer, and V. Sergo, “Validation of Soft Classification Models using Partial Class Memberships: An Extended Concept of Sensitivity & Co. applied to the Grading of Astrocytoma Tissues,” Jan. 2013.
- [26] M. Gök, “Makine Öğrenmesi Yöntemleri ile Akademik Başarının Tahmin Edilmesi,” *Gazi Üniversitesi Fen Bilim. Derg. Part C Tasarım ve Teknol.*, vol. 5, no. 3, pp. 139–148, Sep. 2017.
- [27] A. Dirican, “Tani Testi Performanslarının Değerlendirilmesi Ve Kiyaslanması,” *Cerrahpaşa Tıp Derg.*, vol. 32, no. 1, 2001.
- [28] L. H. Geyer and C. G. DeWald, “Feature lists and confusion matrices,” *Percept. Psychophys.*, vol. 14, no. 3, pp. 471–482, Oct. 1973.