

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

İlhan ZENGİN

05 / 08 / 2020

TEŐEKKÜR

Yüksek lisans eğitiminin boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Doç. Dr. Mehmet Recep BOZKURT'a teşekkürlerimi sunarım.

Laboratuvar olanakları konusunda anlayış ve yardımlarını esirgemeyen Dr.Öğr.Üyesi Muhammed Kürşad UÇAR'a teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	vii
ÖZET	viii
SUMMARY	ix
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
KAYNAK ARAŞTIRMASI	3
2.1. Kasların Kontrol Edilmediği Hastalıklar ve Özellikleri	3
2.1.1. Amyotrofik lateral skleroz (ALS)	3
2.1.2. İnme (Felç)	3
2.1.3. Locked-in sendromu	3
2.1.4. Serebral palsi (SP)	4
2.1.5. Multiple skleroz (MS)	4
2.2. Gözün Fizyolojik Yapısı ve Elektrokülogram	4
2.3. Makine Öğrenmesi ve Özellik Seçme Algoritmaları	6
2.3.1. Özellik seçimi genel adımları.....	8
2.3.2. Kernel f-skor özellik seçme yöntemi.....	8

BÖLÜM 3.

MATERYAL VE YÖNTEM	10
3.1. Materyal	10
3.1.1. Kullanılan araç-gereçler	10
3.2. Yöntem	10
3.2.1. Sinyal işleme	10
3.2.2. Özellik çıkartımı	11
3.2.3. Özellik azaltımı	13
3.2.4. Sınıflandırma	15
3.3. Analizler	17

BÖLÜM 4.

ARAŞTIRMA BULGULARI	20
---------------------------	----

BÖLÜM 5.

TARTIŞMA VE SONUÇ	23
-------------------------	----

KAYNAKLAR	25
-----------------	----

ÖZGEÇMİŞ	29
----------------	----

SİMGELER VE KISALTMALAR LİSTESİ

A	: Varyans
ALS	: Amyotrofik Lateral Skleroz
ANN	: Artificial Neural Network
CM	: Merkezi Moment
DK	: Varyasyon Katsayısı
E	: Ortalama enerji
EOG	: Elektrokülogram
$F_{(t)}$: F-Score fonksiyonu
G	: Geometrik ortalama
GN	: Tanı testinin sağlam dediği, doğru tahminler
GP	: Tanı testinin hasta dediği, doğru tahminler
H	: Harmonik ortalama
HMI	: Human Machine Interface
IQR	: Çeyrekler açıklığı
İMA	: İnsan Makine Arabirimi
k-NN	: K en yakın komşu algoritması
MAD	: Ortalama Mutlak Sapma
S	: Standart sapma
$S_{\bar{x}}$: Standart hata
SF	: Şekil faktörü
SVD	: Tekil Değer Ayırıştırması
T25	: %25 Kırpılmış ortalama
T50	: %50 Kırpılmış ortalama
\tilde{x}	: Ortanca
\bar{x}	: Ortalama
x_{kur}	: Basıklık

x_{ske}	: Çarpıklık
x_{rms}	: Karekök ortalama
x_{max}	: Maksimum
x_{min}	: Minimum
\bar{x}_i^+	: Birinci sınıfın i. özelliğinin ortalaması
\bar{x}_i^-	: İkinci sınıfın i. özelliğinin ortalaması
\bar{x}_i^a	: a sınıfının i. özelliğinin ortalaması
\bar{x}_i^b	: b sınıfının i. özelliğinin ortalaması
\bar{x}_i^c	: c sınıfının i. özelliğinin ortalaması
\bar{x}_i	: Tüm sınıfların i. özelliğinin ortalaması
YN	: Tanı testinin sağlam dediği, hatalı tahminler
YP	: Tanı testinin hasta dediği, hatalı tahminler
YSA	: Yapay Sinir Ağları

ŞEKİLLER LİSTESİ

Şekil 2.1. Göz kasları	5
Şekil 2.2. EOG işaretleri	5
Şekil 2.3. EOG elektrot yerleşimi	6
Şekil 2.4. Makine öğrenmesi çeşitleri	6
Şekil 2.5. Makine öğrenme algoritmaları	7
Şekil 2.6. Özellik seçimi genel akış şeması.....	8
Şekil 3.1. Ölçüm elektrodlarının yerleşimi	11
Şekil 3.2. Sinyallerin kesitlenmesi	11
Şekil 3.3. F-Score algoritması	14
Şekil 3.4. Yapay sinir ağı yapısı	15
Şekil 3.5. Geri yayımlı yapay sinir ağı yapısı	16
Şekil 3.6. Akış diagramı	17

TABLULAR LİSTESİ

Tablo 3.1. Kesitlerin dağılım tablosu	11
Tablo 3.2. Özellik çıkarma tablosu	12
Tablo 3.3. İşaret sürelerinin de eklenmesiyle oluşan 22 adet özelliğin listesi.....	13
Tablo 3.4. Seçilen özellikler	14
Tablo 3.5. Yatay işaretlerin % dağılımı	16
Tablo 3.6. Dikey işaretlerin % dağılımı	16
Tablo 3.7. Tanı testi karmaşıklık matrisi	17
Tablo 3.8. 3x3 boyurnda karmaşıklık matrisi	19
Tablo 3.9. 2x2 boyutuna dönüştürülmüş karmaşıklık matrisleri	19
Tablo 4.1. Yatay işaretlere ait 22 özelliğin sınıflandırma sonucu	20
Tablo 4.2. Yatay işaretlere ait 8 özelliğin sınıflandırma sonucu	20
Tablo 4.3. Dikey işaretlere ait 22 özelliğin sınıflandırma sonucu	20
Tablo 4.4. Dikey işaretlere ait 8 özelliğin sınıflandırma sonucu	21
Tablo 4.5. Yatay işaretlere ait 22 özelliğin sınıflandırma performansı	21
Tablo 4.6 Yatay işaretlere ait 8 özelliğin sınıflandırma performansı	21
Tablo 4.7. Dikey işaretlere ait 22 özelliğin sınıflandırma performansı	21
Tablo 4.8. Dikey işaretlere ait 8 özelliğin sınıflandırma performansı	21

ÖZET

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

Bu çalışmada, İnsan Makine Arabirimi (İMA), kullanılmak üzere Elektrokülogram (EOG) sinyalinden, kaynak işaret üretimi gerçekleştirilmiştir. EOG, insan gözünü hareket ettiren kasların hareketlerini ölçmek için kullanılan bir tekniktir. EOG ölçümleri, erkek bir bireyden alınmıştır. Alınan işaretler Matlab kullanılarak ön işleme tabi tutulmuştur ve öznelikleri çıkarılacak hale getirilmiştir.

EOG sinyallerinden özellikler çıkarılmıştır ve kontrol edilecek sisteme göre etiketlenmiştir. Bu etiketler yatayda sağ ve sol, dikeyde ise yukarı, aşağı ve göz kırpması olacak şekilde oluşturulmuştur. Özellikler Yapay Sinir Ağları (YSA), kullanılarak sınıflandırma işlemine tabi tutulmuştur. Özellik azaltma algoritmaları kullanılarak sonuç üzerinde etkisi az olan özellikler çıkarılmış ve elde edilen özelliklerle sınıflandırma başarıları test edilmiştir.

Özellik seçme algoritması ile başlangıca göre seçilen özellik sayısı %60 oranında azaltılarak, 22 adet özellik içerisinde, Minimum, Ortalama, Maksimum, Ortanca, Harmonik Ortalama, Çarpıklık, T25 ve T50 özellikleri elde edilmiştir. Elde edilen bu özelliklerin sınıflandırma performansları %91 ile %100 arasında dağılım göstermiştir. Literatürde yapılan benzer çalışmalarda elde edilen %91, %95 ve %98.7 sınıflandırma performansları ile kıyaslandığında bu çalışmada elde edilen özelliklerin de İMA'da kullanılabileceği düşünülmektedir.

PROCESSING AND CLASSIFICATION OF ELECTROOCULOGRAM SIGN FOR HUMAN MACHINE INTERFACE

SUMMARY

Keywords: Feature reduction, Artificial Neural Networks (ANN), Human Machine Interface (IMA), Electrooculogram (EOG)

In this study, the source signal was generated from the Electrooculogram (EOG) signal to be used with the Human Machine Interface (IMA). EOG is a technique used to measure the movements of the muscles that move the human eye. EOG measurements were taken from a male individual. The received marks were pre-processed using Matlab and their attributes were made to be extracted.

Features extracted from the EOG signals and labeled according to the system to be controlled. These labels were created horizontally on the right and left, on the vertical, up, down and winking. Features have been subjected to the classification process using Artificial Neural Networks (ANN). By using feature reduction algorithms, features that have little effect on the result were extracted and the classification success was tested with the obtained features.

With the feature selection algorithm, the number of features selected according to the beginning was reduced by 60%, and among 22 features, Minimum, Average, Maximum, Median, Harmonic Mean, Skewness, T25 and T50 properties were obtained. The classification performances of these properties varied between 91% and 100%. When compared with the 91%, 95% and 98.7% classification performances obtained in similar studies in the literature, it is thought that the features obtained in this study can also be used in IMA.

BÖLÜM 1. GİRİŞ

Amyotrofik Lateral Skleroz (ALS), felç ve benzeri hastalıklar, insanların el ve ayaklarında bazı temel motor becerilerini kaybetmesine sebep olmaktadır [1]. Bu hastalıkları olan kişilerin, gözlerinin kontrolünü nadiren kaybettikleri bilgisine dayalı olarak [2], çevreleri ile iletişimi sağlamak ve hayatlarını kolaylaştırmak için çeşitli sistemler önerilmiştir [1]. ALS, felç ve benzeri hastalıkları olan kişiler, gözlerinin kontrolünü nadiren kaybederler. Bu nedenle, Elektrokülogram (EOG) sinyalleri vasıtasıyla kontrol edilen insan makine arabirimi (İMA), bu hastalar için bir umut kaynağı olarak ortaya çıkmıştır [2]. Literatürde, EOG ile İMA'ya yönelik çalışmalar bulunmaktadır.

Örneğin, ALS hastalığına sahip ünlü bilim insanı Stephen Hawking'in kullandığı, bilgisayar destekli tekerlekli bir sandalyeydi. Bu sandalyedeki sistem, Hawking'in yanağında aktif halde bulunan bir kastan alınan işareti, bilgisayar ekranında bir fare imleci olarak kullanmasına olanak sağlamaktaydı [3]. Örneğin başka bir çalışmada, Elektroensefalografi ve EOG sinyallerini ortak değerlendirerek bir tekerlekli sandalye kontrol edilmeye çalışılmıştır [4]. Başka bir çalışmada, yazarlar EOG sinyalleri ile sanal bir klavyeyi kullanmaya çalışmışlardır [5]. Bu çalışmada EOG sinyalleri, k en yakın komşuluk algoritması (k-NN) yaklaşımı ile %95 doğruluk oranında sınıflandırmıştır. Bir diğer örnekte, EOG sinyallerinden yararlanarak göz takip cihazı üzerine bir çalışma yapılmıştır [6]. Bu çalışmada EOG sinyallerini sadece genlik değerlerine göre sınıflandırma işlemi yapılmıştır. Bir başka örnekte, ölçümleri alın bölgesinden yapabilen giyilebilir bir alın bandı yapısında bir EOG sistemi tasarlanmıştır [7]. Bu çalışmada EOG sinyalleri karar ağaçları yöntemiyle %91 doğruluk oranında sınıflandırılmıştır. Bir diğer örnekte EOG sinyalleri ile kontrol edilebilen bir tekerlekli sandalye sistemi tasarlanmıştır [8]. Bu çalışmada

EOG sinyalleri, k-NN yaklaşımı ile %98.7 doğruluk oranında sınıflandırmıştır. Bir başka örnekte, EOG tabanlı gözle yazı yazma sistemi geliştirilmiştir [2].

Gözlerden alınan biyolojik işaretlerin insan makine arabirimi için işlenmesi, kontrol edilecek sisteme göre EOG işaretinin uygun şekilde etiketlenmesidir [9]. Bu işlem için çeşitli yöntemler önerilmiştir [6] [7] [8].

Bu çalışmada, EOG sinyallerinden zaman domeninde (ZD) özellik çıkarımı yapılmış ve özelliklerin ağırlıkları belirlenip, özellik azaltımı yöntemleri kullanılarak sınıflandırma başarımları test edilmiştir. EOG sinyalleri beş farklı şekilde etiketlenmiştir. Bunlar sağ, sol, yukarı, aşağı ve göz kırpmasıdır. Zaman domeninde, EOG'den özellikler çıkarılmıştır [10]. Daha sonra F-Score ile kullanılan özellik sayısı azaltılmıştır [11].

Çalışmanın ana hatları maddeler halinde aşağıdaki gibi verilmiştir.

- a. Giriş bölümünde; teze konu olan çalışma ana hatlarıyla özetlenmiş ve tezin yapısı hakkında özet bilgiler verilmiştir.
- b. İkinci bölümde; teze konu olan hastalıklar, insan makine arabirimi, EOG, gözün fizyolojik yapısı, özellik seçme algoritmaları ve makine öğrenmesi hakkında bilgiler verilmiştir.
- c. Üçüncü bölümde; tez kapsamında kullanılan materyaller ve uygulanan yöntemler hakkında bilgiler verilmiştir.
- d. Dördüncü bölümde; yapılan çalışmalar sonucunda elde edilen bulgular sunulmuştur.
- e. Beşinci bölümde; elde edilen bulgular tartışılmıştır ve çalışmanın sonuçları sunulmuştur.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

Bu bölümde teze konu olan hastalıklar, insan makine arabirimi, EOG, gözün fizyolojik yapısı, özellik seçme algoritmaları ve makine öğrenmesi hakkında bilgiler verilmiştir.

2.1. Kasların Kontrol Edilemediği Hastalıklar

İnsanların yüz, el veya ayaklarında olmak üzere bazı temel motor becerileri kaybetmesine sebep olan ve çevresi ile iletişimini konuşarak veya işaret diliyle sağlayamayan hastaların sahip oldukları hastalıklardan bazıları hakkında genel bilgiler verilmiştir.

2.1.1. Amyotrofik lateral skleroz (ALS)

Amyotrofik Lateral Skleroz (ALS) hastalığı, nörolog Jean-Martin Charcot tarafından 1869 yılında tanımlanmıştır. ALS, motor nöronlarla ilgili bir hastalıktır. Üst ve alt motor nöronda gözlemlenen bulguların birleşimi tanıyı netleştirmektedir [12].

2.1.2. İnme (Felç)

Sinir sistemin hastalıklarında, vücudun bir bölümünde kas kuvvetinin azalması veya tamâmen kaybı, en sık görülen belirtilerdir. Kas zaafı tespit edilen bir hastada, sinir sisteminin; motor nöron, sinir-kas bağlantısı veya doğrudan çizgili kas yapısındaki bozulmalardan kaynaklı olabilir [13].

2.1.3. Locked-in sendromu

Locked-in sendromu, beyin sapındaki sinirlerin hasarlanması sonucu sırasıyla ön ve

arka bacakların birlikte felci ve dil tutukluğunun bir arada gözlenmesi olarak tanımlanmıştır. Hastanın bilinci yerinde olmasına rağmen bedenen neredeyse tamamen felç halinde olması ve bundan dolayı kendini dil veya hareketlerle ifade edememesi durumuna denir [2].

2.1.4. Serebral palsy (SP)

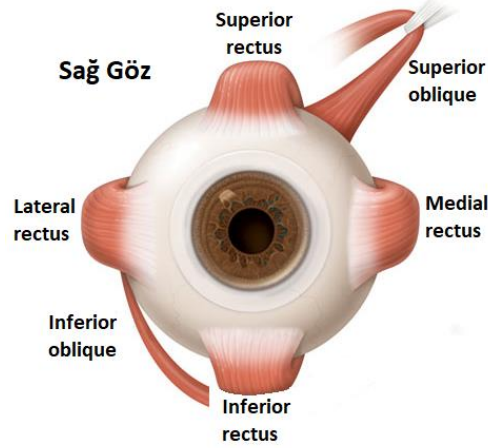
Serebral palsy, 0-6 yaş döneminde, gelişmekte olan beyinde kalıcı bir hasarla meydana gelen motor bozukluğu ifade eder. Omurilik ve kasların yapısı normaldir. Hasar sonucu kol, bacak ve gövdede ilerleyici olmayan motor bozukluk oluşur. Bunun sonucunda hareket ve duruş etkilenir; ayrıca görme, konuşma ve yutma işlevlerinde de sorun yaşanır. İlerleyen zamanlarda edinilen yeni motor becerilerde, hareket bozukluğunun biçimi değişmeye eğilimlidir [14].

2.1.5. Multiple skleroz (MS)

Multiple Skleroz (MS), bağışıklık sistemi hücrelerinin beyin ve omurilikte yanlış çalışması sonucu oluşan nörolojik bir hastalıktır. Beyin ve omurilikteki hücrelerin (nöronların) sinir kılıfları hasar görmektedir. Bunun sonucunda nöronlar işlevlerini doğru şekilde yerine getiremezler. Kişinin görme, konuşma, yürüme gibi fonksiyonları üzerinde kontrol kabiliyeti bozulur [2].


2.2. Gözün Fizyolojik Yapısı ve Elektrokülogram

Göz hareketleri, medial - lateral rektus, superior - inferior rektus, superior - inferior oblique kasları olmak üzere üç ayrı kas çiftiyle kontrol edilmektedir (Şekil 2.1.). Medial – lateral rectus çifti kasılarak göz küresini sağ veya sol yönlü hareket ettirir. Benzer şekilde, superior – inferior rectus çifti kasılarak göz küresini yukarı veya aşağı yönlü hareket ettirir. Öte yandan, superior – inferior oblique çifti ise karşılıklı kasılarak göz küresini döndürürler [1].

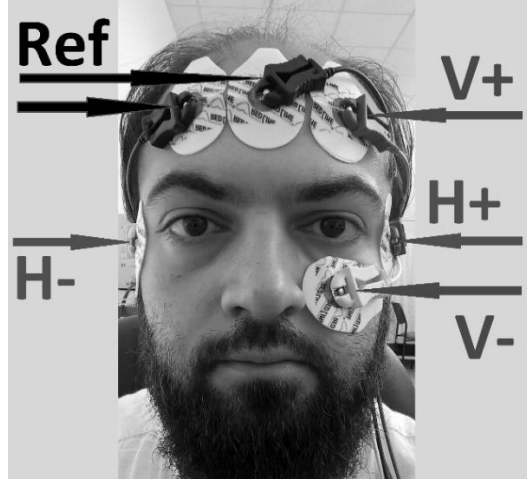


Şekil 2.1. Göz kasları [15]

EOG, insan gözünü hareket ettiren kasların hareketlerini ölçmek için kullanılan bir tekniktir. Bu teknikte, gözün hareketlerine bağımlı olarak, referans alınan bir noktaya göre ölçülmek istenen potansiyel, göz hareketleriyle orantılı bir değişim Şekil 2.2.'de gösterilmektedir. Ölçümler esnasında, dikeyde göz hareketi yapmadan, 3 kez sağa ardından 3 kez sola bakılmıştır. Ardından, yatayda göz hareketi yapılmadan 3 kez yukarı sonra da 3 kez aşağı bakılmıştır. Gözün sağa veya sola doğru olan hareketinde yatay elektrotlarda (H+ ve H-), aşağı veya yukarı hareketinde ise dikey elektrotlarda (V+ ve V-) potansiyel fark oluşur (Şekil 2.3.).




Şekil 2.2. EOG işaretleri



Şekil 2.3. EOG elektrot yerleşimi

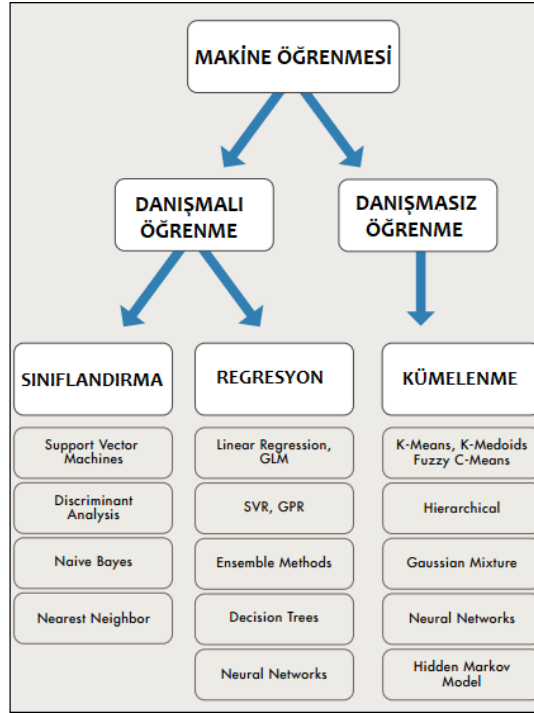
2.3. Makine Öğrenmesi ve Özellik Seçme Algoritmaları

Makine öğrenmesi, bir probleme ait verilerden yola çıkarak modelleme işlemi yapan algoritmaların genel adıdır. Genel olarak danışmalı (supervised), danışmasız (unsupervised) ve yarı danışmalı (semi-supervised) öğrenme olarak Şekil 2.4.'deki gibi 3'e ayrılırlar [16].



Şekil 2.4. Makine öğrenmesi çeşitleri

Kullanılacak veri setinin durumuna göre Şekil 2.5.'deki yöntemlerden uygun olan seçilir. Girdi yapısını keşfetmek ve öğrenmek istenilen durumlarda danışmasız öğrenme, etiketlenmemiş veriler hakkında en iyi tahminlerin yapılmak istendiği durumlarda danışmalı öğrenme yöntemleri kullanılmalıdır [16].



Şekil 2.5. Makine öğrenme algoritmaları [17]

Makine öğrenmesinde temel öge veri kümeleridir. Günümüz teknolojisi ile birlikte toplanan veri miktarları devasa miktarlara ulaşmıştır. Devasa veriler makine öğrenme sürecine bazen olumsuz etki oluşturmaktadır. Günümüz makine öğrenmesi alanındaki en büyük problemlerden biri büyük verilerin işlem süreçlerini uzatması ve performansı azaltmasıdır. Performans azalmasının sebebi ilgisiz verilerin küme içerisinde olmasıdır. Bu problemi çözebilmek için veri setleri içerisinde ilişkili özellikleri seçecek algoritmalar geliştirilmiştir. Bu algoritmalara genel olarak özellik seçme algoritmaları denir [18].

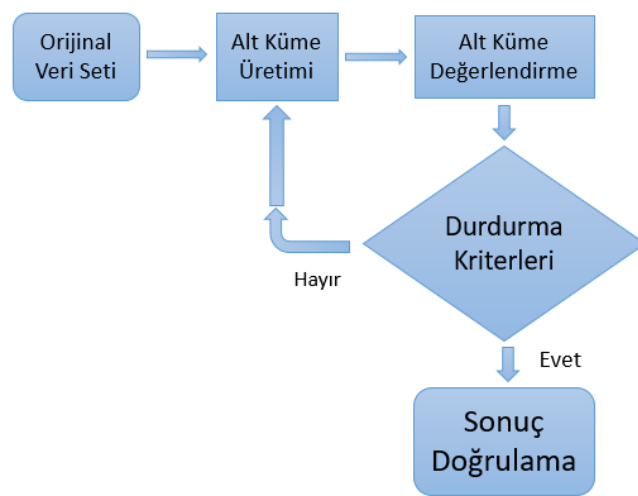
Özellik seçimi, varolan veri kümesini en iyi şekilde karşılayacak alt kümelerin ayırt edilmesi şeklinde ifade edilir [19]. Veri setinde bulunan x adet özelliğin arasından etkinliği yüksek y adet özellik, belirli bir algoritma kapsamında seçilir [20]. Özellik seçimi, ilgilenilen problem için etkinliği yüksek özellikleri seçerek özellik sayısının azaltılmasını amaçlar. Özellik sayısının azaltılması analiz sürecinde kolaylık sağlamaktadır.

Özellik seçmenin sağladığı kolaylıklar [21] :

- Özellik sayısı ve işlem süreleri azalır,
- İlgisiz ve gürültülü veriden arındırır,
- Veri kalitesini iyileştirir,
- Veri toplama işleminde kaynak tasarrufu sağlar,
- Elde edilen modelin başarısını artırır.

2.3.1. Özellik seçimi genel adımları

Özellik seçimi adımları genel olarak Şekil 2.6.'da gösterildiği gibidir. Burada öncelikle orjinal veri setinden bir alt küme oluşturulmakta ve daha sonra bu alt küme için seçilen algoritmalarla değerlendirme yapılmaktadır. Uygun görülen veya eşik değerini geçen özellikler alt kümeyle dahil edilmekte ve durdurma kriterleri sağlanana kadar süreç devam etmektedir.



Şekil 2.6. Özellik seçimi genel akış şeması [22]

2.3.2. Kernel f-skör özellik seçme yöntemi

F-Skor yöntemi, iki sınıfın ayırt edilmesini ölçen basit bir tekniktir. Bu yöntemde, veri kümesindeki her bir özelliğin f-skör değeri hesaplanır. Hesaplanan değerlerin ortalaması alınır ve bu ortalama değer özellikleri seçmek için eşik değer olarak

seçilir. Eşik değerden büyük olan özellikler seçilir ve diğerleri elenir. Fakat F-skor, değişkenler arasındaki karşılıklı bilgiyi hesaba katmaz [23]. Kernel F-Skor algoritması bu eksikliği gidermektedir [23]. Kernel F-Skor algoritması, lineer olarak ayrılamayan medikal veri kümelerini lineer olarak ayrılabilir özellik uzayına dönüştürmektedir.



BÖLÜM 3. MATERYAL VE YÖNTEM

Bu bölümde tezde kullanılan araç ve yöntemlerden bahsedilerek analizler sunulmuştur.

3.1. Materyal

Çalışmada, 30 yaşında 163 cm boyunda ve 73 kg ağırlığında bir erkekten toplamda 3 saat süreyle EOG verileri alınmıştır.

3.1.1. Kullanılan araç-gereçler

Çalışmada, Biopac MP30 veri toplama birimi, 2 adet Biopac SS2L model elektrod uç seti, Redline markasının tek kullanımlık 36-44 Pediatrik katı jelli Ag-AgCl elektrodu, Biopac Student Lab yazılımı ve bu yazılımı çalıştırabilecek bir bilgisayar kullanılmıştır.


3.2. Yöntem

Çalışmada, sinyal işleme, özellik çıkartımı, özellik azaltımı ve sınıflandırma adımları izlenmiştir.

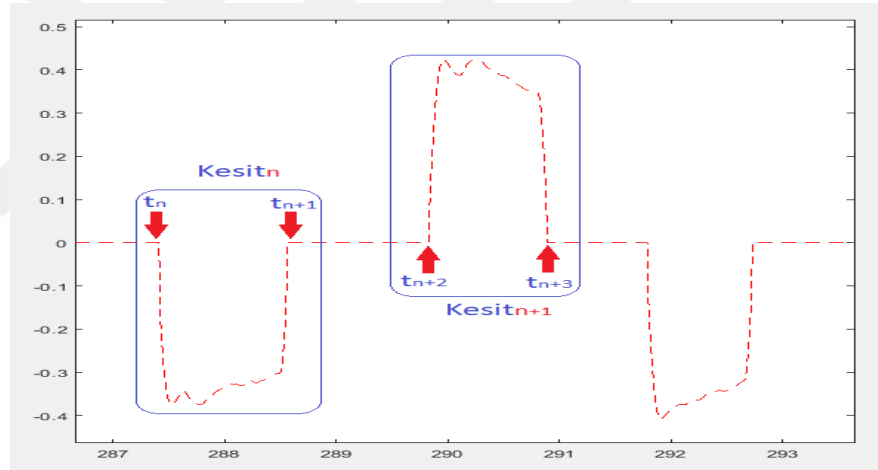
3.2.1. Sinyal işleme

Çalışmada, EOG sinyali Şekil 3.1.'deki gibi iki kanaldan kayıt edilmiştir. Referans elektrodu olarak alna yerleştirilen elektrot seçilmiştir. Alınan sinyallerin örnekleme frekansı 100Hz'dir. Bu işaretler Matlab ortamında filtrelenmiş ve özellikleri çıkarılacak kısımlar kesitlenmiştir [24] [25] [26]. Yatay göz hareketleri için 1158

adet kesit, düşey göz hareketleri içinse 1606 adet kesit, Şekil 3.2.'deki gibi elde edilmiştir ve Tablo 3.1.'de gösterilmiştir.



Şekil 3.1. Ölçüm elektrodlarının yerleşimi



Şekil 3.2. Sinyallerin kesitlenmesi

Tablo 3.1. Kesitlerin dağılım tablosu

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

3.2.2. Özellik çıkartımı

Çalışmada, EOG sinyallerinden elde edilen kesitlerin her birinden zaman domeninde Tablo 3.2.'deki 21 adet özellik çıkarımı yapılmıştır ve özellik matrisi oluşturulmuştur [10].

Tablo 3.2. 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.

Oluşturulan özellik matrisine, kesitlerin işaret süreleri de 22.satıra yeni bir özellik olarak eklenmiştir ve Tablo 3.3.'teki gibi gösterilmiştir.

Tablo 3.3. İşaret sürelerinin de eklenmesiyle oluşan 22 adet özelliğin listesi

işaret no	işaret açıklama	işaret no	işaret açıklama	işaret no	işaret açıklama	işaret no	işaret açıklama
1	Basıklık	7	Ortanca	13	Şekil Faktörü	19	Minimum
2	Çarpıklık	8	Ortalama	14	Çeyrekler Açılığı	20	Merkezi Moment
3	Varyasyon	9	Ortalama Enerji	15	%50 Kırpılmış Ortalama	21	Tekil Değer Ayırıştırması
4	Geometrik Ortalama	10	Karekök Ortalama	16	25% Kırpılmış Ortalama	22	İşaret süreleri
5	Harmonik Ortalama	11	Standart Hata	17	Maksimum	23	
6	Varyans	12	Standart Sapma	18	Ortalama Mutlak Sapma	24	

3.2.3. Özellik azaltımı

Çalışmada, Kernel F-Score özellik seçme algoritması kullanılmıştır [11]. F-Score değerleri aşağıdaki eşitlik kullanılarak (Denklem 3.1) hesaplanmıştır.

$$F_{(i)} = \frac{(\bar{x}_i^+ - \bar{x}_i)^2 + (\bar{x}_i^- - \bar{x}_i)^2}{\frac{1}{n_+ - 1} \sum_{k=1}^{n_+} (x_{k,i}^+ - \bar{x}_i^+)^2 + \frac{1}{n_- - 1} \sum_{k=1}^{n_-} (x_{k,i}^- - \bar{x}_i^-)^2} \quad (3.1)$$

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.

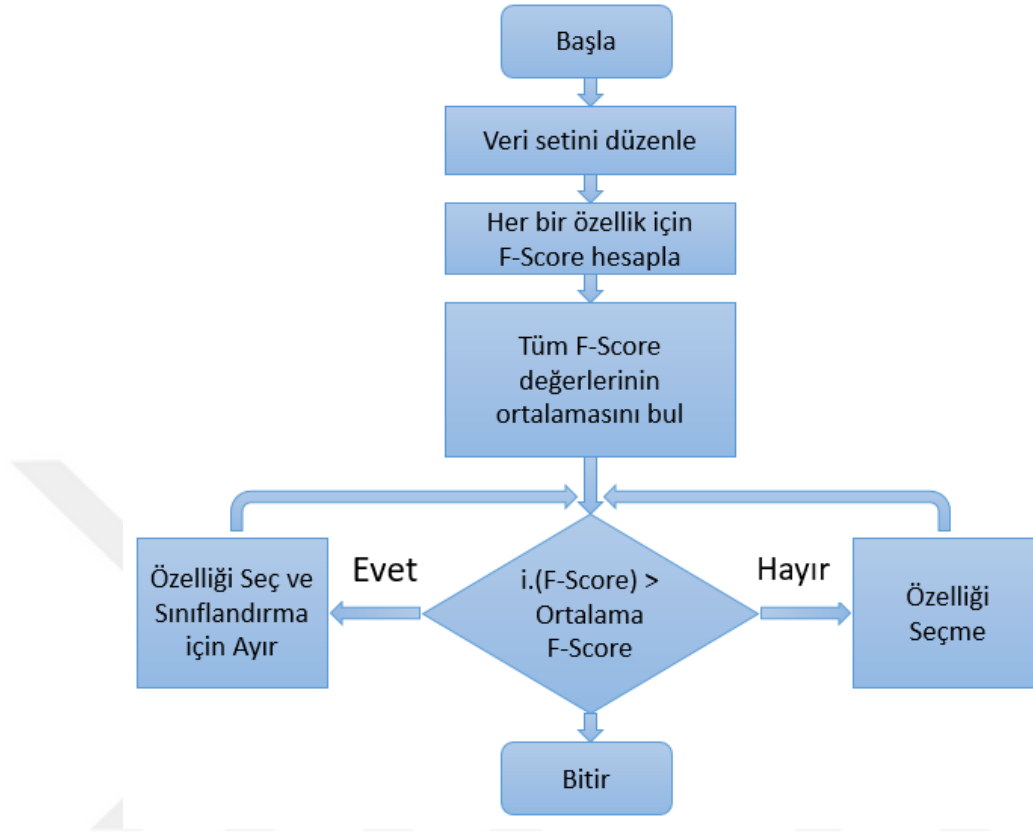
Yukarıdaki eşitlik, 3'lü sınıfları seçmek için aşağıdaki gibi (Denklem 3.2) revize edilmiştir.

$$F_{(i)} = \frac{(\bar{x}_i^a - \bar{x}_i)^2 + (\bar{x}_i^b - \bar{x}_i)^2 + (\bar{x}_i^c - \bar{x}_i)^2}{\frac{1}{n_a - 1} \sum_{k=1}^{n_a} (x_{k,i}^a - \bar{x}_i^a)^2 + \frac{1}{n_b - 1} \sum_{k=1}^{n_b} (x_{k,i}^b - \bar{x}_i^b)^2 + \frac{1}{n_c - 1} \sum_{k=1}^{n_c} (x_{k,i}^c - \bar{x}_i^c)^2} \quad (3.2)$$

Burada , \bar{x}_i^a a sınıfının i. özelliğinin ortalaması, \bar{x}_i^b b sınıfının i. özelliğinin ortalaması, \bar{x}_i^c c sınıfının i. özelliğinin ortalaması ve \bar{x}_i de tüm sınıfların i. özelliğinin ortalaması olarak ifade edilmiştir.

Denklemler ile özelliklere ait F-Score değerleri hesaplanmıştır ve Şekil 3.3.'deki F-

Score özellik seçme algoritması ile özellikler seçilmiştir [11].



Şekil 3.3. F-Score algoritması

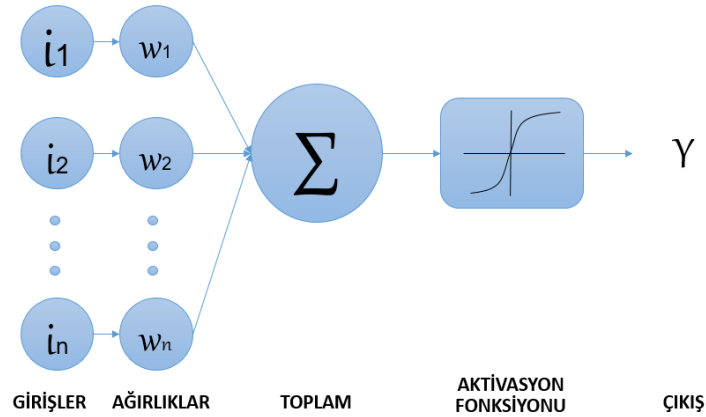
Bu aşamadan sonra 22 adet özellik içerisinde, Minimum, Ortalama, Maksimum, Ortanca, Harmonik Ortalama, Çarpıklık, T25 ve T50 özellikleri seçilmiştir. Seçilen özellikler Tablo 3.4.'deki gibi gösterilmiştir.

Tablo 3.4. Seçilen özellikler

İşaret no	Seçilen işaret
1	Minimum
2	Ortalama
3	Maksimum
4	Ortanca
5	H.Ortalama
6	Çarpıklık
7	25% Kırpılmış Ortalama
8	%50 Kırpılmış Ortalama

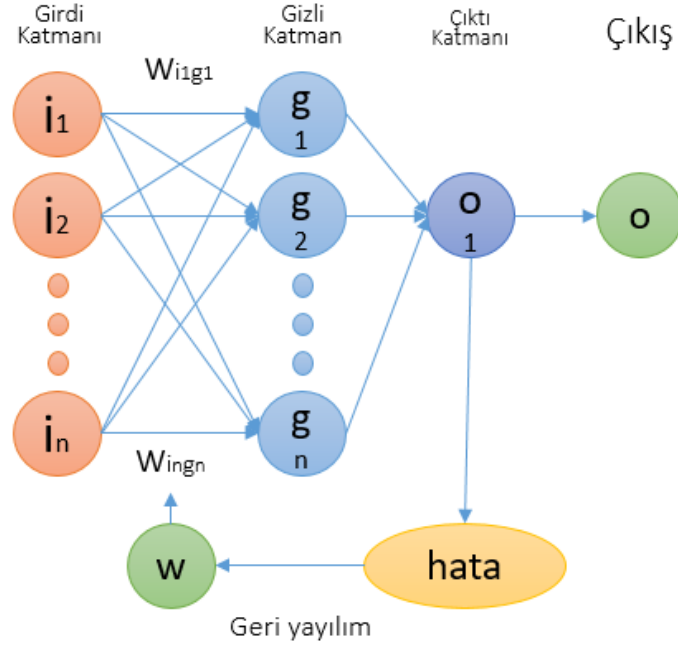
3.2.4. Sınıflandırma

Çalışmada, sınıflandırma yapay sinir ağı (YSA) kullanılarak yapılmıştır. YSA ilk olarak 1940'lı yılların başında Warren McCulloch ve W.A.Pitts tarafından ortaya atılan, insan beyninden esinlenerek geliştirilmiştir. YSA eldeki verilerden yola çıkarak genelleme yapmakta ve hiç görmediği veriler hakkında bu genellemelere göre karar verebilmektedir. YSA'lardaki her bir sinir kendi bilgi işleme yapısına sahiptir ve diğer sinirlerle ağırlıklı bağlantılar aracılığıyla birbirine bağlanır [16]. YSA'da bilgiler giriş katmanındaki sinirlere verilir. Giriş sinirleri tarafından alınan bilgilerin sinir üzerindeki etkisini, ağırlıklar belirler. Her bir girişin kendine ait bir ağırlığı vardır. Toplama fonksiyonunda her bir giriş, ilgili sinirdeki ağırlıklar ile çarpılarak toplanır. Bu toplam aktivasyon fonksiyonuna gönderilir ve buradan geçirilip çıkışa iletilir. Çıkışı y , giriş vektörleri i 'ler tarafından uyarlandığında Şekil 3.4.'deki gibi tanımlanır [16] [27].



Şekil 3.4. Yapay sinir ağı yapısı

YSA'da, ağırlıkların güncellenmesinde geri yayılım algoritmaları sık kullanılan yöntemlerdendir. Genelleştirilmiş delta kuralında, eğitim sürecinde hesaplanan hatanın bir kısmı, ilgili sinir hücresine geri yansıtılır ve ağırlıklar hataya göre güncellenir. Bu işlem belli sayıda tekrarlanarak hatanın en küçük değere ulaşması sağlanır [28]. Geri yayımlı yapay sinir ağı, Şekil 3.5.'teki gibi gösterilir.



Şekil 3.5. Geri yayımlı yapay sinir ağı yapısı

Çalışmada Levenberg-Marquardt geri yayılım algoritması kullanılmıştır. Sınıflandırma işlemi Matlab ortamında YSA kodları kullanılarak yapılmıştır. Nöron sayısı, 22 adet özellik için 22 ve 11, 8 adet özellik için 8 ve 4 olacak şekilde iki farklı değer seçilerek sınıflandırma performansındaki farklar ayrıca gözlemlenmiştir.

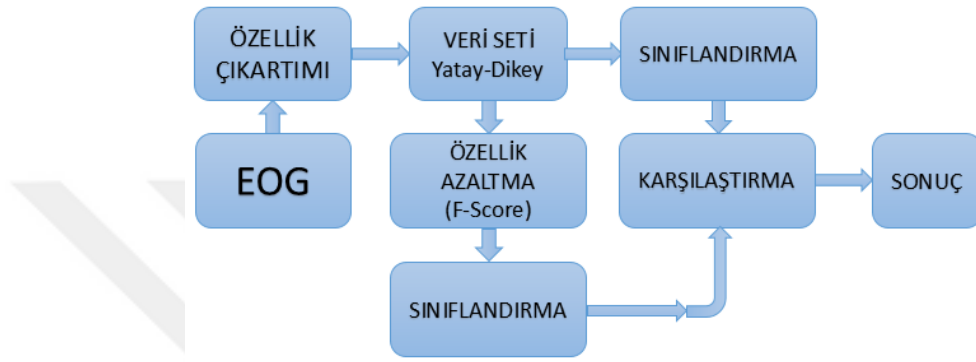
Tablo 3.5. Yatay işaretlerin % dağılımları

	EĞİTİM	TEST	TOPLAM
	70%	30%	100%
SAĞ	404	174	578
SOL	406	174	580
TOPLAM	810	348	1158

Tablo 3.6. Dikey işaretlerin % dağılımları

	EĞİTİM	TEST	TOPLAM
	70%	30%	100%
YUKARI	417	179	596
AŞAĞI	433	186	619
GÖZ KIRPMA	273	118	391
TOPLAM	1123	483	1606

Sınıflandırma işlemi için işlem basamakları Şekil 3.6.'deki akış diyagramında gösterilmiştir. Diyagrama göre alınan EOG sinyallerinden özellik çıkarımı işlemleri gerçekleştirilmiştir. Sınıflandırma için verilerin %70'i eğitim ve kalan %30'u test için ayrılmıştır. Dağılımdaki sınıflara ait özellik sayıları Tablo 3.5. ve Tablo 3.6.'da gösterilmiştir. Sınıflandırmanın ardından özellikler azaltılarak tekrar sınıflandırılmış ve sonuçların performans değerlendirmeleri yapılmıştır.



Şekil 3.6. Akış diyagramı

3.3. Analizler

Çalışmada, sınıflandırma sonuçları karmaşıklık matrisleriyle ifade edilmiştir ve performans değerlendirmesi için tanı testlerinde kullanılan özgün oranlar kullanılmıştır. Tanı testi gerçek hasta ve sağlamlar üzerinden veya bir ana tanı testi (Altın standart) üzerinden yapılır. Bu çalışmada, hedef matrisleri gerçek değerleri, sınıflandırma sonuçları ise teşhis edilecek grubu ifade etmektedir. Bir tanı testinin değerlendirilmesi, Tablo 3.7.'deki gibi (2x2) tipi bir karmaşıklık matrisinde, yanda gerçek sonuçlar, üstte ise tanı testi/tahmini sonuçlar olacak şekilde yapılır [29].

Tablo 3.7. Tanı testi karmaşıklık matrisi [29]

		Tahmin/Tanı Değerleri		
		H+	H-	Toplam
Gerçek Değer	H+	A (GP)	C (YN)	A+C
	H-	B (YP)	D (GN)	B+D
Toplam		A+B	C+D	A+B+C+D

“A (GP)” tanı testinin gerçek tanıya uygun olarak, hasta dediği olgulardır. Yani gerçek pozitifler (GP)’dir. Buna karşın “C (YN)” tanı testinin gerçekte hasta olup, hatalı olarak sağlam dediği oldulardır. Yani yanlış negatif (YN)’dir. Testin geneli için;

- a. Duyarlılık (Sensitivity) : Testin, hastalar arasından gerçek hastaları ayırma ölçüsüdür. Duyarlılık aşağıdaki eşitlik (Denklem 3.3) kullanılarak ifade edilmiştir.
- b. Özgüllük (Specificity) : Testin, sağlamlar arasından gerçek sağlamları ayırma ölçüsüdür. Özgüllük aşağıdaki eşitlik (Denklem 3.4) kullanılarak ifade edilmiştir.
- c. Doğruluk (Accuracy) : Testin, gerçek hasta ve sağlam olarak toplam doğru tanı koyma ölçüsüdür. Doğruluk aşağıdaki eşitlik (Denklem 3.5) kullanılarak ifade edilmiştir.

$$\text{Duyarlılık (Sensitivity)} = \frac{A}{(A + C)} = \frac{GP}{(GP + YN)} \quad (3.3)$$

$$\text{Özgüllük (Specificity)} = \frac{D}{(D + B)} = \frac{GN}{(GN + YP)} \quad (3.4)$$

$$\text{Doğruluk (Accuracy)} = \frac{A + D}{(A + B + C + D)} = \frac{(GP + GN)}{(GP + YP + YN + GN)} \quad (3.5)$$

Karmaşıklık matrisleri (n*n) formatında verildiklerinde, çok boyutlu yapıdan (2*2) boyutuna dönüşüm yapılır [30]. Aşağıda Tablo 3.8.’deki (3*3) boyutundaki matris, Tablo 3.9.’daki (2*2) boyutunda 3 adet matrise dönüştürülmüştür.

Tablo 3.8. 3*3 Boyutunda Karmaşıklık Matrisi

		Tahmin/Tanı Değerleri		
		A	B	C
Gerçek Değer	A	$D(AA)$	$Y(AB)$	$Y(AC)$
	B	$Y(BA)$	$D(BB)$	$Y(BC)$
	C	$Y(CA)$	$Y(CB)$	$D(CC)$

Tablo 3.9. 2*2 Boyutuna Dönüşüm Matrisleri

		Tahmin/Tanı Değerleri	
		A	DİĞER
Gerçek Değer	A	$D(AA)$	$Y(AB)+Y(AC)$
	DİĞER	$Y(BA)+Y(CA)$	$D(BB) + D(CC) + Y(BC) + Y(CB)$

		Tahmin/Tanı Değerleri	
		B	DİĞER
Gerçek Değer	B	$D(BB)$	$Y(BA)+Y(BC)$
	DİĞER	$Y(AB)+Y(CB)$	$D(AA) + D(CC) + Y(AC) + Y(CA)$

		Tahmin/Tanı Değerleri	
		C	DİĞER
Gerçek Değer	C	$D(CC)$	$Y(CA)+Y(CB)$
	DİĞER	$Y(AC)+Y(BC)$	$D(AA) + D(BB) + Y(BA) + Y(AB)$

BÖLÜM 4. ARAŞTIRMA BULGULARI

Sınıflandırma sonuçları karmaşıklık matrisleri ve performans değerlendirmesi iki farklı nöron sayısına göre tablolar halinde sunulmuştur. Performans değerlendirmesi için tanı testlerinde kullanılan özgün oranlar; duyarlılık, özgüllük ve doğruluk oranı değerleri, karmaşıklık matrisleri doğrultusunda, ilgili eşitlikler (Denklem 3.3, Denklem 3.4, Denklem 3.5) vasıtasıyla hesaplanmıştır [29] [30] [31] [32].

Tablo 4.1. Yatay işaretlere ait 22 özelliğin sınıflandırma sonucu

22 Özellik							
22 Nöron				11 Nöron			
		Tahmin Edilen Değer				Tahmin Edilen Değer	
		Sol	Sağ			Sol	Sağ
Gerçek Değer	Sol	174	0	Gerçek Değer	Sol	174	0
	Sağ	0	174		Sağ	0	174

Tablo 4.2. Yatay işaretlere ait 8 özelliğin sınıflandırma sonucu

8 Özellik							
8 Nöron				4 Nöron			
		Tahmin Edilen Değer				Tahmin Edilen Değer	
		Sol	Sağ			Sol	Sağ
Gerçek Değer	Sol	174	0	Gerçek Değer	Sol	174	0
	Sağ	1	173		Sağ	0	174

Tablo 4.3. Dikey işaretlere ait 22 özelliğin sınıflandırma sonucu

22 Özellik									
22 Nöron					11 Nöron				
		Tahmin Edilen Değer					Tahmin Edilen Değer		
		Aşağı	Yukarı	Göz Kırpma			Aşağı	Yukarı	Göz Kırpma
Gerçek Değer	Aşağı	186	0	0	Gerçek Değer	Aşağı	186	0	0
	Yukarı	0	178	1		Yukarı	0	175	4
	Göz Kırpma	0	1	117		Göz Kırpma	0	0	118

Tablo 4.4. Dikey işaretlere ait 8 özelliğin sınıflandırma sonucu

8 Özellik									
8 Nöron					4 Nöron				
Tahmin Edilen Değer					Tahmin Edilen Değer				
		Aşağı	Yukarı	Göz Kırpma			Aşağı	Yukarı	Göz Kırpma
Gerçek Değer	Aşağı	186	0	0	Gerçek Değer	Aşağı	186	0	0
	Yukarı	0	163	16		Yukarı	0	163	16
	Göz Kırpma	0	0	118		Göz Kırpma	0	1	117

Tablo 4.5. Yatay işaretlere ait 22 özelliğin sınıflandırma performansı

22 Özellik									
22 Nöron				11 Nöron					
		Duyarlılık	Özgüllük	Doğruluk			Duyarlılık	Özgüllük	Doğruluk
Sol		1	1	1	Sol		1	1	1
Sağ		1	1	1	Sağ		1	1	1

Tablo 4.6. Yatay işaretlere ait 8 özelliğin sınıflandırma performansı

8 Özellik									
8 Nöron				4 Nöron					
		Duyarlılık	Özgüllük	Doğruluk			Duyarlılık	Özgüllük	Doğruluk
Sol		1	0,9943	0,9971	Sol		1	1	1
Sağ		0,9943	1	0,9971	Sağ		1	1	1

Tablo 4.7. Dikey işaretlere ait 22 özelliğin sınıflandırma performansı

22 Özellik									
22 Nöron				11 Nöron					
		Duyarlılık	Özgüllük	Doğruluk			Duyarlılık	Özgüllük	Doğruluk
Aşağı		1	1	1	Aşağı		1	1	1
Yukarı		0,9944	0,9967	0,9959	Yukarı		0,9777	1	0,9917
G. Kırpma		0,9915	0,9973	0,9959	G. Kırpma		1	0,989	0,9917

Tablo 4.8. Dikey işaretlere ait 8 özelliğin sınıflandırma performansı

8 Özellik									
8 Nöron				4 Nöron					
		Duyarlılık	Özgüllük	Doğruluk			Duyarlılık	Özgüllük	Doğruluk
Aşağı		1	1	1	Aşağı		1	1	1
Yukarı		0,9106	1	0,9669	Yukarı		0,9106	0,9967	0,9648
G. Kırpma		1	0,9562	0,9669	G. Kırpma		0,9915	0,9562	0,9648

Yukarıda Tablo 4.1. ve 4.2. yatay işaretlere, Tablo 4.3. ve 4.4. dikey işaretlere ait sınıflandırma sonucunun karmaşıklık matrislerini içermektedir. Tablo 4.5. ve 4.6. yatay işaretlere, Tablo 4.7. ve 4.8. dikey işaretlere ait sınıflandırmanın performans sonucunu içermektedir. Özellik seçme algoritmaları ile başlangıca göre seçilen özellik sayısı %60 oranında azaltılırken, sınıflandırma sonuçlarının %1 ile %9 arasında olumsuz etkilendiği gözlemlenmiştir. Genel doğruluk oranları açısından değerlendirildiğinde, yatay kanala ait sağ ve sol işaretlerin sınıflandırılma performansı %99 seviyelerinde gözlemlenmiştir. Dikey kanala ait aşağı, yukarı ve göz kırpma işaretlerinin performansları sırasıyla %100, %91 ve %96 seviyelerinde gözlemlenmiştir.



BÖLÜM 5. TARTIŞMA VE SONUÇ

Bu çalışmada, ALS ve benzeri hastalıklara sahip kişilerin hayatlarını kolaylaştırmak için EOG tabanlı kontrol sistemleri için işaret üretimi yapılmıştır. 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, sağa, sola ve göz kırpması) ile etiketlenmiştir. Toplamda 2764 adet sinyal parçası elde edilmiştir. EOG sinyalinden zaman domeninde özellik çıkarımı yapılmış ve daha sonra özellik seçilerek sınıflandırma işlemleri yapılmıştır.

Elde edilen bulgular doğrultusunda, zaman domeninde EOG sinyallerinden çıkarılan 22 adet özellik içerisinde, Minimum, Ortalama, Maksimum, Ortanca, Harmonik Ortalama, Çarpıklık, T25 ve T50 özelliklerinin kullanılmasının uygun olduğu kanaatine varılmıştır.

Özellik seçme algoritmaları makine öğrenmesinin önemli bir parçasıdır. Bu algoritmaların öğrenme süresini kısaltması ve özellik sayısını minimuma indirmesi istenir [10] [11] [18] [31]. Çalışmadaki sonuçlar literatür ile uyum içerisindedir.

Literatürde yapılan çalışmalarda %91, %95 ve %98.7 oranlarında sınıflandırma performansları elde edilmiştir. [7] [5] [8]. Çalışmamızda kullanılan özellik sayıları benzer çalışmalardan fazla olmakla birlikte elde edilen sonuçlar literatürdeki sonuçlar ile yakınlık göstermektedir.

Edinilen sonuçlara göre ALS ve benzeri hastalıklara sahip kişilerin hayatlarını kolaylaştırabilmek adına EOG tabanlı ve gerçek zamanlı sistemler tasarlanırken bu çalışmada seçilen özelliklerin kullanılacağı düşünülmektedir. Çalışmanın geliştirilmesi ve özellikle mikrodenetleyicili sistemlerde kullanılması açısından elde edilen 8 adet özellik, farklı özellik seçme teknikleri ile daha da azaltılarak çalışma

geliştirilebilir. Ayrıca buradaki zaman domeni özellikleri ile beraber frekans domeni özellikleri de kullanılarak benzer bir çalışma yapılabilir.



KAYNAKLAR

- [1] Afandi, J., Eog kontrollü çok yönlü tekerlekli sandalye. İzmir Kâtip Çelebi Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Teknolojileri Ana Bilim Dalı, Yüksek Lisans Tezi, 2019.
- [2] Ülkütaş, H.Ö., Eog'nin Kodlanmasına Dayanan Bilgisayar Tabanlı Gözle Yazı Yazma Sistemi Geliştirilmesi, Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, 2015.
- [3] <https://medium.com/@toprakozt/hawkingin-konusma-cihazı-ve-p300-b38f938733dd>, Erişim Tarihi: 13.12.2019.
- [4] Lin, J.-S., Yang, W.-C., Wireless brain-computer interface for electric wheelchairs with EEG and eye-blinking signals. Int J Innov Comput Inf Control, 8, 6011–6024, 2012.
- [5] Usakli, A. B., Gurkan, S., Design of a novel efficient humancomputer interface: An electrooculogram based virtual keyboard. IEEE Trans. Instrum. Meas., 59(8), 2099–2108, 2010.
- [6] Esas, M. Y., Latifoglu, F., Computer-Based design with dual channel device electrooculography and eye movement tracking. Medical Technologies National Conference (TIPTEKNO), 1–4, 2015.
- [7] Heo, J., Yoon, H., Park, K., A Novel Wearable Forehead EOG Measurement System for Human Computer Interfaces. Sensors, 17(7), 1485, 2017.

- [8] Gül, S., Tiryaki, Z., Kuzu, E., Milligüney, M., Çetinel, G., Move Your Wheelchair with Your Eyes. *Int. J. Appl. Math. Electron. Comput.*, 1(Special Issue), 5–8, 2017.
- [9] Uçar, M. K., Polat, K., Bozkurt, M. R., Bilgin, C., Effect of Time and Frequency Domain Features in Sleep Eeg and Eog Signals Classification. *Tıp teknolojileri ulusal kongresi*, 1, 0–5, 2014.
- [10] Bozkurt, M. R., Uçar, M. K., Bozkurt, F., Bilgin, C., In obstructive sleep apnea patients, automatic determination of respiratory arrests by photoplethysmography signal and heart rate variability. *Australas. Phys. Eng. Sci. Med.*, 1–21, 2019.
- [11] Polat, K., Güneş, S., A new feature selection method on classification of medical datasets: Kernel F-score feature selection. *Expert Syst. Appl.*, 36(7), 10367–10373, 2009.
- [12] Özcan, F., Kaya, A., Yayla, M.E., Amyotrofik Lateral Skleroz Hastalığı ve Aile Hekiminin Rolü. *Celal Bayar Üniversitesi Sağlık Bilim. Enstitüsü Derg.*, 3(3), 431–435, 2016.
- [13] <http://www.itfnoroloji.org/semi1/semi3.htm>., Erişim Tarihi: 11.12.2019.
- [14] <http://www.tuncaycentel.com/cp1.htm>., Erişim Tarihi: 11.12.2019.
- [15] <https://www.aao.org/eye-health/anatomy/eye-muscles>., Erişim Tarihi: 11.12.2019.
- [16] Şahin, E., Makine Öğrenme Yöntemleri ve Kelime Kümesi Tekniği ile İstenmeyen e-Posta sınıflandırması. Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, 2018.

- [17] <https://www.datasciencecentral.com/profiles/blogs/machine-learning-summarized-in-one-picture.>, Erişim Tarihi: 11.12.2019.
- [18] Uçar, M. K., Eta Correlation Coefficient Based Feature Selection Algorithm for Machine Learning: E-Score Feature Selection Algorithm. *Zeki Sist. Teor. ve Uygulamaları Derg.*, 2(1), 7–12, 2019.
- [19] BUDAK, H., Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilim. Enstitüsü Derg.*, 22, 21–31, 2018.
- [20] Forman, G., An extensive empirical study of feature selection metrics for text classification. *J. Mach. Learn. Res.*, 3, 1289–1305, 2003.
- [21] Ladha, L., Deepa, T., Feature selection methods and algorithms. *Int. J. Comput. Sci. Eng.*, 3(5), 1787–1797, 2011.
- [22] Dash, M., Liu, H., Feature selection for classification. *Intell. data Anal.*, 1(3), 131–156, 1997.
- [23] Polat, K., Biyomedikal Sinyallerde Veri Ön-İşleme Tekniklerinin Medikal Teşhiste Sınıflama Doğruluğuna Etkisinin İncelenmesi. *Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Doktora Tezi*, 2008.
- [24] Kavsaoglu, A. R., Polat, K., Bozkurt, M. R., An innovative peak detection algorithm for photoplethysmography signals: an adaptive segmentation method. *Turkish J. Electr. Eng. Comput. Sci.*, 24(3), 1782–1796, 2016.
- [25] Gerla V., Kremen, V., Covassin, N., Lhotska, L., Saifutdinova, E.A., Bukartyk, J., Marik, V., Somers, V.K., Automatic identification of artifacts and unwanted physiologic signals in EEG and EOG during wakefulness. *Biomed. Signal Process. Control*, 31, 381–390, 2017.

- [26] Colonna, J. G., Cristo, M., Salvatierra, M., Nakamura, E.F., An incremental technique for real-time bioacoustic signal segmentation. *Expert Syst. Appl.*, 42(21), 7367–7374, 2015.
- [27] <https://medium.com/@jayeshbahire/the-artificial-neural-networks-handbook-part-4-d2087d1f583e>, Eriřim Tarihi: 17.11.2019.
- [28] Tosun, M., Erginli, M., Kasım, Ö., Uğrař, B., Tanrıverdi, ř., Kavak, T., EEG Verileri Kullanılarak Fiziksel El Hareketleri ve Bu Hareketlerin Hayalinin Yapay Sinir Ağları İle Sınıflandırılması. *Sak. Univ. J. Comput. Inf. Sci.*, 1(2), 1–9, 2018.
- [29] Dirican, A., Tani Testi Performanslarının Deęerlendirilmesi Ve Kiyaslanması. *Cerrahpařa Tıp Derg.*, 32(1), 25-30, 2001.
- [30] Beleites, C., Salzer, R., Sergo, V., Validation of Soft Classification Models using Partial Class Memberships: An Extended Concept of Sensitivity & Co. applied to the Grading of Astrocytoma Tissues. *Chemometrics and Intelligent Laboratory Systems*, 12 - 22, 2013.
- [31] Gök, M., Makine Öğrenmesi Yöntemleri ile Akademik Başarının Tahmin Edilmesi. *Gazi Üniversitesi Fen Bilim. Derg. Part C Tasarım ve Teknol.*, 5(3), 139–148, 2017.
- [32] Geyer, L. H., DeWald, C. G., Feature lists and confusion matrices. *Percept. Psychophys.*, 14(3), 471–482, 1973.

ÖZGEÇMİŞ

İlhan Zengin, 21.09.1989'da Samsun'da doğdu. 2008 yılında tamamladığı lise eğitiminin ardından, 2009 yılında Sakarya Üniversitesi Elektrik - Elektronik Mühendisliği Bölümü'ne başladı. Lisans eğitiminin ardından 2017 yılında Sakarya Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde yüksek lisans eğitimine başladı. Halen özel sektörde mesleğini icra etmektedir.