



BEYİN BİLGİSAYAR ARAYÜZÜNÜN GELİŞTİRİLMESİ İÇİN HAYALİ MOTOR GÖRÜNTÜ TABANLI YAKIN KIZILÖTESİ SPEKTROSKOPİ SİNYALLERİNİN SINIFLANDIRILMASI

Merve KOÇYİĞİT^{1,*}, Ayşegül GÜVEN², Furkan ÇAM³

^{1,2,3}Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri, Türkiye

ÖZET

Yakın Kızılötesi Spektroskopisi (NIRS) ilgili bölgede serabrel izleme potansiyeli sunan, beyindeki hemodinamik aktiviteyi ölçen, girişimsel olmayan fonksiyonel beyin görüntüleme tekniğidir. NIRS sinyalleri elektriksel gürültüden etkilenmeyen, yüksek zamansal çözünürlüğü olan, ekonomik ve taşınabilir bir yapıya sahiptir. Bu avantajlarından dolayı NIRS tabanlı verilerin Beyin Bilgisayar Arayüzü (BCI) sistemlerinde kullanımı son zamanlarda yaygınlaşma göstermektedir. Bununla birlikte kullanılan veri tabanında yapılan öznelik çıkarımı, ön işleme ve sınıflandırma seçimi BCI'daki başarıyı yükseltmek için önemlidir. Bu çalışmada, NIRS veri kümesine ait el açma-kapama motor hareketi hayali tabanlı kaydedilen oksihemoglobin (HbO) ve deoksihemoglobin (HbR) sinyalleri kullanılmıştır. Öncelikle bu sinyaller, çevresel ve fizyolojik gürültülerin etkisinden temizlemek için dalgacık tabanlı filtre ile ön işlem geçirilmiştir. Elde edilen HbO ve HbR işaretlerinden Ortalama Enerji, Varyans, Standart Sapma, Entropi, Çarpıklık ve Basıklık tabanlı özneliklere ulaşılmıştır. Ulaşılan öznelikler Rasgele Orman metodu ile sınıflandırılarak HbR için %82.7586, HbO için %84.4828 ve HbR+ HbO için %89.6552 ortalama sınıflama doğruluğu hesaplanmıştır.

Anahtar kelimeler: Yakın kızılötesi spektroskopisi, BCI, Rasgele orman

CLASSIFICATION OF IMAGING MOTOR IMAGE BASED NEAR INFRARED SPECTROSCOPY SIGNALS FOR IMPROVING THE BRAIN COMPUTER INTERFACE

ABSTRACT

Near Infrared Spectroscopy (NIRS) is a noninvasive functional brain imaging technique that measures the hemodynamic activity in the brain, offering serabrel monitoring potential in the relevant region. NIRS signals are not affected by electrical noise, have high temporal resolution, economic and portable structure. Because of these advantages, the use of NIRS-based data in Brain Computer Interface (BCI) systems has become widespread recently. However, attribute extraction, preprocessing and classification selection in the database used is important to increase the success in BCI. In this study, oxyhemoglobin (HbO) and deoxyhemoglobin (HbR) signals are used based on the imaginary based on hand on-off motor motion of NIRS data set. First, these signals are pretreated with a wavelet-based filter to remove the effects of environmental and physiological noise. Mean Energy, Variance, Standard Deviation, Entropy, Skewness and kurtosis based attributes were obtained from HbO and HbR signals. The obtained attributes were classified by Random Forest method and 82.7586% for HbR, 84.4828% for HbO and 89.6552% for HbR + HbO were calculated.

Keywords: Near infrared spectroscopy (NIRS), BCI, Random forest

1. GİRİŞ

İnsan motor kabiliyetini kısıtlayan, iletişim, kontrol ve motor bozukluğuna sebep olan ancak bilincini etkilemeyen birden çok hastalık vardır. Beyin Sapı Felçleri, Amotrofik Lateral Skleroz ve Multipl Skleroz bu rahatsızlıklardan bir kaçıdır. Bu rahatsızlıklarda birey bilinçlidir ve beyin yapısı düzgün çalışır fakat beyinden gelen komutlar vücuttaki uzuvlardan iletilmez. Bu tip rahatsızlıklarda bireyin günlük yaşantısını Beyin Bilgisayar Arayüzü (Brain Computer Interface-BCI) sistemleri kolaylaştırırlar ve beyin aktivitesini yorumlayıp, beyinden gelen komutları uygulamak için öngörülen eylemlere dönüştürürler.

* Sorumlu yazar / Corresponding author, e-posta / e-mail: mervekocyigit38@hotmail.com
Geliş / Recieved: 19.08.2019 Kabul / Accepted: 05.12.2019 doi: 10.28948/ngumuh.606507

BCI sistemleri, beyinde oluşan elektriksel aktiviteyi ölçümlemek için bireye uygulanan müdahaleye göre girişimsel (invasive) ve girişimsel olmayan (non-invasive) yöntemler olarak ikiye ayrılırlar. Girişimsel yöntemde bireye operasyon yapılması gerekmektedir. Fakat girişimsel olmayan yöntemde böyle bir uygulama yoktur. Girişimsel yöntemde elektrotlar kafa derisinin altına direk beyinde ilgili bölgeye yerleştirilmektedir. Bu yöntemde elektrotların beyine direk temasından dolayı daha iyi ölçümler yapılmaktadır. Bu durumda sinyalin işlenmesi daha kolaylaşmakta ve yüksek çözünürlükte kalite sağlanmaktadır. Girişimsel olmayan yöntemde ise elektrotlar bir jel yardımı ile direk kafanın üzerine yerleştirilmektedir. Bu uygulamanın dezavantajı beyin istenilen bölgesine direk elektrotların yerleştirilememesi sebebiyle saç veya dış etkenden kaynaklanan gürültülerin sinyal kalitesini bozmasıdır. Fakat girişimsel yöntem operasyon gerektirir ve birey bu durumdan uzak durmak adına daha çok operasyon gerektirmeyen acısız bir yöntem olan girişimsel olmayan yöntemi tercih etmektedir [1].

BCI'nın girişimsel olmayan uygulama metodlarından MEG, PET, FMRI gibi teknikler uygulamada yüksek çözünürlük sağlanmasına rağmen taşınması, uygulanması zor ve pahalı olmasından dolayı çok tercih edilememektedir [2]. BCI uygulamalarında yaygın olarak kullanılan girişimsel olmayan bir diğer teknik Elektroensefalografi (EEG) uygulamasıdır. Bu tekniğin taşınması kolay ve yüksek zamansal çözünürlüğü sahiptir. EEG nin bu avantajlarının yanında elektrotların yerleştirilmesinden dolayı yaşanan sıkıntı ve düşük uzaysal çözünürlük gibi dezavantajları vardır [3]. Fakat son zamanlarda Yakın Kızılötesi Spektroskopi (Near Infrared Spektroskopi-NIRS) olarak adlandırılan girişimsel olmayan BCI uygulamalarında artış olmuştur [4].

NIRS beyin bölgesel aktivasyonu ile ortaya çıkan Oksihemoglobin (HbO) ve Deoksihemoglobin (HbR) değişimine bağlı olarak serabrel hemoglobinin konsantrasyonlarını ölçebilen girişimsel olmayan fonksiyonel bir görüntüleme tekniğidir. NIRS 700nm ile 1000nm arasında kızıl ötesi ışığa sahiptir. Kızıl ötesi ışın ilgili bölgeye gönderilir ve hücreler tarafından emildikten sonra yansıyan ışınlar dedektörler tarafından tekrar ölçülebilir. Böylelikle hemoglobin konsantrasyonları ile beyindeki aktivite sırasında çalışan bölgeler tespit edilebilir. Taşınabilir, düşük maliyetli, yüksek zamansal çözünürlüğe sahip olan NIRS sinyalleri diğer girişimsel olmayan BCI yöntemlerine göre çeşitli avantajlar sunar [4,6].

Literatürde NIRS tabanlı BCI çalışmalarında sınıflandırma doğruluğunu artıracak farklı yöntemler kullanılmıştır. NIRS tabanlı motor hareket hayali çalışmalarından biri Naasar ve Hong'un çalışmalarıdır. Bu çalışmada, sağ-sol el bileği motor görüntü tabanlı NIRS işaretlerinde doğrusal ayırıcı analiz (linear discriminant analysis-LDA) sınıflandırıcı ile HbO konsantrasyonundaki değişimin ortalaması ve eğimi öznitelikleri kullanılarak ortalama sınıflandırma doğruluğu sırasıyla %77.56 ile %87.28 olarak elde etmişlerdir [7].

Sitarm ve arkadaşları, Destek Vektör makinesi(SVM) ve hidden markow modelini kullanarak sağ ve sol ellerin parmakla hafifçe vurulması ve gizlenmesine dayalı motor hareket hayali tabanlı NIRS işaretlerini sırasıyla %73 ve %89'luk sınıflandırma doğruluğu ile hesaplamışlardır [2]. Haihong ve Cuntai çalışmalarında sağ ve sol el motor hareketine dayalı NIRS sinyallerine kernel temelli sinyal yerleştirme öznelikliğini kullanmışlardır. Daha sonra SVM ile sınıflandırdıkları bu öznelikten %74.10 sınıflandırma doğruluğu hesaplamışlardır [8]. Ancak bunlar arasında hayali motor görüntü tabanlı el -açma ve kapama yer almamaktadır.

Shin ve arkadaşları, 29 kişiden kayıt ettiği NIRS tabanlı motor hareketine dayalı el -açma ve kapama işaretleri ile çalışmışlardır. Elde edilen NIRS işaretlerini öncelikle 6. Dereceden 0.1 ve 0.01 Hzlik Butterworth filtresinden geçirmişlerdir. Filtrelenmiş olan sinyali öznitelik çıkarımı için otak uzamsal örneklendirme tekniği ile elde etmişlerdir. Daha sonra çıkarmış oldukları öznitelik verisini LDA sınıflandırıcısı yöntemi ile sınıflandırmışlar ve HbO için ortalama %63.50 HbR için ortalama %66.50 sınıflandırma doğruluk yüzdesine ulaşmışlardır[9]. Diğer taraftan Yavuz ve Aydemir aynı veri kümesini kullanarak öncelikle NIRS işaretine 2. Dereceden 0.2-0.7 Hzlik Butterworth filtresi uygulayarak önışlemeden geçirmişlerdir. Önışlemeden geçirmiş oldukları NIRS işaretinden Katz Fraktal Boyut (KFB) tabanlı öznitelik çıkarmışlardır. K-en yakın komşuluk sınıflandırma yöntemi ile bu öznitelikleri sınıflandırmışlardır. Sınıflandırma sonucunda, sınıflandırma doğruluk yüzdesini HbO işareti için ortalama %70.14 HbR işareti için ortalama %72.36 SD olarak hesaplamışlardır ve başarıyı yükseltmişlerdir [10].

Bu çalışmanın temel amacı BCI teknolojilerinin performansını artırmak için NIRS'ın kullanımının uygulanabilirliğini test etmektir. Son zamanlarda BCI uygulamalarında artış gösteren NIRS sinyalleri seçilen önışleme, öznitelik ve sınıflandırma adımlarının uygunluğuna göre başarımda artış sağlamaktadır. Bu çalışma ile NIRS sinyallerine ait istatistiksel özellikler kullanılarak motor hareket hayali tabana ait verilerin yüksek sınıflama başarısı amaçlanmıştır. Böylece BCI'da NIRS sinyallerinin pratik kullanımı sağlanmış olacaktır.

2. MATERYAL VE METOT

2.1 Veri Kümesi

Bu çalışmada, Shin ve arkadaşlarının [11] numaralı referansta belirtildiği gibi açık erişime sunulan veri seti kümesi kullanılmıştır. Sıradan aydınlık bir odada sağlıklı ve gönüllü 29 kişiden Motor hareket hayali tabanlı NIRS işaretleri kaydedilmiştir.


BEYİN BİLGİSAYAR ARAYÜZÜNÜN GELİŞTİRİLMESİ İÇİN HAYALİ MOTOR GÖRÜNTÜ TABANLI YAKIN KIZILÖTESİ SPEKTROSKOPİ SİNYALLERİNİN SINIFLANDIRILMASI

Deney aşamasında kayıt alınan gönüllü kişiler 50 inçlik beyaz bir ekranın önüne oturtulmuştur. Kafaları ile ekran arasındaki mesafe 1,6m olarak ayarlanmıştır. Veri kaydı sırasında vücudun herhangi bir yerini hareket ettirmemeleri istenmiştir. Deney Şekil 1. deki kayıt şemasına göre yapılmıştır.



Şekil 1. Deney kayıt şeması

Deney üç seansta gerçekleştirilmiştir. Herbir seans 60 saniyelik ön bir dinlenme ile başlamakta sonrasında ekranın sağ veya sol tarafında beliren 2 saniyelik bir görsel tanıtımın ardından kayıt basamağına kısa bir bip sesi ile geçilmektedir. Yirmi deneme tekrarının yapıldığı 10 saniyelik kayıtlar ile motor hareket hayali tabanlı işlem basamağı gerçekleştirilmiştir. Bu yirmi denemenin 10 tanesi sağ el hayali motor hareketini gereyi kalan 10 tanesinde sol el hayali motor hareketini içermektedir. Daha sonra 1 saniyelik dur anlamına gelen 'stop' uyarısı ile 15-17 saniyelik dinlenimin ardından seans sonu 60 saniyelik dinlenme ile bir seans aşaması tamamlanmıştır. 3 seans sonunda 60 deneme (20 deneme x 3 seans) kayıt alınmıştır. Her bir denemenin 100 örnek içerdiği 10 Hzlik alt örnekleme frekansına sahip olan NIRS verileri 12.5 Hz örnekleme frekansı adı altında kaydedilmiştir. Otuz altı fizyolojik kanal ile sonuçlanan, frontal (Fp1, Fp2 ve Fpz etrafında), motor (C3 ve C4 etrafında) ve görsel alanlara (Oz çevresinde) on dört emitör ve on altı dedektörler Şekil 2. deki gibi yerleştirilmiştir.



Şekil 2. NIRS veri kaydının alındığı emitör ve dedektör pozisyonu

2.2 Önışleme

NIRS sinyalleri çok düşük frekans bandına sahip fizyolojik bilgiler içermektedirler. Bu sebeple solunum, kafa hareketi, kalp atışı gibi fizyolojik, cep telefonları gibi çevresel ve donanıma bağlı birçok gürültü faktörü elde edilen NIRS sinyali üzerinde bozucu etki yapmaktadırlar. NIRS sınıflandırma sistemlerinde yüksek başarımla elde edebilmek için sinyaller filtrelenerek ön işlemden geçirilip üzerindeki gürültüden arındırılır. Bu çalışmada, NIRS sinyallerini filtrelemek için ayrıcık dalgacık dönüşümü (ADD) filtreleme yapısı kullanılmıştır [12].

2.2.1 Ayrık dalgacık dönüşümü

ADD, NIRS gibi durağan olmayan işaretlerin incelenmesini sağlayan spektral analiz tekniğidir. Hareket eserlerinin çoğu, sinyalin genliğinde ani değişiklikler şeklinde görünür. ADD, iyi zaman-frekans lokalizasyonu sağlar. Bununla birlikte yüksek frekans aralığında küçük boyutlu, düşük frekans aralığında ise büyük boyutlu pencere yapısını kullanır. ADD, sinyalleri frekans bileşenlerine ayırarak filtreleme amacıyla kullanılan bir dönüşümdür. Bu dönüşüm yapısı sinyalde yüksek ve düşük frekansları analiz edip ayırtırmak için yüksek frekans bileşenlerini yüksek geçiren filtreden, düşük frekans bileşenlerini de alçak geçiren filtreden geçirip düşük ve yüksek frekansları birbirinden ayırır [13]. Bütün bu avantajlarından dolayı ADD tercih edilmiştir.

ADD'nin temel formülü aşağıdaki gibi ifade edilebilir:

$$w(j, k) = \sum_j \sum_k X(n) 2^{-j/2} \Psi(2^{-j}n - k) \quad (1)$$

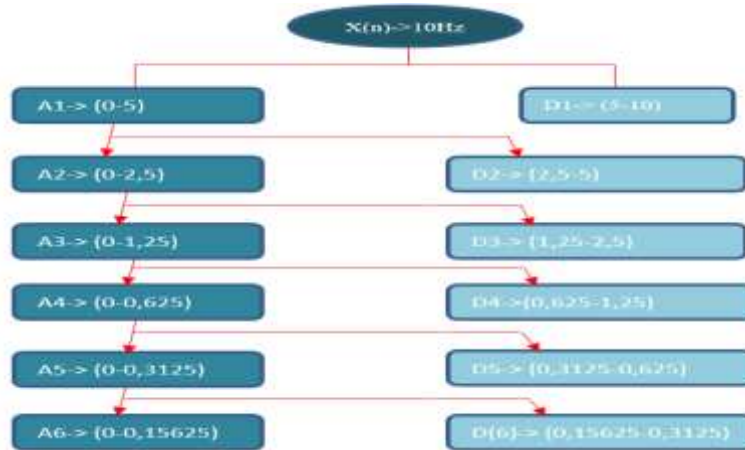
Burada $x(n)$ işaretin kendisi ve Ψ ana dalgacıktır. Bu ayırıştırma işleminde yüksek geçiren filtre ve alçak geçiren filtre sırasıyla $h_{yüksek}[k]$ ve $g_{alçak}[k]$ olarak ifade edilmektedir.

$$h_{yüksek}[k] = \sum_n x[n]h[2k - n] \quad (2)$$

$$g_{alçak}[k] = \sum_n x[n]g[2k - n] \quad (3)$$

Bu çalışmada, NIRS sinyaline Daubechies-6 dalgacığı uygulanarak, 6. Seviye ayırıştırma yapılmıştır.

Literatürde NIRS gibi düşük frekanslı olan fizyolojik sinyallerde Daubechies dalgacık fonksiyonlarının yaygın olarak kullanıldığı görülmektedir [14,16]. Bu sebeple çalışmamızda da ADD için dalgacık olarak tercih edilmiştir. Şekil 3'de 6. Seviyeden ADD frekans ağacı verilmiştir. $X(n)$ giriş sinyali olarak gösterilmiştir. A_n 'ler alçak geçiren filtre sonucu oluşan yaklaşık terimi, D_n 'ler ise yüksek geçiren filtre sonucu oluşan detay terimini vermektedir. NIRS sinyali 0-0.15 Hz arasında daha etkindir [17]. Bu çalışmada önceki bandlar solunum, kafa hareketi, kalp atışı gibi fizyolojik, çevresel ve donanımsal faktörlere bağlı gürültü içerdiğinden filtrelenerek gürültüden ayırıştırılıp A6(0.15Hz) bandı temel alınarak öznelik ve sınıflandırma işlemi gerçekleştirilmiştir.



Şekil 3. 6. Seviye ADD frekans ağacı

2.3 Öznelik Çıkarma

Öznelik çıkarma yöntemi sınıflandırma için önemli adımdır. Çünkü çalışma için uygun öznelik seçimi sınıflandırmanın performansını artırmaktadır. Bu çalışmada filtrelenmiş NIRS sinyallerinde; ortalama enerji, standart sapma, varyans, çarpıklık, basıklık ve entropi temel istatistiksel öznelikleri çıkarılmıştır. Kullanılan öznelikler Tablo 1'de kısaca açıklanmıştır.

BEYİN BİLGİSAYAR ARAYÜZÜNÜN GELİŞTİRİLMESİ İÇİN HAYALİ MOTOR GÖRÜNTÜ TABANLI YAKIN KIZILÖTESİ SPEKTROSKOPİ SİNYALLERİNİN SINIFLANDIRILMASI

Tablo 1. Çıkarılan öznitelikler

Öznitelik	Tanım	Formül İfadesi
Standart sapma	Standart sapma, verilerin aritmetik ortalamaya göre nasıl bir dağılım gösterdiğinin ifadesidir. \bar{x} ortalama, Std standart sapma, n veri sayısıdır.	$Std = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$ (4)
Çarpıklık	Bir rastgele sürecin olasılık dağılımını asimetrisinin bir ölçüsü olarak ifade edilir. Rastgele sürecin 3. Momenti ile hesaplanır. \bar{x} ortalama, Std standart sapma, n veri sayısı ve ζ çarpıklıktır.	$\zeta = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)std^3}$ (5)
Ortalama enerji	Kayıd alınan sinyalin sahip olduğu genlik değerlerinin karelerinin ortalamasıdır. Eşitlik (6) de ortalama enerjiye ait denklem verilmiştir. Burada E ortalama enerjiyi ifade etmektedir.	$E = \frac{1}{n} \sum_{i=1}^n X_i^2$ (6)
Varyans	Varyans, Standart sapmanın karesidir. Basit bir istatiksel ifadedir.	$Var = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ (7)
Entropi	Sinyaldeki düzensizliğin bir ölçüsüdür. H sinyalin entropisi, N sinyalin uzunluğu, $P(X = x_i)$ olasılık dağılım fonksiyonudur.	$H = - \sum_{i=1}^N P(X = x_i) \cdot \log_2 P(X = x_i)$ (8)
Basıklık	Bir rastgele sürecin olasılık dağılımının bir ölçüsü olarak ifade edilir. Rastgele sürecin 4. momenti ile hesaplanır. \bar{x} ortalama, b basıklık Std standart sapma, n veri sayısıdır.	$b = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)std^4}$ (9)

2.4 Sınıflandırma Yöntemi

Bu çalışmada sınıflandırıcının sınıflama sonuçları WEKA (bilgi analizi için Waikato Ortamı) Sürüm 3.8.3 kullanılarak elde edilmiştir. Elde edilen veriler sınıflandırılırken veri madenciliğinde çok sık kullanılan WEKA programındaki J48, BayesNet, Naive bayes ve Rasgele orman (RO) gibi algoritmalar ile çalışılmıştır. Bu çalışmada örnekleme sayısının az olması sebebiyle literatürde tercih edilen bir konu dışı bırakma (leave-one-subject-out) çapraz doğrulama kullanılmıştır. Bu sayede rasgele yüksek başarımla elde edilmesi giderilmiştir. Bunların sonucunda en yüksek başarımla RO algoritması ile elde edilmiştir [17,18].

2.4.1 Rasgele orman sınıflandırıcısı

Bremin tarafından geliştirilen RO sınıflandırıcısı, karar ağaçları ve düğümlerden oluşan ve kullanılması en esnek ve kolay algoritma tekniklerinden biridir. Bir veri setinden yeterince küçük bilgiler çıkararak veri setini birbirinden ayrılma işlemini yapabilen sınıflandırma tekniğidir. Karar ağaçları ne kadar fazla bulunursa RO o kadar güçlü olmaktadır. İkili (binary), kategorik ve sayısal özellikler konusunda başarılı bir algoritmadır. Dengesiz ve lineer olmayan veriler üzerinde de başarıları çok iyidir [19,20].

Literatürde RO sınıflandırma algoritması Biyomedikal alanda birçok çalışmada kullanılmıştır. Bu çalışmalardan biri Betlemsan ve arkadaşlarının çalışmalarıdır. Bu çalışmada EEG tabanlı sağ ve sol el motor görüntü sınıflandırmasında RO ve filtre bankası ortak mekansal algoritması kullanılmıştır. RO sınıflandırıcısı ile %97.07 sınıflandırma doğruluğu elde edilmiştir [21]. Okumuş ve Aydemir, çalışmalarında deneye sağ ve sol elini hareket ettirmesi hayaline dayalı motor görüntü sınıflandırmasında destek vektör makinesi, k-en yakın komşuluk, LDA ve RO sınıflandırıcısı kullanmışlar ve RO sınıflandırıcısı ile maksimum %90.71 sınıflandırma doğruluğu elde etmişlerdir [22].

3. SONUÇLAR VE TARTIŞMA

Bu çalışmada, motor hareketine dayalı 2sınıflı (el açma-kapama) olarak 29 kişiden kaydedilen NIRS işaretleri ile çalışılmıştır. NIRS işaretleri dalgacık dönüşümü filtreleme ile önışlemeden geçirilmiş ve Ortalama Enerji, Varyans, Entropi, Standart Sapma, çarpıklık ve basıklık öznitelikleri çıkarılmıştır. Çıkarılan öznitelik işaretlerine RO sınıflandırması uygulanmıştır. Sınıflandırma sonucunda HbO işareti için ortalama %84.4828, HbR işareti için ortalama %82.7586 ve HbO+HbR için ortalama % 89.6552 SD hesaplanmıştır. HbO, HbR ve HbO+HbR RO sınıflandırması için Karışıklık matris ifadeleri tablolarda gösterilmiştir.

Tablo 2. Sınıflandırmanın HbO, HbR ve HbO+HbR karışıklık matrisi

SINIF	HbO	HbO	HbR	HbR	HbO+HbR	HbO+HbR
	Sağ el	Sol el	Sağ el	Sol el	Sağ el	Sol el
Sağ el	40	18	38	20	46	12
Sol el	0	58	0	58	0	58

HbO işareti için sağ el durumu olarak doğru sınıflandırılmış örneklerin sayısı 40 iken, HbR için 38 ve HbO+HbR için 46'dır. Diğer taraftan sol el durumunun doğru sınıflandırılmış örnek sayısı HbO, HbR ve HbO+HbR işaretlerinin herbiri için 58'dir. Sağ el olarak yanlış sınıflandırılmış örneklerin sayısı ise HbO işaretinde 18, HbR işaretinde 20 ve HbO+HbR işaretinde 12'dir. Sol el olarak yanlış sınıflandırılmış örnek sayısı bulunmamaktadır. Bu çalışmada kullanılmış olan RO sınıflandırıcısı sol el sınıflandırma örneğinde yüksek başarı sağlarken sağ el örneğinde az da olsa yanlış sınıflandırma örneklemini yaparak sol el çıkarmıştır. Bu durumun giderilmesi ve önerilen sınıflandırıcı başarılarını daha da artırılması için farklı öznitelikler veya farklı sinyal işleme yöntemleri kullanılabilir.

HbO işareti için sınıflandırma %84.4828 olarak elde edilmiş İken HbR işareti için %82.7586 olarak hesaplanmıştır. Bu çalışmada ek olarak HbO işareti ile HbR işareti birleştirilmiş ve HbO+HbR işaretinin sınıflandırma doğruluğu %89.6552 olarak elde edilmiş ve başarı yüzdesinin arttığı gözlemlenmiştir.

Literatürde yer alan çalışmalardan birkaçı ile bu çalışma sonuçlarının karşılaştırılması Tablo 3'de gösterilmiştir.

Literatürde motor hayali hareketi tabanlı EEG sınıflandırma çalışmasında yüksek doğruluk elde edilmiş çalışmalar bulunmaktadır. Fakat BCI sistemlerinde NIRS kullanımı kolaylık ve uygulanabilirlik açısından artmaya başlamıştır. Literatüre baktığımızda sağ-sol el açıp-kapama motor hareketi hayali tabanlı sınıflandırma az bulunmakla birlikte yüksek başarıyı içermesi açısından da azdır. BCI sistemini geliştirmek ve test etmek için daha fazla çalışma yapılması lazımdır. NIRS sinyalinden yararlanmak için yeni sinyal işleme, öznitelik ve sınıflandırma yöntemlerinin geliştirilmesi gerekmektedir. NIRS'ın kullanımında iletken jelle gerek olmadığından kullanımı daha kolaydır. NIRS, iyonlaştırıcı değildir ve uzun süreli kullanımlar için uygundur. Bu çalışmada, Tablo 3'de görüldüğü gibi farklı öznitelikler kullanarak yüksek sınıflandırma doğruluğu elde edilip motor hareket hayali tabanlı NIRS sinyallerinin BCI sisteminin kullanımına katkıda bulunabileceği saptanmıştır.

BEYİN BİLGİSAYAR ARAYÜZÜNÜN GELİŞTİRİLMESİ İÇİN HAYALİ MOTOR GÖRÜNTÜ TABANLI YAKIN KIZILÖTESİ SPEKTROSKOPİ SİNYALLERİNİN SINIFLANDIRILMASI**Tablo 3.** Çalışma sonuçlarının literatürde bulunan çalışmalar ile karşılaştırılması

Referans No	Kullanılan fizyolojik sinyal	Ön işleme	Öznitelik	Sınıflandırıcı	Sınıflandırıcı doğruluk yüzdesi
[6]	NIRS	Ampirik mod ayrıştırması	Ortalama, eğim	Doğrusal ayırıcı analiz	77.56, 87.28
[7]	NIRS	*****		Destek vektör makinesi , Hiddin markow	73,89
[8]	NIRS	*****	Kernel tabanlı sinyal yerleştirme	Destek vektör makinesi	74.10
[9]	NIRS	0.01 ve 0.1 Hzlik 6. Dereceden Butterworth filtresi ile ön işlemden geçirilmiş	Ortak uzumsal örüntüleme	Doğrusal ayırıcı analiz	HbO=63.50 HbR=66.50
[10]	NIRS	0.2-0.7 Hzlik 2. Dereceden Butterworth filtresi uygulayarak önışlemeden	Katz fraktal boyut	k-en yakın komşuluk	HbO=70.14 HbR=72.36
Bu Çalışma İçin Önerilen yöntem	NIRS	Ayrık Dalgacık Dönüşümü	Varyans, standart sapma, entropi, çarpıklık, basıklık, ortalama enerji	Rasgele Orman	HbO=84.4828 HbR=82.7586 HbO+HbR=89.6552

TEŞEKKÜR

Bu çalışmada kullanmış olduğumuz veri setini [11] açık erişime sunmuş olmalarından dolayı Shin ve arkadaşlarına teşekkür ediyoruz.

KAYNAKLAR

- [1] Kaya, M., Cömert, M., & Mıshchenko, Y., “Beyin Bilgisayar Arayüzü için DVM Makine Öğrenme Yöntemi Kullanılarak EEG Verilerinden Sağ ve Sol El Hareket Düşüncelerinin Tespiti”, Türk Bilim Araştırma Vakfı (TÜBAV), vol. 10, no.3, pp. 1-20, 2017.
- [2] Sitaram, R., Zhang, H., Guan, C., Thulasidas, M., Hoshi, Y., Ishikawa, A., Shimizu, K., & Birbaumer, N., “Temporal classification of multichannel near-infrared spectroscopy signals of motor imagery for developing a brain-computer interface”, NeuroImage, vol. 34, no. 4, Feb., pp. 1416-1427,2007.
- [3] Cui, X., Bray, A., & Reiss, A.L., “Speeded Near Infrared Spectroscopy(NIRS) Response Detection”, PloS one, vol. 5, no. 11, 2010, e15474.
- [4] Olgun, N., & Türkoğlu, İ., “Brain-Computer Interface Systems”, At 8th International Advanced Technologies Symposium, Elazığ, Turkey’ 01, 2017, pp. 2318-2327.

- [5] Hu, X.S., Hong, K.S., & Ge, S.S., “Recognition of stimulus-evoked neuronal optical response by identifying chaos levels of near-infrared spectroscopy time series”, *Neuroscience Letters*, vol. 504, no. 2, Oct., pp. 115-120, 2011.
- [6] Sitaram, R., Caria, A., & Birmaumer, N., “Hemodynamic brain-computer interfaces for communication and rehabilitation”, *Neural Networks*, vol. 22, no.9, Jun., pp.1320-1328, 2009.
- [7] Yin, X., Xu, B., Jiang, C., Fu, Y., Wang, Z., & Shi, G., “NIRS-based classification of clench force and speed motor imagery with the use of empirical mode decomposition for BCI”, *Medical Engineering & Physics* vol. 37, no.3, Mar., pp. 280-286, 2015.
- [8] Haihong, Z., & Cuntai, G., “A kernel-based signal localization method for nirs brain-computer interfaces”, In *Pattern Recognition 18th International Conference’ 08*, 2006, pp. 229-232.
- [9] Shin, J., von Lümann, A., Blankertz, B., Kim, D. W., Jeong, J., Hwang, H.j., & Müller, K. R., “Open Access dataset for EEG+NIRS single-trial classification”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol.25, no. 10, Nov., pp. 1735-1745, 2017.
- [10] Ergün, E., & Aydemir, D., “Classification of Motor Imaginary Based Near-Infrared Spectroscopy Signals”, *Signal Processing and Communications Applications Conference (SIU)’ 06*, 2018, pp. 1-4.
- [11] Shin, J., von Lümann, A., Blankertz, B., Kim, D. W., Jeong, J., Hwang, H.j., & Müller, K. R., “Open access dataset for simultaneous EEG and NIRS brain-computer interface(BCI)”, *The Berlin Brain-Computer Interface*, Oct 1, 2017. [Online]. Available: <http://doc.ml.tu-berlin.de/hBCI/> . [Accessed Oct. 10, 2018].
- [12] Naaser, N., & Hong, K., “FNIRS-based brain-computer interfaces: a review”, *Front Hum Neurosci*, vol. 9, no. 3, Jan., pp. 172, 2015.
- [13] Kaya, Y., & Tekin, R., “Epileptik Nöbetlerin Tespiti için Aşırı Öğrenme Makinesi Tabanlı Uzman Bir Sistem”, *Bilişim Teknolojileri Dergisi*, vol. 5, no. 2, Sep., pp. 33-39, 2012.
- [14] Palabaş, T., “Ayrık Dalgacık Dönüşümü Bileşenlerine Ait İstatistiksel Veriler ile Epileptik EEG İşaretlerinin Sınıflandırılması”, *AJIT-e: Online Academic Journal of Information Technology*, vol. 15, no.5, pp. 49-56, 2015.
- [15] Jahankhani, P., Kodogiannis, V., & Revett, K., “EEG Signal Classification Using Wavelet Feature Extraction and Neural Networks”, *IEEE John Vincent Atanasoff 2006 International Symposium on Modern Computing(JVA’06)*, 2006, pp. 120-124.
- [16] Koçyiğit, Y., & Korürek, M., “EMG işaretlerini dalgacık dönüşümü ve bulanık mantık sınıflayıcı kullanarak sınıflama”, *İtÜdergisi/d mühendislik* vol. 4, no. 3, Jun., pp. 25-31, 2005.
- [17] Güven, A., Altınkaynak, M., Dolu, N., İzzetoğlu, M., Pektaş, F., Özmen, S., Demirci, E., & Batbat, T., “Combining functional near-infrared spectroscopy and EEG measurements for the diagnosis of attention-deficit hyperactivity disorder”, *Neural Computing and Applications*, Jul., pp. 1-14, 2019.
- [18] Cawley, G.C., & Talbot, N., “Fast exact leave-one-out cross-validation of sparse least-squares support vektör machines”, *Neural NetWorks*, vol. 17, no. 10, Dec., pp. 1467-1475, 2004.
- [19] Kho, J., “Why Random Forest is My Favorite Machine Learning Model”, *Towards Data Science*, Oct 20, 2018. [Online]. Available: <https://towardsdatascience.com/why-random-forest-is-my-favorite-machine-learning-model-b97651fa3706> . [Accessed Oct. 20, 2018].
- [20] Buettner, R., Sauer, S., Maier, C., & Eckhardt, A., “Towards Ex Ante Prediction of User Performance: A Novel Neurols Methodology Based on Real-Time Measurement of Mental Effort”, *2015 48th Hawaii International Conference on System Sciences’ 01*, 2015, pp. 1530-1605.
- [21] Bentlemsan, M., Zemouri, E., Bouchaffra, D., Zoubir, B.Y., & Ferroudji, K., “Random Forest and Filter Bank Common Spatial Patterns for EEG-Based Motor Imagery Classification”, *5th International Conference on Intelligent Systems, Modelling and Simulation’01*, 2015.
- [22] Okumuş, H., & Aydemir, Ö., “Random forest classification for brain computer interface applications”, *Signal Processing and Communications Applications Conference (SIU)’ 06*, 2017, pp. 1,4.

