



# El Sıkma Hareketinin İşlevsel Yakın Kızılaltı Spektroskopisi ve Elektromiyografi Sinyalleri Kullanılarak Sınıflandırılması

## Classification of Hand-Grip Movement Using Functional Near-Infrared Spectroscopy and Electromyography

Aykut Eken<sup>1</sup>

<sup>1</sup> TOBB Ekonomi ve Teknoloji Üniversitesi, Biyomedikal Mühendisliği Bölümü, [aykuteken@etu.edu.tr](mailto:aykuteken@etu.edu.tr)  
ORCID: <https://orcid.org/0000-0002-7023-7930>

### MAKALE BİLGİLERİ

#### Makale Geçmişi:

Geliş 1 Aralık 2022  
Revizyon 8 Ocak 2023  
Kabul 16 Ocak 2023  
Online 23 Mart 2023

#### Anahtar Kelimeler:

El sıkma,  
iYKAS,  
EMG,  
Makine Öğrenmesi

### ÖZ

El hareketinin sınıflandırılması, özellikle inme rahatsızlığı geçiren kişilerde nörorehabilitasyon amaçlı beyin bilgisayar arayüzü (BBA) modellerinin geliştirilmesinde büyük önem arz etmektedir. Ancak, el hareketi odaklı BBA modellerinin geliştirilmesinde kullanılan kas ve beyin aktivitesi ölçüm modalitelerinin tek başlarına kullanılmasında, nörolojik adaptasyon ve bazı hasta gruplarının nöromusküler hastalık barındırması gibi çeşitli problemler bulunmaktadır. Bu çalışmada bir kavrama kuvveti görevi aracılığı ile gerçekleştirilen el hareketinin sonucu elde edilen işlevsel yakın kızılaltı spektroskopisi (iYKAS) ve elektromiyografi (EMG) sinyalleri kullanılarak el hareketinin sınıflandırılması gerçekleştirilmiştir. Bu sinyallerden çıkarılan öznitelikler, L1 norm tabanlı bir destek vektör makinesi (DVM) ile seçildikten sonra, K-en yakın komşuluk, doğrusal ve radyal temelli DVM, Gradyan Artırma, Adaboost, Naive Bayes, Doğrusal Diskriminant, Kuadratik Diskriminant ve Lojistik regresyon sınıflandırıcılara verilmiştir. Sınıflandırıcıların başarımı, bir katılımcıyı dışarıda bırak (leave-one-subject-out) çapraz geçerliliği uygulanarak gerçekleştirilmiştir. Sınıflandırıcılar arasında en yüksek doğruluk yüzdesi, iYKAS ve EMG odaklı özniteliklerden faydalanılarak, Doğrusal Diskriminant metodu ile %84 olarak bulunmuştur. Sonuçlarımız bize işlevsel yakın kızılaltı spektroskopisi ve elektromiyografi verilerinin el hareketinin sınıflandırılmasında kullanılabileceğini ve bunun BBA sistemlerine de entegre edilebileceğini ortaya koymaktadır.

### ARTICLE INFO

#### Article history:

Received 1 December 2022  
Received in revised form 8 January 2023  
Accepted 16 January 2023  
Available online 23 March 2023

#### Keywords:

Hand-Grip,  
fNIRS,  
EMG,  
Machine Learning

### ABSTRACT

Classification of hand movement is of great importance in the development of brain-computer interface (BCI) models for neurorehabilitation, particularly in stroke patients. However, there are various problems in the application of muscle and brain activity measurement modalities used in the performance of hand movement-oriented BCI systems, such as neurological adaptation and neuromuscular disease in some patient groups. In this study, classification of hand movement was performed using functional near infrared spectroscopy (fNIRS) and electromyography (EMG) signals obtained as a result of hand movement performed through a grip strength task. Features extracted from these signals are given to K-nearest neighbor, linear and radial basis SVM, Gradient Boost, Adaboost, Naive Bayes, Linear Discriminant, Quadratic Discriminant and Logistic regression classifiers after they are selected with an L1 norm-based support vector machine (SVM). The performance of the classifiers was achieved by applying the leave-one-subject-out cross-validation. Among the classifiers, the highest percentage of accuracy was found to be 84% with the Linear Discriminant method, using iYKAS and EMG focused features. Our results reveal that functional near-infrared spectroscopy and electromyography data can be used to classify hand movement and can be integrated into BCI systems.

Doi: 10.24012/dumf.1212691

\* Sorumlu Yazar

## Giriş

Beyin-bilgisayar arayüzleri (BBA) veya Beyin-makine arayüzleri insanların dış dünyadaki nesnelere haberleşmesi için kullanılan donanımsal ve yazılımsal bir haberleşme sistemidir [1]. BBA'nin başta tıp [2] olmak üzere, endüstriyel [3], sosyal araştırmalar [4] ve nörorehabilitasyon [5-7] gibi çeşitli uygulama alanları bulunmaktadır. Sistemsel olarak BBA, işlevsel manyetik rezonans görüntüleme (iMRG) [8], Elektroensefalografi (EEG) [9], işlevsel yakın kızılaltı spektroskopisi (iYKAS) [10] ve magnetoensefalografi (MEG) [11] gibi çeşitli invaziv olmayan nörogörüntüleme teknikleri kullanılarak elde edilen sinyallerin, belirli ön işleme aşamalarından geçirildikten sonra, bu sinyallerden çıkartılan özneliklerin yapay zeka yöntemleri ile sınıflandırılması ve bu sınıflandırma sonucunda ortaya çıkan cevabın (örn: el hareketini gerçekleştirme) dış dünyadaki nesnelere haberleşmesi sürecini içerir. BBA'lerinde bu nörogörüntüleme modalitelerinin içerisinde iYKAS son yıllarda gittikçe popülerlik kazanmaktadır [10]. Bunun en önemli sebebi, iYKAS sistemlerinin iMRG'ye kıyasla daha ucuz, taşınabilir ve zamansal çözünürlüğünün yüksek, EEG'ye nazaran ise uzaysal çözünürlüğünün yüksek ve her iki modaliteye kıyasla hareket artefaktlarına karşı daha az duyarlı olmasıdır [12].

iYKAS, yaklaşık olarak 600-1000 nm aralığındaki yakın kızıl altı ışık spektrumunda insan beynindeki damarlardaki HbO ve Hb'nin ölçülmesinde kullanılan optik bir sistemdir. iYKAS kullanılarak genellikle, kaynak-dedektör mesafesine bağlı olarak kafatası yüzeyinin yaklaşık 2-3 cm altında bulunan kortikal yapılarda hemodinamik cevap gözlemlenir. Bunun yanı sıra, bu spektranın içinde hemodinamik aktivitenin oluşması, oksihemoglobin (HbO) ve deoksihemoglobin'in (Hb) uygulanan yakın kızıl altı ışığa karşı davranışı ile doğrudan ilişkilidir. BBA modellerinde iYKAS, özellikle EEG ile birlikte kullanıldığı durumlarda genellikle tek bir modalite ile kullanıldığı durumlara nazaran daha yüksek doğruluk sonuçları raporlanmaktadır [10]. Bununla birlikte BBA'lerinde kullanılan EEG sistemlerine ek olarak özellikle nörorehabilitasyon uygulamalarında elektromiyografi (EMG) de bu sistemlere veri sağlayıcı olarak sıklıkla kullanılmaktadır [13-15].

BBA modellerinin eğitilmesinde kullanılan, beyin ve kaslardan alınan sinyaller tek başlarına çeşitli problemler içermektedir. Beyinden elde edilen sinyaller genellikle katılımcılara özel bir nörolojik adaptasyon gerektirmekte ve bu adaptasyon gerçekleşmediği sürece genellikle BBA sistemlerinde çok düşük sınıflandırma doğrulukları elde edilmektedir [16]. Öte yandan, kastan elde edilen sinyallerde ise bazı hastalık gruplarının nöromusküler hastalıklar da barındırabileceğinden özellikle

elektrofizyolojik cevaplarda bu hastalıklara bağlı anomaliler gösterebilecektir [17, 18]. Bu handicaplara araştırmacıları kas ve beyinden elde edilen sinyalleri birlikte kullanılabilecek yaklaşımlar oluşturarak BBA modelleri eğitilmesine yönlendirmiştir. Bu çalışmalar içerisinde, klasik yaklaşım olan kas ve beyinden alınan verilerden çıkartılan öznelik füzyonu da kullanılırken [19-23], aynı zamanda bu yaklaşımdan bağımsız olarak EEG ve EMG sinyallerinden çıkartılan kortikomusküler koherans da kullanılmıştır [15, 17]. Bu çalışmada uzaysal çözünürlüğü EEG'den daha yüksek olan iYKAS sistemi ve EMG'den toplanmış sinyaller kullanılarak el sıkma hareketinin sağ ya da sol el tarafından yapıldığının sınıflandırılması işlemi gerçekleştirilmiştir. Önceki yıllarda yakın kızılaltı spektroskopisi ve EMG çalışmaları genel olarak kas oksijenasyonunun gerçek zamanlı ölçümü üzerine kullanılmıştır [24]. Ancak, literatürde bildiğimiz kadarı ile iYKAS ile EMG'nin birlikte kullanıldığı, bir BBA modeli geliştirmeye yönelik bir çalışma bulunmamaktadır. Bunun için, çalışmamızda, dokuz makine öğrenmesi algoritması kullanarak, sadece iYKAS odaklı öznelikler, sadece EMG odaklı öznelikler ve hem iYKAS hem de EMG odaklı özneliklerin kullanıldığı BBA modelleri geliştirmeye çalışarak, modalitelerin ve algoritmaların başarımlarını üzerine etkisini gözlemlemeye çalıştık.

## Yöntem


Bu çalışmada Hibrid Dinamik Grip (Hybrid Dynamic-Grip, HYGRIP) veri seti kullanılmıştır [25]. Bu veri seti 14 sağlıklı sağ-el dominant katılımcıdan, bir motor kontrol görevi esnasında toplanan iYKAS, EEG, EMG, dinamometre kullanarak el sıkma kuvveti ve solunum verisini içermektedir. Bu çalışmada sadece EMG ve iYKAS verisi kullanılmıştır. Verilerin ön-işleme ve öznelik çıkarım aşamalarından MATLAB (Mathworks Co., MA, ABD) programlama dili kullanılmış olup, sınıflandırma aşamalarında, Python tabanlı bir kütüphane olan *scikit-learn* kullanılmıştır [26].

## Deneyel Tasarım

Çalışmada kullanılan veri bir motor kontrol deneyi esnasında elde edilmiştir. Bu deneyde hem sağ hem sol el kullanılarak, 10 kez (5 sağ el / 5 sol el) 21 saniyelik blok içerisinde bir dinamometrenin sıkılması görevi gerçekleştirilmiştir. Her bir 20 saniyelik blok içerisinde 10 kez (1.55 saniye sıkma / 0.55 saniye dinlenme) sıkma deneyi her iki el için gerçekleştirilmiştir. Deneyel tasarım şekil 1. de gösterilmektedir.

## EMG Sinyal Kaydı ve Ön-İşleme

EMG sinyal kaydı ActiChamp sistemi aracılığı ile gerçekleştirilmiştir (Brain Products, Berlin, Almanya). Sinyalin örnekleme frekansı 4 kHz dir. EMG sinyali için bir aktif biri referans olmak üzere iki elektrot kullanılmış



Şekil 1. Deneysel tasarım.

olup, bu elektrotlar *flexor digitorum superficialis* kasının üzerine yerleştirilmiştir. Elde edilen EMG sinyalleri, ilk olarak 50 Hz şehir şebeke geriliminden 2. derece bir sonsuz dürtü tepkisi (Infinite Impulse Response-IIR) filtre kullanılarak arındırılmıştır. Bu işlem için MATLAB'daki *iirnotch* fonksiyonundan faydalanılmıştır. Daha sonra 5-450 Hz'lik 4. derece bir butterworth band geçiren filtre kullanılarak sinyalin yüksek frekanslardaki gürültüleri yok edilmiştir. Bu işlemlerden sonra, EMG sinyalimizin mutlak değerini alarak tam dalga doğrultması (full-wave rectification) gerçekleştirilmiştir. Tam dalga doğrultmasından sonra sinyalimiz 1 saniyelik hareketli ortalama filtre (moving average filter) ve 5 saniyelik hareketli ortalama karekökü (Root Mean Square) alınarak ile yüksek frekanslı bileşenler bastırılmıştır.

### İYKAS Sinyal Kaydı

iYKAS sinyalleri, NIRScout iYKAS sistemi (NIRx Medizintechnik GmbH, Berlin, Almanya) kullanılarak toplanmıştır. Sistemin, ölçüm aldığı dalga boyları 760 nm ve 850 nm iken, örnekleme frekansı 12.5 Hz'dir. Yakın kızılaltı ışık kaynağı ile dedektörler arasındaki mesafe 3 cm'dir. Dedektörlerden alınan optik yoğunluk değişimleri uyarlanmış Beer-Lambert yasası [27] kullanılarak oksihemoglobin ( $\Delta HbO$ ) ve deoksihemoglobin ( $\Delta Hb$ ) konsantrasyon değişimleri elde edilmiştir. Uyarlanmış Beer-Lambert yasasında,  $\lambda_1$  ve  $\lambda_2$  her 760 ve 850 nm dalga boylarını,  $d$  kaynak-dedektör arası mesafeyi, DPF fotonların dokuya gönderildikten sonra doku içerisinde katettiği ortalama mesafenin


kaynak dedektör mesafesine oranını,  $\Delta OD$  optik yoğunluk değişimini,  $\epsilon$  emilim katsayısını gösterdiğinde,  $\Delta HbO$  ve  $\Delta Hb$  yi elde etmek için;

$$\begin{bmatrix} \Delta OD_{\lambda_1} \\ \Delta OD_{\lambda_2} \end{bmatrix} = \begin{bmatrix} \epsilon_{Hb}^{\lambda_1} d DPF & \epsilon_{HbO}^{\lambda_1} d DPF \\ \epsilon_{Hb}^{\lambda_2} d DPF & \epsilon_{HbO}^{\lambda_2} d DPF \end{bmatrix} \begin{bmatrix} \Delta Hb \\ \Delta HbO \end{bmatrix} \quad (1)$$

eşitliğini kullanırız. Burada değişim kavramının kullanılmasındaki temel amaç, deney başlamadan önce elde edilecek olan referans  $HbO$  ve  $Hb$  değerlerinin deney başladıktan sonra değişim miktarını temsil etmektir. DPF değeri bu çalışmada 760 nm için 5.98, 850 nm için 7.54 olarak kullanılmıştır.

### İYKAS Ön-İşleme

Toplanan iYKAS sinyallerinin öncelikle kalite kontrolü gerçekleştirildi. Bunun için her katılımcının ayrı ayrı kanallarının Welch metodu ile güç spektrumları incelenerek kanallarda kalp atımına karşılık gelen yaklaşık 1-1.5 Hz arasında bir güç spektrumunun olup olmadığı kontrol edilmiştir [30, 31]. Bu durum kanallardaki kafatası-optod kuplajının başarılı bir şekilde yapıldığını göstermektedir. Kalp atımının güç spektrumunda temsiliyeti olmayan kanallar ihmal edilmiştir. Sinyal kalitesinin kontrolünden sonra dalgacık dönüşümü tabanlı filtreleme gerçekleştirilerek iYKAS sinyallerinde görülen hareket artefaktları yok edilmiştir [32]. Kalp atımı ve solunum gibi fizyolojik gürültüleri yok etmek için 0.001-0.3 Hz kesim frekansları olan 2. derece bir bant geçiren butterworth filtre kullanılmıştır. Örnek bir ön-işleme sonucu Şekil 2.'de gösterilmektedir.



Şekil 2. iYKAS ön işleme örneği. Üstteki grafikte ham, alttaki grafikte filtrelenmiş  $\Delta HbO$  sinyalleri görülmektedir.

EMG ve iYKAS sinyallerde ön işleme tamamlandıktan sonra tüm uyarılar (sağ el ve sol el) için EMG ve iYKAS tepkileri, 2 sn uyarın öncesi (pre-stimulus) ve 30 saniye uyarın sonrası (post-stimulus) olmak üzere çıkarılmıştır. Şekil 1.'de gösterilen deneysel tasarımda 21 saniye süren kavrama kuvveti görevinden, 9 saniye daha uzun bir uyarın sonrası veri alınmasının sebebi iYKAS sinyallerinin uyarın öncesi haline dönmüş halinin elde edilmesi içindir. 14 katılımcıdan toplamda 328 (164 sağ, 164 sol) tane uyarın sonrası cevap elde edilmiştir.

### İYKAS Kanal Konfigürasyonu

Optodlar, merkezi EEG 10-20 sistemindeki C3 ve C4 kanallarına denk gelecek şekilde 3 x 3 olarak iki grid şeklinde iki yarımküreye yerleştirilmiştir. C3 ve C4 elektrot pozisyonlarının primer motor korteks bölgelerine karşılık geldiği geçmiş çalışmalardan bilinmektedir [28, 29]. Her bir grid'de 5 tane kaynak ve 4 tane de dedektör olarak toplamda 10 kaynak ve 8 dedektörden ölçüm alınmaktadır. Kanal konfigürasyonu Şekil 3'de gösterilmektedir.

### Öznitelik Çıkartımı ve Seçimi

Öznitelik çıkartımı her bir el sıkma denemesinde (sağ el ve sol el) İYKAS için her bir kanaldan elde edilen sinyallerin ilgili ön işleme süreçlerini tamamladıktan sonra;

- Maksimum  $\Delta HbO$  değeri
- Minimum  $\Delta Hb$  değeri
- $\Delta HbO$  ve  $\Delta Hb$ 'nin standart sapması
- $\Delta HbO$  ve  $\Delta Hb$ 'nin çarpıklık (skewness) değeri
- $\Delta HbO$  ve  $\Delta Hb$ 'nin basıklık (kurtosis) değeri

- Ortalama  $\Delta HbO$  ve  $\Delta Hb$  değeri

iYKAS tabanlı öznitelikler tüm kanallardan (24 kanal) alındı. Dolayısı ile toplamda 240 tane öznitelik sadece iYKAS sinyallerinden çıkartıldı. Bu özniteliklere ek olarak EMG sinyalinin;

- Maksimum genlik değeri
- Ortalama genlik değeri
- Standart sapması
- Çarpıklık (skewness) değeri
- Basıklık (kurtosis) değeri

çıkartılmış olup toplamda 245 tane öznitelik elde edildi. Dolayısı ile sınıflandırma için öznitelik seçimi yapacağımız öznitelik vektörümüzün boyutları 328 x 245 olmuş oldu. Öznitelik vektörünü oluşturduktan sonra, uç değerleri normalize etmek için tüm özniteliklere Z-skor normalizasyonu uygulandı. Öznitelik seçimi için L1 cezalandırma yaklaşımı tabanlı bir öznitelik seçimi gerçekleştirdik ve yöntem olarak doğrusal destek vektör makinesini (DVM) kullandık [33]. DVM kullanılarak öznitelik seçiminin temel yaklaşımı; düzenleme parametresi (C) seyrekliği kontrol etmektedir. Düşük bir C değeri daha az öznitelik seçimi anlamına gelir. Burada da düzenleme parametresi C=0.01 olarak alınmıştır. L1 normlu DVM kullanarak öznitelikler seçerken, eğer veri setimize c tane örneklem içeren D der isek;

$$D = \{(s_i, l_i) | s_i \in R^d, l_i \in (-1, +1)\}_{i=1}^c \quad (2)$$

Denklem 2'de,  $s_i$  d tane özniteliği olan i. örneği ve  $l_i$  karşılığı olan sınıf etiketini göstermektedir.  $s_i$  d boyutlu satır vektörü olarak gösterilmektedir  $s_i = [s_{i1}, s_{i2}, s_{i3}, \dots, s_{id}]$ . Denklem 2. de ifade ettiğimiz üzere eğer bu problem iki sınıfı sınıflandırma problem

olarak varsayarsak, DVM'nin ayırt edici hiperdüzlemi denklem 3'deki gibi gösterilir.

$$w^T s_i + b = l_i \quad (3)$$

Bu denklemde,  $w$  ağırlık vektörü ve  $b$  yanlılığı (bias) temsil etmektedir. Hedefimiz bu hiperdüzlemin marjin mesafesi olan  $(\frac{2}{\|w\|})$  değerini  $w$ 'yi minimize ederek maksimize etmektir. Bunu gerçekleştirmek için maliyet fonksiyonumuz denklem 4'de gösterilmektedir.

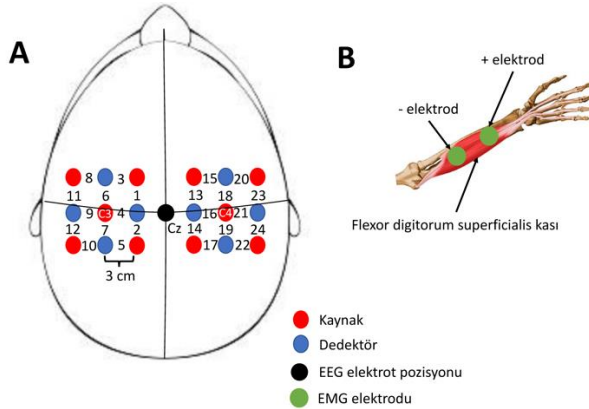
$$\min_{w,b,\xi} C \sum_{i=1}^c \xi(w, b; s_i, l_i) + \frac{1}{2} \|w\|_1 \quad (4)$$

$$\begin{cases} l_i(w^T s_i + b) \geq 1 - \xi(w, b; s_i, l_i) \\ \xi(w, b; s_i, l_i) \geq 0, \quad i = \overline{1, c} \end{cases}$$

Bu denklemlerde,  $s_i, l_i$ 'ye bağlı olan  $\xi$  gevşek değişkendir. Bu noktada,  $k$  sayıda optimal öznelik  $d$  tane öznelik arasından çıkarmamız gerekmektedir ( $1 \leq k \leq d$ ). Bunu gerçekleştirirken her bir özneliğin karşılık geldiği ağırlığı göz önüne alırız. Eğer bu ağırlıklar 0'dan büyük ise bu öznelikler seçilir. Daha sonra, optimizasyon problem denklem 5'deki gibi tanımlanır.

$$\min_{w,b} C \sum_{i=1}^c \max(0, 1 - l_i(w^T s_i + b))^2 + \frac{1}{2} \|w\|_1 \quad (5)$$

Her öznelik için  $w$  bulduktan sonra,  $w = 0$  olan öznelikleri öznelik matrisimizden çıkarttık.



Şekil 3. A) iYKAS optodlarının kafa yüzeyinde dizilim konfigürasyonu. B) EMG elektrotlarının flexor digitorum superficialis kası üzerindeki yerleşimi.

### Sınıflandırma

Öznelik seçiminden sonra, çalışmamızda sağ ve sol el hareketini sınıflandırmak için K-en yakın komşuluk (K-EYK), doğrusal ve radyal temelli DVM, Gradyan Artırma (GA), Adaboost, Naive Bayes (NB), Doğrusal Diskriminant, Kuadratik Diskriminant ve Lojistik regresyon yaklaşımları kullanılmıştır. Öznelik çıkarımını ve seçimini yaptıktan sonra elde edilen öznelik vektörü üzerinde sınıflandırma işlemini gerçekleştirilirken, bir katılımcıyı dışarıda bırakmalı çapraz geçerlilik yöntemi (leave-one-subject-out cross-validation - LOSOCV) uygulanmıştır. Bu yöntemde

klasik birini dışarıda bırak çapraz geçerliliğinden farklı olarak ilgili katılımcıdan elde edilen tüm veri test verisi olarak kullanılırken, diğer katılımcılardan elde edilen veriler eğitim verisi olarak kullanılır. LOSOCV'yi kullanmaktaki temel amaç, sınıflandırıcının her bir katılımcı için performansını gözlemlemektir ve BBA çalışmalarında modelin başarımını test etmek için sıklıkla tercih edilen bir çapraz geçerlilik yaklaşımıdır[34-36]. Bununla birlikte çalışmamızda duyarlılık (sensitivity) ve özgüllük (specificity) sonuçları hesaplanırken Tablo 3. deki gibi bir karışıklık matrisi (confusion matrix) uygulanmıştır. Bu karışıklık matrisinde doğru pozitif (DP), yanlış pozitif (YP), doğru negatif (DN) ve yanlış negatif (YN) sağ ve sol el için tablodaki gibi temsil edilmiştir. Duyarlılık hesaplaması yapılırken tüm sol el sınıflarının % kaçını sol el olarak sınıflandırdığı (DP/(DP + YN)) ve özgüllük hesaplaması yapılırken (DN/(DN + YP)) tüm sağ el sınıflarının % kaçını sağ el olarak sınıflandırdığı belirlenmiştir.

Tablo 3. Karışıklık Matrisi

Gerçek Sonuç \ Model Sonucu	Sol El	Sağ El
Sol El	DP	YP
Sağ El	YN	DN

### Sonuçlar

Öznelik seçimimiz sonrası çalışmamızda toplamda 6 tane öznelik seçimi gerçekleştirdik. Bu kullanılan öznelikler Tablo 1.'de gösterilmektedir.

Tablo 1. L1 norm tabanlı DVM tarafından seçilen öznelikler

MODALİTE	KULLANILAN ÖZNELİK
İYKAS	<ul style="list-style-type: none"> <li>Kanal 15 (C4 superior horizontal-anterior) ortalama <math>\Delta Hb</math></li> <li>Kanal 16 (C4 superior horizontal-coronal) ortalama <math>\Delta Hb</math></li> <li>Kanal 19 (C4 horizontal-posterior coronal) Maksimum <math>\Delta HbO</math></li> <li>Kanal 20 (C4 inferior horizontal anterior) maximum <math>\Delta HbO</math></li> </ul>
EMG	<ul style="list-style-type: none"> <li>Maksimum EMG genliği</li> <li>EMG zaman serisinin basıklık değeri</li> </ul>

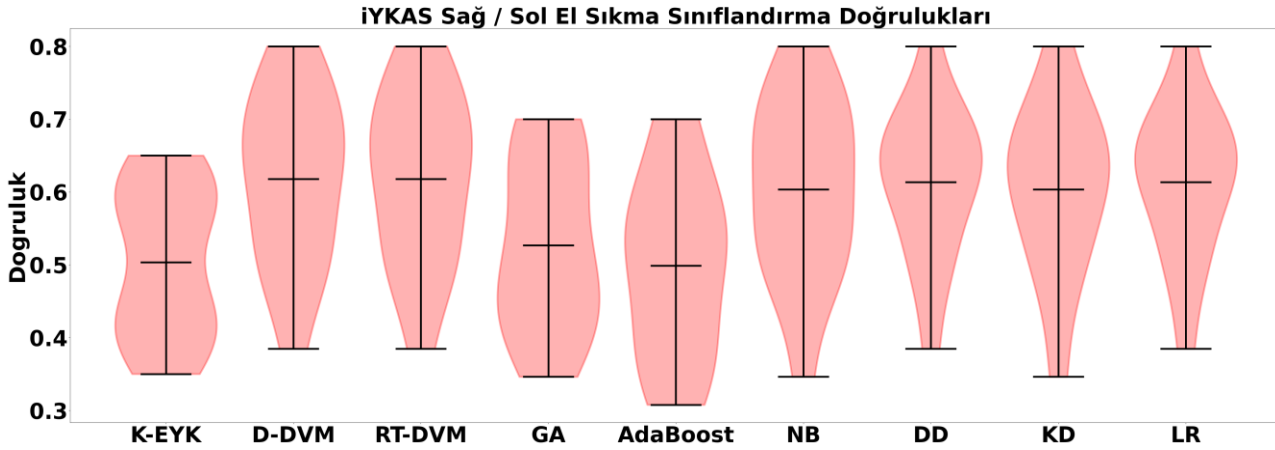
Öznitelikler çıkartıldıktan sonra hem İYKAS, hem EMG, hem de her iki modaliteden alınan öznitelikler birleştirilerek dokuz sınıflandırma algoritması kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Tablo 1’de gösterilen İYKAS tabanlı özniteliklerden elde ettiğimiz sınıflandırma sonuçları Tablo 2.’de ve Şekil 4.’de verilmiştir. Buna göre, İYKAS tabanlı öznitelikler kullanılarak bulunan en yüksek ortalama doğruluk, % 61 oranında Doğrusal DVM, Radyal tabanlı DVM, Doğrusal Diskriminant ve Lojistik Regresyon kullanılarak bulunmuştur. Diğer sınıflandırıcılara da bakıldığında genel olarak doğruluk değeri % 50 – 61 arasında

değişmektedir. Bu tek başına düşük bir sınıflandırma yüzdesidir. Öte yandan Tablo 1.’de verilen EMG tabanlı özniteliklerden elde ettiğimiz sonuçlar Tablo 2.’de ve Şekil 5.’de verilmiştir. EMG tabanlı özniteliklerle gerçekleştirilen sınıflandırma sonucunda, ortalama en yüksek doğruluk değeri %83 olarak Doğrusal Diskriminant algoritması tarafından bulunmuştur. EMG kullanılan öznitelikler ile yapılan sınıflandırmalarda bulunan doğruluk değerleri % 61-83 arasında bulunmuştur. Buradan kıyaslandığında EMG tabanlı özniteliklerin ayırt ediciliği İYKAS tabanlı özniteliklere nazaran daha yüksektir.


Tablo 2. Sınıflandırma işlemi sonrası tüm katılımcılar için ve ortalama doğruluk sonuçları. K-EYK: K-en yakın komşuluk, D-DVM: Doğrusal Destek Vektör Makinesi, RT-DVM: Radyal Tabanlı Destek Vektör Makinesi, GA: Gradyan Arttırma, NB: Naive Bayes, DD: Doğrusal Diskriminant, KD: Kuadratik Diskriminant, LR: Lojistik Regresyon. Ort.: Ortalama. Std.: Standart sapma, Alg: Algoritma, Mod.: Modalite

		Katılımcılar														
Alg.	Mod.	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14	Ort.± Std.
K-EYK	İYKAS	0.60	0.57	0.42	0.42	0.53	0.61	0.65	0.35	0.60	0.40	0.60	0.42	0.46	0.38	0.50 ± 0.10
	EMG	0.45	0.50	1.00	0.50	1.00	1.00	0.80	0.80	1.00	0.70	0.50	0.46	0.96	1.00	0.76 ± 0.23
	İYKAS + EMG	0.75	0.61	0.88	0.61	0.73	0.84	0.90	0.85	0.95	0.75	0.70	0.53	0.80	0.88	0.77 ± 0.12
D-DVM	İYKAS	0.75	0.69	0.61	0.38	0.61	0.80	0.65	0.70	0.50	0.75	0.53	0.50	0.50	0.50	0.61 ± 0.12
	EMG	0.50	0.50	1.00	1.00	1.00	1.00	0.80	0.25	1.00	0.80	0.45	0.50	0.96	1.00	0.76 ± 0.26
	İYKAS + EMG	0.80	0.65	0.92	0.65	0.73	1.00	1.00	0.40	0.90	0.55	0.75	0.76	0.88	0.84	0.77 ± 0.17
RT-DVM	İYKAS	0.75	0.69	0.61	0.38	0.61	0.65	0.80	0.65	0.70	0.50	0.75	0.53	0.50	0.50	0.61 ± 0.12
	EMG	0.50	0.50	1.00	1.00	1.00	1.00	0.80	0.25	1.00	0.80	0.45	0.50	0.96	1.00	0.76 ± 0.26
	İYKAS + EMG	0.80	0.65	0.92	0.65	0.73	1.00	1.00	0.40	0.90	0.55	0.75	0.76	0.88	0.84	0.77 ± 0.17
GA	İYKAS	0.65	0.61	0.38	0.42	0.53	0.61	0.45	0.50	0.65	0.45	0.70	0.46	0.53	0.38	0.52 ± 0.10
	EMG	0.50	0.50	0.50	0.50	1.00	1.00	0.85	0.85	1.00	0.25	0.50	0.50	0.46	1.00	0.67 ± 0.26
	İYKAS + EMG	0.50	0.50	0.50	0.50	0.76	1.00	0.85	0.80	1.00	0.70	0.50	0.50	0.46	1.00	0.68 ± 0.21
Ada Boost	İYKAS	0.55	0.69	0.34	0.46	0.57	0.38	0.60	0.35	0.55	0.50	0.70	0.30	0.53	0.42	0.49 ± 0.12
	EMG	0.50	0.50	1.00	0.50	0.50	0.50	0.85	0.50	1.00	0.30	0.50	0.50	0.46	1.00	0.61 ± 0.23
	İYKAS + EMG	0.50	0.50	1.00	0.61	0.84	1.00	0.85	0.80	1.00	0.60	0.40	0.50	0.80	1.00	0.74 ± 0.19
NB	İYKAS	0.70	0.73	0.61	0.34	0.50	0.73	0.60	0.70	0.65	0.50	0.80	0.57	0.50	0.50	0.60 ± 0.10
	EMG	0.50	0.50	1.00	1.00	1.00	1.00	0.85	0.75	1.00	0.85	0.35	0.50	0.96	1.00	0.80 ± 0.20
	İYKAS + EMG	0.65	0.46	0.96	0.57	0.92	0.92	0.90	0.85	1.00	0.85	0.40	0.69	0.92	0.96	0.79 ± 0.10
DD	İYKAS	0.70	0.69	0.61	0.38	0.53	0.69	0.65	0.60	0.65	0.65	0.80	0.61	0.50	0.50	0.61 ± 0.11
	EMG	1.00	0.50	1.00	1.00	0.84	1.00	0.90	0.80	1.00	0.70	0.50	0.50	0.92	1.00	0.83 ± 0.23
	İYKAS + EMG	0.85	0.73	0.92	0.65	0.76	0.96	1.00	0.90	0.90	0.90	0.70	0.80	0.76	0.88	0.84 ± 0.20
KD	İYKAS	0.70	0.73	0.50	0.34	0.61	0.65	0.55	0.65	0.65	0.60	0.80	0.65	0.53	0.46	0.60 ± 0.11
	EMG	0.50	0.50	1.00	1.00	1.00	1.00	0.85	0.75	1.00	0.85	0.35	0.50	0.96	1.00	0.80 ± 0.23
	İYKAS + EMG	0.40	0.69	0.92	0.69	0.96	0.96	0.90	0.85	1.00	0.85	0.40	0.61	0.92	1.00	0.79 ± 0.20

LR	iYKAS	0.70	0.69	0.61	0.38	0.53	0.69	0.65	0.60	0.65	0.65	0.80	0.61	0.50	0.50	0.61 ± 0.10
	EMG	1.00	0.50	1.00	1.00	0.96	1.00	0.75	0.75	1.00	0.70	0.45	0.50	0.96	1.00	0.82 ± 0.21
	iYKAS + EMG	0.85	0.53	0.96	0.73	0.96	1.00	0.85	0.90	0.95	0.75	0.55	0.76	0.88	0.96	0.83 ± 0.14



Şekil 4. Sadece iYKAS sinyallerinden elde edilen öznitelikler kullanılarak gerçekleştirilen sınıflandırma sonuçlarının keman grafiği ile gösterimi. Siyah çizgi ortalama değeri göstermektedir. Keman grafiğinde, simetrik olarak 14 katılımcıdan alınan doğruluk değerlerinin istatistiksel dağılımı görülmekte olup, ortalama değer ile ortanca değer hemen hemen birbirine yakındır. K-EYK: K-en yakın komşuluk, D-DVM: Doğrusal Destek Vektör Makinesi, RT-DVM: Radyal Tabanlı Destek Vektör Makinesi, GA: Gradyan Arttırma, NB: Naive Bayes, DD: Doğrusal Diskriminant, KD: Kuadratik Diskriminant, LR: Lojistik Regresyon



Şekil 5. EMG sinyallerinden elde edilen öznitelikler kullanılarak gerçekleştirilen sınıflandırma sonuçlarının keman grafiği ile gösterimi. Siyah çizgi ortalama değeri göstermektedir. Keman grafiğinde, simetrik olarak 14 katılımcıdan alınan doğruluk değerlerinin istatistiksel dağılımı görülmektedir. K-EYK: K-en yakın komşuluk, D-DVM: Doğrusal Destek Vektör Makinesi, RT-DVM: Radyal Tabanlı Destek Vektör Makinesi, GA: Gradyan Arttırma, NB: Naive Bayes, DD: Doğrusal Diskriminant, KD: Kuadratik Diskriminant, LR: Lojistik Regresyon


Öte yandan hem iYKAS hem de EMG tabanlı özniteliklerin füzyonu sonucu Tablo 1'de gösterilen toplam 6 öznitelik kullanılarak elde edilen sınıflandırma sonuçları Tablo 2. ve Şekil 6'da gösterilmektedir. Her iki modalite kullanıldığında ise en yüksek doğruluk değeri %84 olarak Doğrusal Diskriminant algoritması kullanılarak bulunmuştur. Bununla birlikte tüm algoritmalarda iYKAS ve EMG tabanlı özniteliklerin

kullanılması sonucu elde edilen doğruluk değerleri iYKAS tabanlı özniteliklerin kullanılması sonucu elde edilen doğruluk değerlerinden daha yüksek bulunmuştur. Öte yandan, dokuz algoritmanın yedi tanesinde iYKAS ile EMG tabanlı özniteliklerin kullanılması, EMG tabanlı özniteliklerden elde edilen doğruluk değerlerinden daha yüksek doğruluk değerleri bulurken, Naive Bayes ve Kuadratik Diskriminant algoritmalarında sadece

EMG'nin kullanılması dahi başarılı bir sonuç vermektedir. İstatistiksel olarak karşılaştırıldığında sadece AdaBoost algoritmasının kullanılmasında iYKAS ile EMG kaynaklı özneliklerin sağladıkları doğruluk değeri, sadece EMG kaynaklı özneliklerin sağladığı doğruluk değerinden anlamlı olarak daha yüksektir ( $t(13)=-2,569, p=0.023$ ).

Doğruluk değerlerinin yanı sıra 14 katılımcıdan LOSOCV sonucu alınan ortalama duyarlılık ve özgüllük sonuçları da Tablo 4.'de verilmiştir. Sonuçlara göre en yüksek doğruluk elde ettiğimiz iYKAS ve EMG özneliklerini kullanan doğrusal diskriminant

sınıflandırıcısı ile %80 oranında duyarlılık ve %87 oranında özgüllük elde ettik. Tüm sınıflandırıcılar ve modaliteler içerisinde en yüksek elde ettiğimiz duyarlılık sonucu doğrusal diskriminant ile %80 iken, Gradyan Arttırma sınıflandırıcısı ile %91 oranında bir özgüllük elde ettik. Ancak Gradyan Arttırma sınıflandırıcısının duyarlılık oranı her üç öznelik seti için de çok düşük değerlerde olduğu için bu sınıflandırıcı daha çok sağ el verisini sınıflandırmada duyarlı bir sınıflandırıcı olarak göze çarpmıştır. Dolayısı ile optimal düzeyde bakıldığında doğrusal diskriminant sınıflandırıcısının her iki sınıftan da veriyi %80 ve üstü bir başarımla sınıflandırdığını söylemek mümkündür.



Şekil 6. iYKAS ve EMG sinyallerinden elde edilen öznelikler birleştirilen sınıflandırma sonuçlarının keman grafiği ile gösterimi. Siyah çizgi ortalama değeri göstermektedir. Keman grafiğinde, simetrik olarak 14 katılımcıdan alınan doğruluk değerlerinin istatistiksel dağılımı görülmektedir. K-EYK: K-en yakın komşuluk, D-DVM: Doğrusal Destek Vektör Makinesi, RT-DVM: Radyal Tabanlı Destek Vektör Makinesi, GA: Gradyan Arttırma, NB: Naive Bayes, DD: Doğrusal Diskriminant, KD: Kuadratik Diskriminant, LR: Lojistik Regresyon

## Tartışma

Çalışmamızda, en yüksek doğruluğu, iYKAS ve EMG bazlı öznelikler ile Doğrusal Diskriminant algoritmasını kullanarak %84 olarak elde ettik. Bununla birlikte tüm algoritmalarda EMG ile iYKAS'ın birlikte kullanıldığı sınıflandırma sonuçlarında iYKAS'ın doğruluk değerlerine kıyasla doğruluk yüzdesinde artış gözlemledik. Çalışmamızda iYKAS odaklı özneliklere baktığımızda sağ motor korteks'e yakın bölgelerde  $\Delta HbO$  ve  $\Delta Hb$  odaklı öznelikler kullanılmıştır.  $\Delta HbO$  zaman serileri ağırlıklı olarak BBA sistemlerinde öznelik sağlayıcı olarak kullanılmaktadır [10]. Bunun en temel sebebi  $\Delta Hb$ 'e nazaran yüksek bir sinyal-gürültü-oranı (SGO) olmasıdır [37-40]. Ancak bunun yanısıra,  $\Delta Hb$  zaman serilerinin düşük SGO'ları olması da ekstraserebral ve intraserebral artefaktlardan az düzeyde etkilenmesinden kaynaklanabilir, bu da sağ ve sol el arasındaki sınıflandırmanın sağlanmasında etkili olabilir [41]. Bununla birlikte, sınıflandırmada kullanılan EMG bazlı öznelikler maksimum EMG genliği ve EMG zaman serisinin basıklık (kurtosis) değeridir. Bu öznelikler önceki yıllarda yapılan EMG tabanlı makine

öğrenmesi çalışmalarında en sıklıkla faydalanan özneliklerdendir [42]. Sınıflandırma skorlarına baktığımızda, EMG'nin iYKAS ile birlikte kullanılması efektif bir el sıkma hareketi odaklı bir BBA geliştirmek için yeterli olabilirken, algoritmaya bağlı olarak sadece EMG de yeterli olabilmektedir. iYKAS tek başına BBA modelleri geliştirmek için, özellikle motor icraatçı görevler (motor execution) sıklıkla kullanılmaktadır [43-46]. Bu çalışmada, en temel fark bir dinamometre ile el sıkma görevi gerçekleştirilmiştir. Benzer bir çalışmada, sağ ve sol el hareketlerinin bir dinamometre ile sıklığı sonucu elde edilen EEG sinyallerinden 8-30 Hz sensorimotor olaya ilişkin desenkronizasyon verisi kullanılarak yapılan el sıkılmasının kuvvet tahmini doğruluğu sağ el kullanılarak %55, sol el kullanılarak %53 olarak bulunmuştur. Katılımcılara, sağ ve sol elleri ile dinamometre sıkma paradigması uygulanan başka bir çalışmada, sadece iYKAS sinyalleri kullanılarak geliştirilen bir derin öğrenme modeli ile %80 oranında sağ / sol el sıkma tahmin edilmiştir [47]. Benzer başka iYKAS ve EMG çalışmasında ise sağ ve sol el sıkma arasındaki fark klasik doğrusal modellerle istatistiksel yöntemlerle ayırt edilememiştir [48].



Tablo 4. Sınıflandırıcıların LOSOCV sonucu duyarlılık (sol el sınıflandırma) ve özgülük (sağ el sınıflandırma) ortalamaları

Sınıflandırıcı	Modalite	Duyarlılık	Özgüllük
K-EYK	İYKAS	0.53	0.47
	EMG	0.64	0.88
	İYKAS + EMG	0.79	0.75
D-DVM	İYKAS	0.72	0.51
	EMG	0.64	0.89
	İYKAS + EMG	0.72	0.82
RT-DVM	İYKAS	0.72	0.51
	EMG	0.64	0.89
	İYKAS + EMG	0.72	0.82
GA	İYKAS	0.51	0.52
	EMG	0.35	0.91
	İYKAS + EMG	0.45	0.90
AdaBoost	İYKAS	0.51	0.48
	EMG	0.28	0.94
	İYKAS + EMG	0.59	0.89
NB	İYKAS	0.58	0.61
	EMG	0.71	0.89
	İYKAS + EMG	0.75	0.82
DD	İYKAS	0.62	0.60
	EMG	0.78	0.88
	İYKAS + EMG	0.80	0.87
KD	İYKAS	0.61	0.58
	EMG	0.71	0.89
	İYKAS + EMG	0.75	0.83
LR	İYKAS	0.62	0.60
	EMG	0.78	0.86
	İYKAS + EMG	0.80	0.86

Çalışmamızda bulduğumuz %84 doğruluk, daha önce bulunan doğruluk oranlarından daha yüksektir. Ayrıca tek bir modaliteden elde edilen doğruluk değerlerinden daha yüksek bir doğruluk değeri her iki modaliteden elde edilen özneliklerden elde edilmiştir. Bu da her iki modalitenin birlikte kullanılmasının avantajlı olacağını göstermektedir. Öte yandan, bireysel düzeyde sınıflandırma sonuçlarına baktığımızda, sınıflandırma skorları arasında yüksek bir değişkenlik gözlemlenmektedir. Sınıflandırıcı doğrulukları arasındaki %10 -26 arasında bir değişkenlik görülmektedir. Bu değişkenlik İYKAS sisteminden elde edilen  $\Delta HbO$  ve  $\Delta Hb$  sinyallerinin hem katılımcı bazında (intra-subject) hem de grup bazında (inter-subject) bir değişkenliğin olmasından kaynaklanabilir. Bu değişkenlik genel olarak, dikkat ve hafıza yükü gibi psiko-fizyolojik faktörlerin elde edilen sinyallere katkısından kaynaklanabilir [49]. Öte yandan bazı sınıflandırıcıların sağ ve sol el kavrama kuvvetinden elde edilen öznelikler sonucu spesifik olarak bir eli

sınıflandırmaya daha yatkın olduğu gözlemlenmiştir. Ancak en yüksek doğruluğu bulduğumuz doğrusal diskriminant algoritması bize hem sağ elde hem de sol el de %80 ve üstü başarı vererek her iki elin kavrama kuvveti sonucu elde edilen EMG ve İYKAS aktivitesini başarı ile sınıflandırmıştır.

## Sonuçlar

Bu çalışmada, İYKAS ve EMG ölçüm sistemleri kullanılarak el sıkma odaklı bir BBA sisteminin başarımı incelenmiştir. Çalışmada hem İYKAS tabanlı, hem EMG tabanlı öznelikler ile dokuz tane farklı sınıflandırma algoritması kullanılarak hem algoritmalar arasındaki sonuçlar hem de modalitelerden elde edilen özneliklerin etkinliği elde edilen doğruluk skorlarına göre karşılaştırılmıştır. Önerilen modaliteler ve öznelikler, özellikle inme gibi hastalıklarda nörorehabilitasyon amaçlı kullanılacak nöromusküler BBA yaklaşımlarını geliştirme konusunda ileriki çalışmalara fikir vermesi bakımından önemli olduğu düşünülmektedir. Literatürde daha önce herhangi bir EMG ve İYKAS tabanlı BBA çalışması bulunmadığından bu çıkartılan öznelik ve algoritmaların özelliklerinin başarımlarının karşılaştırılması için ileriki yıllarda bu alanda yapılacak çalışmalara ihtiyaç vardır.

## Etik Kurul Onayı ve Çıkar Çatışması Beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur ve herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

## Kaynaklar

- [1] L. F. Nicolas-Alonso and J. Gomez-Gil, "Brain computer interfaces, a review," *Sensors (Basel)*, vol. 12, no. 2, pp. 1211-79, 2012, doi: 10.3390/s120201211.
- [2] J. J. Shih, D. J. Krusienski, and J. R. Wolpaw, "Brain-computer interfaces in medicine," *Mayo Clinic proceedings*, vol. 87, no. 3, pp. 268-79, Mar 2012, doi: 10.1016/j.mayocp.2011.12.008.
- [3] C. L. Pulliam, S. R. Stanslaski, and T. J. Denison, "Industrial perspectives on brain-computer interface technology," *Handb Clin Neurol*, vol. 168, pp. 341-352, 2020, doi: 10.1016/B978-0-444-63934-9.00025-1.
- [4] J. Kogel, J. R. Schmid, R. J. Jox, and O. Friedrich, "Using brain-computer interfaces: a scoping review of studies employing social research methods," *BMC Med Ethics*, vol. 20, no. 1, p. 18, Mar 7 2019, doi: 10.1186/s12910-019-0354-1.
- [5] R. Carabalona, P. Castiglioni, and F. Gramatica, "Brain-computer interfaces and neurorehabilitation," *Studies in health technology and informatics*, vol. 145, pp. 160-76, 2009. [Online]. Available:

- <https://www.ncbi.nlm.nih.gov/pubmed/19592793>
- [6] <https://ebooks.iospress.nl/publication/12265>. S. Sreedharan, R. Sitaram, J. S. Paul, and C. Kesavadas, "Brain-computer interfaces for neurorehabilitation," *Critical reviews in biomedical engineering*, vol. 41, no. 3, pp. 269-79, 2013, doi: 10.1615/critrevbiomedeng.2014010697.
- [7] M. J. Young, D. J. Lin, and L. R. Hochberg, "Brain-Computer Interfaces in Neurorecovery and Neurorehabilitation," *Semin Neurol*, vol. 41, no. 2, pp. 206-216, Apr 2021, doi: 10.1055/s-0041-1725137.
- [8] R. Sitaram *et al.*, "fMRI brain-computer interface: a tool for neuroscientific research and treatment," *Comput Intell Neurosci*, p. 25487, 2007, doi: 10.1155/2007/25487.
- [9] S. Machado *et al.*, "EEG-based brain-computer interfaces: an overview of basic concepts and clinical applications in neurorehabilitation," *Rev Neurosci*, vol. 21, no. 6, pp. 451-68, 2010, doi: 10.1515/revneuro.2010.21.6.451.
- [10] N. Naseer and K. S. Hong, "fNIRS-based brain-computer interfaces: a review," (in eng), *Front Hum Neurosci*, vol. 9, p. 3, 2015, doi: 10.3389/fnhum.2015.00003.
- [11] J. Mellinger *et al.*, "An MEG-based brain-computer interface (BCI)," *Neuroimage*, vol. 36, no. 3, pp. 581-93, Jul 1 2007, doi: 10.1016/j.neuroimage.2007.03.019.
- [12] S. H. Kohl, D. M. A. Mehler, M. Luhrs, R. T. Thibault, K. Konrad, and B. Sorger, "The Potential of Functional Near-Infrared Spectroscopy-Based Neurofeedback-A Systematic Review and Recommendations for Best Practice," *Front Neurosci*, vol. 14, p. 594, 2020, doi: 10.3389/fnins.2020.00594.
- [13] S. Balasubramanian, E. Garcia-Cossio, N. Birbaumer, E. Burdet, and A. Ramos-Murguialday, "Is EMG a Viable Alternative to BCI for Detecting Movement Intention in Severe Stroke?," *IEEE transactions on biomedical engineering*, vol. 65, no. 12, pp. 2790-2797, Dec 2018, doi: 10.1109/TBME.2018.2817688.
- [14] J. Rouillard *et al.*, "Hybrid BCI Coupling EEG and EMG for Severe Motor Disabilities," *Procedia Manufacturing*, vol. 3, pp. 29-36, 2015/01/01/ 2015, doi: <https://doi.org/10.1016/j.promfg.2015.07.104>.
- [15] V. de Seta *et al.*, "Cortico-muscular coupling to control a hybrid brain-computer interface for upper limb motor rehabilitation: A pseudo-online study on stroke patients," *Frontiers in Human Neuroscience*, Original Research vol. 16, 2022. [Online]. Available: <https://www.frontiersin.org/articles/10.3389/fnhum.2022.1016862>.
- [16] A. Chowdhury, H. Raza, Y. K. Meena, A. Dutta, and G. Prasad, "Online Covariate Shift Detection-Based Adaptive Brain-Computer Interface to Trigger Hand Exoskeleton Feedback for Neuro-Rehabilitation," *IEEE Transactions on Cognitive and Developmental Systems*, vol. 10, no. 4, pp. 1070-1080, 2018, doi: 10.1109/TCDS.2017.2787040.
- [17] A. Chowdhury, H. Raza, Y. K. Meena, A. Dutta, and G. Prasad, "An EEG-EMG correlation-based brain-computer interface for hand orthosis supported neuro-rehabilitation," *J Neurosci Methods*, vol. 312, pp. 1-11, Jan 15 2019, doi: 10.1016/j.jneumeth.2018.11.010.
- [18] T. Sadoyama, T. Masuda, and H. Miyano, "Relationships between muscle fibre conduction velocity and frequency parameters of surface EMG during sustained contraction," *European journal of applied physiology and occupational physiology*, vol. 51, no. 2, pp. 247-256, 1983/08/01 1983, doi: 10.1007/BF00455188.
- [19] C. Byung Chan and S. Bo Hyeok, "Development of new brain computer interface based on EEG and EMG," in *2008 IEEE International Conference on Robotics and Biomimetics*, 22-25 Feb. 2009 2009, pp. 1665-1670, doi: 10.1109/ROBIO.2009.4913251. [Online]. Available: [https://ieeexplore.ieee.org/stampPDF/getPDF.jsp?tp=&arnumber=4913251&ref=](https://ieeexplore.ieee.org/stampPDF/getPDF.jsp?tp=&arnumber=4913251&ref=sp?tp=&arnumber=4913251&ref=)
- [20] R. Leeb, H. Sagha, R. Chavarriaga, and R. Millan Jdel, "A hybrid brain-computer interface based on the fusion of electroencephalographic and electromyographic activities," *J Neural Eng*, vol. 8, no. 2, p. 025011, Apr 2011, doi: 10.1088/1741-2560/8/2/025011.
- [21] N. A. Bhagat *et al.*, "Design and Optimization of an EEG-Based Brain Machine Interface (BMI) to an Upper-Limb Exoskeleton for Stroke Survivors," *Front Neurosci*, vol. 10, p. 122, 2016, doi: 10.3389/fnins.2016.00122.
- [22] J. Zhang, B. Wang, C. Zhang, Y. Xiao, and M. Y. Wang, "An EEG/EMG/EOG-Based Multimodal Human-Machine Interface to Real-Time Control of a Soft Robot Hand," *Front Neurobot*, vol. 13, p. 7, 2019, doi: 10.3389/fnbot.2019.00007.
- [23] Z. Wang *et al.*, "Incorporating EEG and EMG Patterns to Evaluate BCI-Based Long-Term Motor Training," *IEEE Transactions on Human-Machine Systems*, vol. 52, no. 4, pp. 648-657, 2022, doi: 10.1109/THMS.2022.3168425.
- [24] A. Scano *et al.*, "NIRS-EMG for Clinical Applications: A Systematic Review," *Applied Sciences*, vol. 9, no. 15, doi: 10.3390/app9152952.
- [25] P. Ortega, T. Zhao, and A. A. Faisal, "HYGRIP: Full-Stack Characterization of Neurobehavioral Signals (fNIRS, EEG, EMG, Force, and Breathing) During a Bimanual Grip

- Force Control Task," *Front Neurosci*, vol. 14, p. 919, 2020, doi: 10.3389/fnins.2020.00919.
- [26] F. Pedregosa *et al.*, "Scikit-learn: Machine Learning in Python," *J. Mach. Learn. Res.*, vol. 12, no. null, pp. 2825–2830, 2011.
- [27] M. Cope and D. T. Delpy, "System for long-term measurement of cerebral blood and tissue oxygenation on newborn infants by near infrared transillumination," *Med Biol Eng Comput*, vol. 26, no. 3, pp. 289-94, May 1988. [Online]. Available: <http://www.ncbi.nlm.nih.gov/pubmed/2855531>
- [28] L. Koessler *et al.*, "Automated cortical projection of EEG sensors: anatomical correlation via the international 10-10 system," *Neuroimage*, vol. 46, no. 1, pp. 64-72, May 15 2009, doi: 10.1016/j.neuroimage.2009.02.006.
- [29] M. Okamoto *et al.*, "Three-dimensional probabilistic anatomical cranio-cerebral correlation via the international 10-20 system oriented for transcranial functional brain mapping," *Neuroimage*, vol. 21, no. 1, pp. 99-111, Jan 2004. [Online]. Available: <http://www.ncbi.nlm.nih.gov/pubmed/14741647>
- [http://ac.els-cdn.com/S1053811903005366/1-s2.0-S1053811903005366-main.pdf?\\_tid=b4eff368-3e5d-11e4-8c7e-00000aab0f27&acdnat=1410953471\\_c5a2dba1d0acdd9b6ef748fc21a01acd](http://ac.els-cdn.com/S1053811903005366/1-s2.0-S1053811903005366-main.pdf?_tid=b4eff368-3e5d-11e4-8c7e-00000aab0f27&acdnat=1410953471_c5a2dba1d0acdd9b6ef748fc21a01acd).
- [30] H. Ayaz *et al.*, "Optical imaging and spectroscopy for the study of the human brain: status report," *Neurophotronics*, vol. 9, no. Suppl 2, p. S24001, Aug 2022, doi: 10.1117/1.NPh.9.S2.S24001.
- [31] M. A. Yucel *et al.*, "Best practices for fNIRS publications," *Neurophotronics*, vol. 8, no. 1, p. 012101, Jan 2021, doi: 10.1117/1.NPh.8.1.012101.
- [32] B. Molavi and G. A. Dumont, "Wavelet-based motion artifact removal for functional near-infrared spectroscopy," *Physiological measurement*, vol. 33, no. 2, pp. 259-70, Feb 2012, doi: 10.1088/0967-3334/33/2/259.
- [33] V. N. Vapnik, "The Nature of Statistical Learning," *Theory*, 1995 1995. [Online]. Available: <https://ci.nii.ac.jp/naid/10020951890/en/>.
- [34] J. Ying, Q. Wei, and X. Zhou, "Riemannian geometry-based transfer learning for reducing training time in c-VEP BCIs," *Scientific reports*, vol. 12, no. 1, p. 9818, Jun 14 2022, doi: 10.1038/s41598-022-14026-y.
- [35] K. Won, M. Kwon, M. Ahn, and S. C. Jun, "Selective Subject Pooling Strategy to Improve Model Generalization for a Motor Imagery BCI," *Sensors (Basel)*, vol. 21, no. 16, Aug 12 2021, doi: 10.3390/s21165436.
- [36] A. M. Ray *et al.*, "A subject-independent pattern-based Brain-Computer Interface," *Frontiers in behavioral neuroscience*, vol. 9, p. 269, 2015, doi: 10.3389/fnbeh.2015.00269.
- [37] S. Montero-Hernandez *et al.*, "Estimating Functional Connectivity Symmetry between Oxy- and Deoxy-Haemoglobin: Implications for fNIRS Connectivity Analysis," *Algorithms*, vol. 11, no. 5, 2018, doi: 10.3390/a11050070.
- [38] H. Niu *et al.*, "Resting-state functional connectivity assessed with two diffuse optical tomographic systems," *Journal of biomedical optics*, vol. 16, no. 4, p. 046006, Apr 2011, doi: 10.1117/1.3561687.
- [39] Y. J. Zhang, C. M. Lu, B. B. Biswal, Y. F. Zang, D. L. Peng, and C. Z. Zhu, "Detecting resting-state functional connectivity in the language system using functional near-infrared spectroscopy," *Journal of biomedical optics*, vol. 15, no. 4, p. 047003, Jul-Aug 2010, doi: 10.1117/1.3462973.
- [40] F. Homae *et al.*, "Development of global cortical networks in early infancy," *The Journal of neuroscience : the official journal of the Society for Neuroscience*, vol. 30, no. 14, pp. 4877-82, Apr 7 2010, doi: 10.1523/JNEUROSCI.5618-09.2010.
- [41] E. Kirilina *et al.*, "The physiological origin of task-evoked systemic artefacts in functional near infrared spectroscopy," *Neuroimage*, vol. 61, no. 1, pp. 70-81, May 15 2012, doi: 10.1016/j.neuroimage.2012.02.074.
- [42] A. Jaramillo-Yanez, M. E. Benalcazar, and E. Mena-Maldonado, "Real-Time Hand Gesture Recognition Using Surface Electromyography and Machine Learning: A Systematic Literature Review," *Sensors (Basel)*, vol. 20, no. 9, Apr 27 2020, doi: 10.3390/s20092467.
- [43] J. Shin and J. Jeong, "Multiclass classification of hemodynamic responses for performance improvement of functional near-infrared spectroscopy-based brain-computer interface," *Journal of biomedical optics*, vol. 19, no. 6, p. 067009, Jun 2014, doi: 10.1117/1.JBO.19.6.067009.
- [44] M. Stangl, G. Bauernfeind, J. Kurzmann, R. Scherer, and C. Neuper, "A Haemodynamic Brain-Computer Interface Based on Real-Time Classification of near Infrared Spectroscopy Signals during Motor Imagery and Mental Arithmetic," *Journal of Near Infrared Spectroscopy*, vol. 21, no. 3, pp. 157-171, 2013/06/01 2013, doi: 10.1255/jnirs.1048.
- [45] R. Zimmermann *et al.*, "Detection of motor execution using a hybrid fNIRS-biosignal BCI: a feasibility study," *J Neuroeng Rehabil*, vol. 10, p. 4, Jan 21 2013, doi: 10.1186/1743-0003-10-4.
- [46] K. S. Hong, N. Naseer, and Y. H. Kim, "Classification of prefrontal and motor cortex signals for three-class fNIRS-BCI," *Neurosci Lett*, vol. 587, pp. 87-92, Feb 5 2015, doi: 10.1016/j.neulet.2014.12.029.

- [47] P. Ortega and A. Faisal, "HemCNN: Deep Learning enables decoding of fNIRS cortical signals in hand grip motor tasks," in *2021 10th International IEEE/EMBS Conference on Neural Engineering (NER)*, 4-6 May 2021 2021, pp. 718-721, doi: 10.1109/NER49283.2021.9441323.
- [48] G. Derosiere, F. Alexandre, N. Bourdillon, K. Mandrick, T. E. Ward, and S. Perrey, "Similar scaling of contralateral and ipsilateral cortical responses during graded unimanual force generation," *Neuroimage*, vol. 85 Pt 1, pp. 471-7, Jan 15 2014, doi: 10.1016/j.neuroimage.2013.02.006.
- [49] A. Abdalmalak *et al.*, "Assessing Time-Resolved fNIRS for Brain-Computer Interface Applications of Mental Communication," *Front Neurosci*, vol. 14, p. 105, 2020, doi: 10.3389/fnins.2020.00105.